

Ajan Bazlı Finansal Modelleme ve Uygulama Prosedürü*

Şükrü Can DEMİRTAŞ¹, Senem ÇAKMAK ŞAHİN²

¹Doktora öğrencisi, Yıldız Teknik Üniversitesi; İİBF, ORCID ID: 0000-0002-6953-3599, demirtasukru@gmail.com

²Doç. Dr., Yıldız Teknik Üniversitesi; İİBF, ORCID ID: 0000-0003-3395-9122, cakmaks@yildiz.edu.tr

Öz: Ajan bazlı modelleme (ABM) yöntemi gelişen bilgisayar altyapıları sayesinde model kurmak için giderek daha kullanışlı hale gelmiştir. ABM yine kullanım alanlarının çeşitliliği ve kurulan modellerin, karmaşık sistemler üzerindeki etkinliği ve teorilerin test edilebilmesindeki kolaylık nedeniyle araştırmacıların ilgisini çeken bir yöntem olmuştur. ABM ile araştırmacılar, orman yangınlarından virüs yayılımlarına, sağlık bilimlerinden fizik bilimi modellerine, genel ekonomik modellerden yalnızca yapay piyasaların modellenmesine kadar birçok alanda çalışma yaparak literatürü ve araştırma alanlarını geliştirebilmektedirler. Bu çalışmada Ajan Bazlı Finansal Modelleme (ABFM) ve ABFM ile birlikte kullanılan bazı teknikler ele alınarak ABFM prosedürü açıklanmaktadır. Araştırmacılara yol göstermesi açısından bu alandaki erken dönem çalışmalardan olan Genoa Yapay Piyasası (GASM - Genoa Artificial Stock Market) ve bu model temel alınarak geliştirilen borsa modeli olan Santa Fe Enstitüsü Yapay Piyasası (SFI-ASM – Santa Fe Institute Artificial Stock Market) teknik açıdan incelenmiştir. Söz konusu çalışmalar ABFM literatürünün en bilinen çalışmaları arasında yer aldıklarından bu çalışmada modellemeye örnek olmaları açısından seçilmişlerdir. Ayrıca literatür incelenirken kolaylık sağlaması açısından ODD (Overview, Design Concepts, and Details) prosedürü de araştırmacıların ilgisine sunulmuştur.

Anahtar Kelimeler: Ajan Bazlı Finansal Modelleme, Makine Öğrenmesi, Genetik Algoritma.

Jel Kodları: G10, G11, G12, G17

Agent Based Financial Modeling and Its Application Procedure

Abstract: Agent-based modelling (ABM) has become increasingly valuable for model building thanks to the developing computer infrastructure. ABM has caught the researchers' attention due to its diverse usage areas, the effectiveness of the models on complex systems and the ease of testing theories. With ABM, researchers can expand the literature and research areas by working in various fields, including forest fires, virus spreading, health sciences, physical science models, general economic models, and the modelling of only artificial stock markets. In this study, Agent Based Financial Modelling (ABFM) and some techniques used with ABFM are discussed and the ABFM procedure is explained. To provide guidance for researchers, this study examines the Genoa Artificial Stock Market (GASM), one of the pioneering studies in this area, and the Santa Fe Institute Artificial Stock Market (SFI-ASM), a stock market model that is based on this model, from a technical perspective. These stock market models, which are widely known in the ABFM literature, are used as examples for modelling in this study. In addition, the ODD (Overview, Design Concepts, and Details) procedure has also been presented to the attention of researchers for convenience when examining the literature.

Atıf: Demirtaş, Ş. C.; Çakmak Şahin, S. (2023). Ajan Bazlı Finansal Modelleme ve Uygulama Prosedürü. *Politik Ekonomik Kuram*, 7(2), 201-214. <https://doi.org/10.30586/pek.1315128>

Geliş Tarihi: 15.06.2023
Kabul Tarihi: 05.09.2023



Telif Hakkı: © 2023. (CC BY) (<https://creativecommons.org/licenses/by/4.0/>).

Keywords: Agent Based Financial Modelling, Machine Learning, Genetic Algorithm

Jel Codes: G10, G11, G12, G17

* Bu çalışma Yıldız Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından SDK-2021-4302 nolu proje kapsamında desteklenen ve Doç. Dr. Senem Çakmak Şahin danışmanlığında yürütülen "Ajan Bazlı Finansal Modelleme ve Genetik Algoritma ile Yatırımcı Davranışı Tahmini" adlı doktora tezinden üretilmiştir. "Ajan Bazlı Modelleme İle Yatırımcı Davranışlarının Tahmini" adı ile IX. Yıldız Uluslararası Sosyal Bilimler Kongresi'nde sunulmuştur. Bu araştırmada yer alan tüm/kısmi nümerik hesaplamalar TÜBİTAK ULAKBİM, Yüksek Başarım ve Grid Hesaplama Merkezi'nde (TRUBA kaynaklarında) gerçekleştirilmiştir.

1. Giriş

Ekonomiler; mikro davranışları, etkileşim kalıplarını ve küresel ticaret sisteminin etkileşimini kapsayan karmaşık sistemlerdir. Ekonomik sistem çalışmaları kapsamında, gerçek yaşamın karmaşık kesitleri arasında yer alan asimetrik bilgi, eksik rekabet, stratejik etkileşim, genel öğrenme ve çoklu denge gibi konuların nasıl ele alınacağı incelenmektedir. Hesaplama araçlarındaki son gelişmeler, araştırmacılara bu konuları nicel olarak çalışma olanağı sağlayacak yeni yaklaşımlar sunmaktadır. Bu yeni yaklaşımlardan biri olan Ajan Bazlı Modelleme (ABM), ekonomik süreçlerin etkileşimli ajan dinamik sistemleri şeklinde hesaplanmasına izin vermektedir (Tsfatsion ve Judd, 2006). Ekonomiler aynı zamanda dinamik sistemlerdir. Çok sayıda mikro ajan, tekrar tekrar çevresindeki ajanlarla etkileşime girerek istihdam ve büyüme oranlarını, gelir dağılımını, piyasa kurumlarını, sosyal sözleşmeleri ve bunun gibi daha pek çok makro veriyi küresel çapta etkileyebilmektedir. Küresel sistemdeki bu etkileşimler ABM yöntemi ile modellenip ölçülebilmektedir. Bu bağlamda ekonomilerde ABM simülasyonları yapılabilmekte ve hatta bütününcü incelenmesi ile olası krizler ortaya çıkmadan çözümler için piyasa yapıcıya erken müdahale şansı verilebilmektedir.

Finansal piyasaların dinamiklerini analiz etmek için kullanılan finans alanındaki modeller, piyasaları sınırlı rasyonel ajan grupları olarak ele alarak etkileşimlerini incelemektedirler. Bu modellerde, bilgisayarlar piyasa dinamiklerinin anlaşılmasına yönelik bir araç olarak kullanılmaktadır. Ajan Bazlı Finansal Modelleme (ABFM) bu alandaki diğer modelleme yöntemlerinden ayrılmaktadır. Bunun nedeni, bu modellerde heterojen ajanların bir süredir kullanılması ve piyasa dinamiklerinin analizi için oldukça elverişli olmasıdır. Ajan bazlı finansal piyasa modellerinde dinamik heterojenlik, özellikle önemli bir faktör olarak öne çıkmaktadır. Heterojenlik, sabit veya değişen bir dizi strateji arasında bir ajan veya servet dağılımı ile temsil edilebilmektedir. Aslında optimizasyonel ajanlar, diğer ajan stratejilerinde bu dağılıma en uygun olacak şekilde yanıt vermektedirler. Ancak genellikle bu durum uzayı, optimal bir stratejiyi hesaplamaya başlamak için çok karmaşıktır ve hem ajanları hem de modellemeyi yapan araştırmacıyı sınırlı rasyoneliteyi kabule zorlamaktadır. Bu alanda, sınırlı rasyonelite, özellikle durum uzayının karmaşıklığına bağlı olarak, bireysel ajanların algılanan sınırlamalarından daha etkin bir şekilde hareket etmektedir. Ajanlar tarafından kullanılan basitleştirilmiş temel kuralların, alıştırmaların durağan durum veya modelin dinamikleri üzerinde bir tür basitleştirilmiş çözümü zorladığı, önermediği veya piyasaların rasyonel denge teorileri tarafından tam olarak temsil edilmediği unutmamalıdır. Bununla birlikte, temel kuralların basit uyarlanabilir davranışlar temelinde inşa edilmesi gerektiği de hatırlanmalıdır (Tsfatsion ve Judd, 2006).

Finansal piyasalar, fonların, yatırım fırsatı olmayanlardan yatırım fırsatı olanlara doğru hareketini sağlayarak sermayenin etkin bir biçimde tahsisine hizmet etmektedirler (Aras, 2003). Ajan bazlı finansal modeller finansal piyasalardaki getiri oranları, hacim bilgisi veya kapanış fiyatlarının tahmini için kullanılabilirlerdir.

Çalışmada, öncelikle kompleks adaptif sistemler analiz edilirken en sık kullanılan ajan bazlı modelleme yöntemi kısaca açıklanmıştır. Sonrasında bu yöntemler kullanılarak ajan bazlı finansal modelleme yapan çalışmaların bazıları incelenmiş ve çalışma genelinde ABM'nin nasıl kurgulanabileceği anlatılmaya çalışılmıştır.

Çalışma, literatür özeti, ABFM yönteminin anlatılması, bu alanda çok bilinen iki modelin incelenmesi ve sonuç bölümünde yorumlanması ile tamamlanmaktadır.

2. Literatür Özeti

ABFM özelinde hazırlanan bu çalışmanın literatür özeti bölümünde ilk model çalışmalarının yanı sıra bu alanda son dönemde çıkan çalışmalar da incelenmiştir. Bu alanda en çok bilinen iki çalışma sonrasında inceleneceği için literatüre dahil edilmemiştir.

Arifovic (1994) tarafından yapılan çalışmada üretime karar vermek için genetik algoritma kullanan ajanların CobWeb üretim modelinde rasyonel beklentiler dengesine

yol açabileceğini göstermiştir. Bu çalışma araştırmacılar tarafından ABM literatürünün en erken örneklerinden biri olarak kabul edilmektedir. LeBaron'un (2002) çalışması ABFM literatürünün en bilinen çalışmalarından biridir. LeBaron 2006 yılında yaptığı başka bir çalışmada ise mevcut modellerin türlerini ve bazı ampirik konuları incelemeye geçmeden önce tasarım sorularına odaklanmıştır. Tasarım bölümü, tercihler ve zaman, fiyatın nasıl oluştuğu, evrim, öğrenme, bilginin nasıl temsil edileceği ve sosyal öğrenme gibi konuları kapsamaktadır. LeBaron 2006 tarihli çalışmasında modelin iyi anlaşılmasının gerekliliğini ve kıyaslama için yeterli parametrelere sahip olmasının önemini vurgulamıştır. Çalışma dinamik ve heterojen modellere kadar bir dizi modeli kapsamakta ve kendi ifadesiyle "birkaç tür model, ajanlar tarafından riskli bir varlığın ticaretini yapmak için kullanılan, tipik olarak teknik veya temel olan az sayıda stratejiyi" analiz etmektedir. Sonrasında bu alanda çalışmaya devam ederek 2021 yılında yine ABFM için yazdığı makalesinde ajanlara strateji değişimine imkân verilmesi durumunda ne olacağı sorusuna cevap arayarak toplam ajan sayısının %70'ten biraz fazlasının üçüncü bir tahmin stratejisini seçtiği sonucuna ulaşmıştır. Kirman 2002 ve 2010 yıllarında yayımladığı çalışmalarında ABM yapan araştırmacıların ekonomik sistem modellerini nasıl oluşturduklarını ve genel olarak ekonomik modellemenin nasıl yapılması gerektiğini incelemektedir. Bu çalışma, ajanlar arasındaki doğrudan etkileşimleri hesaba katan modellerin ve özellikle ağ tabanlı yaklaşımların yararlarına ilişkin bir argüman sunmaktadır. Horst (2005), makalesinde ABFM ile bir finansal piyasa modeli oluşturmuştur. Yatırımcıların heterojen ajanlar olarak belirlendiği çalışmada hem toplam ajan davranışını hem de varlık fiyatlarını analiz etmiştir. Çalışma, finansal piyasalarda denge fiyatlarının belirlenmesi ve fiyat dalgalanmalarının analizi için mikro ekonomik bir temel sağlamış ve denge fiyatlarının benzersiz bir dengeye yaklaşması için gereken koşulları ortaya koymuştur. Ayrıca, fiyatların zaman içindeki dalgalanmalarının analizi için difüzyon modellerinin kullanımını savunmuştur. Bu modeller, ajanların kararları ve piyasa koşulları gibi faktörlere dayanarak fiyatların nasıl değiştiğini anlamamıza yardımcı olmaktadır. Mahfoud ve Mani (1996), çalışmalarında hisse senedi işlemlerinden daha fazla kâr sağlanması için Genetik Algoritma (GA) kullanmışlardır. 1600 hisse senedi verisini kullanarak 12 haftalık periyotta bu hisseler arasında daha fazla getiriye sağlayacak hisse senedini ve zamanını araştırmışlardır. Çalışmada GA ile birlikte karşılaştırma için yapay sinir ağlarına (YSA) da başvurulmuştur. Teknik ve temel analiz göstergelerini temsil eden on beş gösterge seçilerek GA'lardan YSA'lara göre daha başarılı sonuçlar alınmıştır. Subramanian ve diğerleri (2004), portföy seçiminde GA kullanımının gösterimi için Hindistan'ın 99-03 arası CMIE-BSE-100 ve BSE Sensex hisse senedi fiyat endeksi verilerini kullanmışlardır. Çalışmada kullanılan modelleri Markovitz'in risk-getiri yaklaşımına uygun olarak 0.1, 0.5 ve 0.9 risk seviyeleri için test ederek en iyi portföyün seçilmesi sağlanmıştır. Demirtaş ve Güngör (2004) ise çalışmalarında IMKB-30 (Borsa İstanbul 30 Endeksi) hisse senetlerini kullanarak oluşturulan biri en düşük standart sapmaya sahip, diğeri ise en yüksek sharpe rasyosuna (riske göre düzeltilmiş performans ölçüsü) sahip olan iki farklı portföyü karşılaştırmışlardır. Çalışmanın sonucunda en düşük riskli portföyü oluşturmak için 19 adet hisse senedi gerektiği belirtilmiştir. Bryan R. Routledge'un (1999) adaptif öğrenme üzerine yaptığı çalışma, Grossman ve Stiglitz'in (1980) modelinin tekrarlanan bir versiyonunda adaptif öğrenme süreçlerinin etkisini araştırmaktadır. Çalışma, özellikle herhangi bir sürecin tekdüze bir seçim dinamiğine sahip olduğu durumlarda ve bilgili yatırımcıların oranı sabit olduğunda, varlık taleplerinin rasyonel beklentilere yakınsayacağını gösteren bir sonuç ortaya koymaktadır. Ayrıca, bu öğrenme süreçlerinin, Grossman-Stiglitz (GS) dengesi için benzersiz ve asimptotik olarak kararlı bir sabit noktaya sahip olması gereken öğrenme süreçlerini araştırmaktadır. Çalışmada öğrenmenin gürültülü deneylere (noisy exp.) karşı sağlamlığı, Binmore ve Samuelson'un (1999) deterministik sapma yaklaşımı kullanılarak ve ekonomik parametrelere ve öğrenme süreci parametrelerine ilişkin koşullar belirlenerek adaptif öğrenmenin GS rasyonel beklentiler dengesine yol açacağı gösterilmiştir. Agrawal ve diğerleri (2019) çalışmalarında, yapay zekâya gösterilen halk ilgisinin çoğu iş

üzerindeki etkisini incelemişlerdir. Çalışmada yapay zekâ alanındaki başarıların çoğunun, makine öğrenimi adı verilen hesaplamalı istatistik dalındaki gelişmelerin bir sonucu olduğu vurgulanmaktadır. Standart makine öğrenimi ders kitaplarındaki regresyon, maksimum olasılık tahmini, kümeleme ve parametrik olmayan regresyon gibi kavramların çoğunun, ekonomistlerce bilindiği ve regresyon ağaçları, sinir ağları ve pekiştirmeli öğrenme gibi diğer tekniklerin ekonometrinin araç setine yeni girdiği belirtilmiştir. Son on yılda yaşanan veri toplama, veri depolama ve algoritmalarındaki gelişmelerin ticari uygulamalarla birlikte hızla ilerlediği ve önemli gelişmelere yol açtığı ifade edilerek, bu tekniklerin işgücü piyasasına etkileri incelenmiştir. O'halloran ve diğerleri (2016), karmaşık tekniklerin 1950'den beri Amerika Birleşik Devletleri'nde mali düzenleme yapısının tasarımını analiz etmek için uygulandığını belirtmişlerdir. Çalışmada mali sektör yasalarını ilan etme, uygulama ve bunlara uyumu denetleme konusunda düzenleyici kurumlara takdir yetkisi devrine odaklanılmıştır. Pabuçcu (2019) çalışmasında, finansal zaman serilerinin barındırdığı belirsizliğin yapılan tahminleri oldukça güçleştirdiğini belirtmiştir. Makroekonomik faktörlerin, politik değişimler, ekonomik görünüm, yatırımcı beklentileri ve diğer endekslerin hareketleri gibi çeşitli faktörlerden etkilenen borsa endekslerinin tahminleri zorlu bir süreçtir, ancak aynı zamanda çekici bir araştırma konusudur. Bu bağlamda, makine öğrenme algoritmalarının endeks hareketleri ve geleceğe dönük tahminler üretmede başarılı olduğu belirtilmektedir. Çalışmada, BIST 100 endeksinin yönünün tahmin edilmesine çalışılmış ve Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM) ve Naive Bayes gibi sınıflandırıcı makine öğrenme algoritmaları kullanılmış ve performansları karşılaştırılmıştır. Borsa endeksi tahminleri için yararlanılan on teknik gösterge modeller için girdi olarak kullanılmıştır. Veri seti 2009-2018 periyodunu kapsayan günlük kapanış değerlerini içermektedir. Çalışmanın sonucunda, BIST 100 endeksi hareketlerinin tahmin edilmesinde kullanılan YSA, DVM ve Naive Bayes sınıflandırıcısı algoritmalarının hepsinin borsa endeks hareketlerini yakalamak için uygun olduğu görülmüştür. Ancak, yapılan analizlerle YSA algoritmasının daha iyi sonuç verdiği gösterilmektedir. Yu ve diğerleri (2014) çalışmalarında LOO-IELM (Birini Dışarda Bırakan Aşırı Öğrenme Makine - Leave-one-out Extreme Learning Machine) kullanarak iflasları tahmin etmeye çalışmışlardır. Yu ve diğerlerinin çalışmasında LOO-IELM ile Combo metodu birleştirilerek toplu bir model oluşturulmuştur. Bu algoritmanın iyi bir tahmin yaptığı belirtilmiştir. Bajari ve diğerleri (2015) ise makine öğrenmesi yöntemleriyle talep tahmininin etkinliğini araştırmışlardır. Bu bağlamda son yıllarda tüketici davranışlarını bilgisayar bilimi ve istatistik kullanarak modelleyen birçok çalışma bulunmaktadır. Bu çalışmada makine öğrenmesi yöntemleri ve klasik ekonometrik yöntemler birbirleriyle karşılaştırılmıştır. Lineer regresyon ve koşullu logit gibi altı farklı makine öğrenmesi yöntemi kullanılan analizde, talebi belirlemek için ise sekiz farklı model kullanılmıştır. Sonuç olarak makine öğrenmesi modellerinin klasik lineer regresyon modeline göre daha doğru sonuçlar verdiği belirtilmiştir. Demirtaş ve Çakmak (2022) tarafından yapılan çalışmada farklı bilgi seviyeleri altında algoritmik yatırımın geleneksel yatırıma kıyasla performansı araştırılmaktadır. Çalışma, yatırımcıların (insan yatırımcılar ve algoritmik yatırımcılar) aldıkları bilgilere dayanarak varlıkların ticaretini yaptığı bir ticaret oyunuyla deneysel bir senaryo kullanmaktadır. 20 farklı trend dönemi üzerinde yapılan çalışmada sonuçlar incelendiğinde algoritmik yatırımcıların kârlılık ve verimlilik açısından insan yatırımcılardan daha iyi performans gösterdikleri görülmektedir. Ancak, yukarı trend durumlarında insan yatırımcıların algoritmik yatırımcılardan daha iyi performans gösterdikleri ortaya çıkmıştır. Maehara ve diğerleri (2015)'nin çalışmasında firmaların reklam verirken etkili ve verimli bütçe tahsisi yapması amacıyla bir model kurulmuştur. Bu doğrultuda her bir medya kanalı etkili kullanılarak müşterilerin bütçelerini bu kanallar arasında nasıl paylaşacakları kararını verebilmeleri amaçlanmıştır. Patel ve diğerleri (2015), makalelerinde hisse senedi ve hisse senedi fiyat endeksi hareketlerini makine öğrenmesi teknikleri ile tahmin etmeye çalışmaktadırlar. Çalışmada, Yapay Sinir Ağları (YSA), Destek Vektör Makinası (DVM), Rassal Orman (Random Forests) ve Naive

Bayes'in iki farklı yaklaşımı kullanılarak hisse senedi fiyat endeksi hareketlerinin tahmin edilmesi konusunda sonuçları karşılaştırılmıştır. En iyi tahmini %83,56 doğruluk payı ile Rastgele Orman algoritması sağlarken en zayıf tahmine ise Naive Bayes algoritması ile ulaşılmıştır. Galindo ve Tamayo (2000) çalışmalarında finansal araçların risk değerlendirmesini makine öğrenmesi modelleri ile tahmin etmişlerdir. En iyi tahmin %8.31 hata payı ile Sınıflandırma ve Regresyon Ağacı (CART Classification and Regression Tree) modelleri kullanılarak gerçekleştirilmiştir.

3. Yöntem Seçimi

Bu bölümde modelleme yapmak isteyen araştırmacılar için izlenmesi tavsiye edilen süreçler ele alınmıştır. Bu süreçlerde basit modellerden daha karmaşık modellere kadar geniş bir yelpazeye değinilmiştir. Spesifik bir alan üzerinde sadece ABM yapmak dahi birçok açıklayıcılığı beraberinde getirmektedir. Ancak istenildiği takdirde, Büyük Veri (Big Data) ile daha geniş bir veri seti kullanarak modellemeye derinlik katılabilmektedir. Daha karmaşık ve ileri çalışmalar için modele Makine Öğrenmesi (Machine Learning - ML) ya da Derin Öğrenme (Deep Learning - DL) algoritmaları kullanılarak öğrenme süreçleri ve tahmin yapabilme özelliği verilebilmektedir. Aynı zamanda istenirse Genetik Algoritma (Genetic Algorithm - GA) gibi optimizasyon algoritmaları kullanılarak modele optimizasyonu sağlama yönünde bir yetenek kazandırılabilir.

3.1. Ajan Bazlı Modelleme Süreçleri

Ajan bazlı modellemeler genel denge kavramından uzak olan ve zaman zaman tam olarak rasyonel olmayan olayları içeren finansal piyasalardaki davranışları keşfetmek için son yıllarda sıkça kullanılan ve görece yeni olan yöntemlerdir. Özellikle ekonomi, bilgisayar bilimi, fizik ve psikoloji gibi disiplinlerden araştırmacılar bu yöntemleri kullanarak ABM literatürünü genişletmeye devam etmektedirler. Günümüzde ajan bazlı modelleme yöntemi, disiplinler arası çalışmalar ile zenginleştirilmekte ve gerçeğe en yakın çalışma alanlarından birini temsil etmektedir.

Ajan bazlı modellerin ilk örneği, fizikçi Enrico Fermi'nin madde yoluyla nötronların taşınmasını içeren problemleri çözmeye çalıştığı 1930'lardaki modeline dayanmaktadır (Poledna ve diğerleri, 2023). 1947 yılına gelindiğinde ise bilim insanları bu teknik için olasılıklı doğasını yansıtan bir isim geliştirmişlerdir ve söz konusu teknik Monte Carlo yöntemi olarak anılmaya başlanmıştır. ABM her disiplinde farklı isimlerle anılmaktadır. Bu isimler arasında, biyoloji ve ekolojide bireysellik bazlı modeller, bilgisayar bilimi ve lojistikte ise çoklu ajan sistemleri, ekonomide ajan bazlı hesaplamalı (kompütasyonel) ekonomi, fizikte ise Monte Carlo simülasyonları yer almaktadır. Son olarak ise Hommes ve Lebaron 2018'de ABM genel tanımından hareketle farklılaştırdıkları Heterojen Ajan Modelleri (HAM – Heterogenius Agent Modelling) ile modellemeyi finans için daha özel bir hale getirmişlerdir. Ancak bu isim henüz genel kullanıma yayılmamıştır.

Ajan bazlı modelleme yöntemini takip ederken dikkat edilmesi gereken altı farklı tasarım sorunu bulunmaktadır. Bunlar; ajan tercihleri, fiyatın belirlenmesi ve ticaretin gerçekleştirme şekli, varlıklar, öğrenme süreci, kıyaslama ve kalibrasyondur. Modelin kurulumundan itibaren izlenecek sıkı bir süreç sayesinde modelin karmaşıklığı hem sorun olmaktan çıkmakta hem de daha iyi bir model kurulmasına yardımcı olmaktadır. Bu durum diğer araştırmacılara da kolaylık sağlamaktadır.

Ajan tercihleri, ABM'ye başlarken alınması gereken en önemli karardır. Tercih türleriyle ilgili sorular çok önemlidir. Bu bağlamda miyop ve intertemporal tercihlerden hangisinin seçileceği de bir başka önemli konudur. İkinci olarak öğrenme sürecinin nasıl olacağına karar verilmelidir. Öğrenme, ek karmaşıklık oluşturabileceği gibi modele gerçekçilik de katmaktadır. Kayıptan kaçınma gibi belirli davranış özelliklerinin de modele dahil edilmesi mümkündür. Bazı durumlarda ajanların tercihlerden tamamen kaçınması ve sadece belirli davranış kurallarının evrimine konsantre olunması yönünde bir argüman da öne sürülebilmektedir. Bu yaklaşım, diğer modellerle karşılaştırmaların yapılmasına izin vermektedir.

Fiyat belirleme ve ticaretin gerçekleşme şekli ise bir diğer tasarım sorunudur. Fiyatın nasıl belirleneceği konusunda birçok yöntem kullanılmaktadır. Bu yöntemler genel olarak dört kategoride incelenebilmektedir. İlk yöntemde, piyasanın dengede olmadığı bir süreçte yavaş fiyat ayarlamaları kullanılmaktadır. İkinci piyasa mekanizması yöntemi, her dönemde piyasayı sayısal olarak temizlemek için veya geçici piyasa takas fiyatına kolay bir analitik çözüm sağlayan bazı teorik basitleştirmeler kullanılmaktadır. (Tsfatsion ve Judd, 2006). Başka bir modelleme yöntemi piyasalardaki gerçek ticaret mekanizmasının modellenmesini içermektedir (LeBaron, 2001). Piyasa benzeri özelliklere sahip olmayan, ancak piyasa davranışına yaklaşabilen yapıları incelemek, diğer bir modelleme çözümü olarak düşünülmektedir (Tsfatsion ve Judd, 2006).

Varlıklar tıpkı gerçek finansal piyasa modellerinde olduğu gibi, ABM'nin de önemli bir parçasıdır. ABM dünyasında genellikle işlem gören varlık türleri oldukça basittir, çünkü heterojen ajanlar sebebiyle ortaya çıkan karmaşıklık, araştırmacıları genellikle ticaret için mevcut varlıkları basitleştirmeye yönlendirmektedir. Birçok ABM, geleneksel ekonomik modellere dayanarak tasarlanmıştır ve bu sayede karşılaştırmaların daha yararlı olmasını sağlamaktadır. Menkul kıymet fiyatları genellikle temel bir değere, örneğin temettü veya kazanca bağlıdır ve gerçek veriler kullanılarak ayarlanabilmektedir (LeBaron, 2001).

Öğrenme sürecini içeren sınırlı sayıda çalışma, yapay zekâ literatüründen alınan teknikleri kullanmaktadır. Bu yapay zekâ tekniklerinden biri GA'dır. GA, Bayesyen öğrenme ve uyarlanabilir doğrusal modeller gibi geleneksel öğrenme yaklaşımlarına alternatif olarak sunulan yöntemlerdir. GA'nın yatırımcı davranışlarında öğrenme sürecini artırmak için kullanışlı olup olmadığı konusunda net bir düşünce yoktur.

Bir diğer tasarım sorunu, yararlı olabilecek kıyaslama/kalibrasyon karşılaştırmalarının oluşturulmasıdır. Piyasanın dinamikleri hakkında sağlam bir anlayış, parametrelerin belirlenmesinde önemli bir faktördür. Bu faktörler, öğrenme dinamikleri ve ticaret açısından kurulacak modelin özelliklerini belirleyebilmektedir. Bir diğer önemli faktör, belirli parametreler için iyi tanımlanmış bir rasyonel beklenti dengesine yakınsama olabilmektedir. Parametre hassasiyetleri, oluşturulan piyasanın bir dengeye doğru yaklaşmasında veya dengeden uzaklaşmasında kritik bir rol oynayabilmektedir. Son olarak, öğrenme sürecinin dinamikleri, bir dengede olduğu kadar dengeden uzakta olduğu durumlarda da ilginç bir araştırma konusu olabilmektedir. Bu ayrımı yapmak için bir ölçütün tanımı esastır (Tsfatsion ve Judd, 2006). Kalibrasyon yapılabilmesi sayesinde çalışmanın gerçek dünyaya yakınlığı yani gerçek piyasayı ne kadar iyi açıkladığı ölçülebilmektedir. Bu bağlamda yapılacak tahmin de daha gerçekçi olmakta ve araştırmaya kıyaslama olanağı sağlamaktadır.

3.2. Makine Öğrenmesi Süreçleri

Algoritma kelime olarak El-Harezmi'den gelmektedir. Problemin çözümünü belirtmek için kullanılan El-Harezmi, El-Gorizm kelimeleri zaman içinde "algorithm"e dönüşmüş ve dilimize algoritma olarak çevrilmiştir. Kelime anlamı itibarıyla çözüm yolu anlamına gelmektedir (Topal Koç, 2021).

Makine öğrenmesi algoritmaları, bilgisayar sistemlerinin deneyimler yoluyla öğrenmesini ve kararlar vermesini sağlayan matematiksel modellerdir. Bu algoritmalar, verilerin analizi, desen tanıma, sınıflandırma, tahmin, kümeleme ve boyut azaltma gibi birçok farklı problemi çözmek için kullanılabilirler. Makine öğrenmesi algoritmaları, denetimli, denetimsiz ve pekiştirmeli öğrenme olarak incelenebilmektedir.

Denetimli öğrenme, makine öğrenmesi alanında en yaygın kullanılan tekniklerden biridir. Bu yaklaşım, bir modelin öğrenmesini sağlamak için veri setlerindeki özellikleri ve hedef değerleri (etiketleri) kullanılmaktadır. Öğrenme süreci, giriş verileri ile istenen çıktılar arasındaki ilişkiyi modellemeyi içermektedir. Algoritma, giriş verileri temelinde bir çıktı üretmekte ve bu çıktı gerçek çıktıyla karşılaştırılmaktadır. Daha sonra, hata düzeltme yöntemleri kullanılarak algoritmanın çıktısı iyileştirilmektedir. Denetimli öğrenmenin çeşitli uygulama alanları vardır. Örneğin, e-posta filtreleme, doğal dil işleme,

görüntü sınıflandırması ve tahmin modelleri gibi alanlarda sıkça kullanılmaktadır. Bu yaklaşım, veri analizi, sınıflandırma, regresyon ve tahmin etme süreçlerini daha verimli hale getirmektedir. Ancak, denetimli öğrenmenin dezavantajlarından biri, etiketlenmiş veri kümesine ihtiyaç duymasıdır. Algoritmalar, veri setindeki özellikleri (girişleri) ve hedef değerleri eşleştirerek bir model oluşturmaktadırlar. Bu modeller daha sonra yeni özelliklerle birlikte kullanılmak üzere eğitilmektedir. Denetimli öğrenme algoritmalarının önemli bir özelliği, modelin doğruluğunu ölçmek ve geliştirmek için geri bildirim sağlayabilmesidir. Karar ağaçları, yapay sinir ağları, destek vektör makineleri ve k-en yakın komşu gibi yöntemler, denetimli öğrenme alanında en popüler olanlardır. Algoritmaların seçimi, verinin özelliklerine, boyutuna ve hedef probleme bağlıdır.

Denetimsiz öğrenme (Unsupervised Learning), veri setinin özellikleri veya etiketleri hakkında hiçbir bilgi sahibi olmadan, veri setindeki gizli yapıları, gruplamaları, yoğun bölgeleri ve aykırı noktaları keşfetmeyi sağlamaktadır. Klasik bir denetimsiz öğrenme algoritması, kümeleme algoritmasıdır. Bu algoritma, veri setindeki benzer özelliklere sahip verileri gruplara ayırmakta ve her grubu tek bir küme olarak temsil etmektedir. Bu gruplama işlemi, veriler arasındaki benzerlik ölçütlerine ve küme sayısına bağlı olarak yapılandırılmaktadır. Denetimsiz öğrenme ayrıca boyut indirgeme teknikleri için de kullanılmaktadır. Veri setindeki yüksek boyutlu veriler, genellikle düşük boyutlu bir alt uzaya indirgenmektedir. Böylece verilerin daha iyi görselleştirilmesi, daha hızlı işlenmesi ve daha az gürültülü hale getirilmesi sağlanmaktadır. Denetimsiz öğrenme algoritmaları, geniş bir uygulama yelpazesine sahiptir. Örneğin, görüntü işleme, müzik analizinde, biyoinformatikte, sosyal medya analizinde ve daha birçok alanda kullanılmaktadırlar. Ancak, denetimsiz öğrenme algoritmaları için doğru parametre seçimi ve sonuçların doğru yorumlanması gibi birçok zorluk bulunmaktadır (Alpaydın, 2010).

Pekiştirmeli öğrenme (Reinforcement Learning), bir ajanın belirli bir ortamda bir dizi eylem gerçekleştirerek belirli bir ödül alma amacıyla öğrenme sürecidir. Bu yöntem, ajanın ortamı keşfetmesine ve optimize etmesine izin veren denetimsiz öğrenme yöntemlerinden farklıdır. Pekiştirmeli öğrenme, özellikle yapay zekâ ve robotik gibi alanlarda, bir ajanın doğru eylem planlarını otomatik olarak öğrenmesi gerektiğinde kullanılmaktadır. Ajanın belirli bir durumda karar vermek için kullanabileceği bir dizi aksiyonu değerlendirmektedir. Ajan, bir eylem gerçekleştirdikten sonra ortamdan geri bildirim almakta ve bir ödül veya ceza kazanmaktadır. Ajanın amacı, ödülü maksimize etmek için en iyi eylem planlarını öğrenmektir. Pekiştirmeli öğrenme algoritmaları, Q-learning, SARSA ve Deep Q-Networks (DQN) gibi çeşitli teknikleri içermektedir. Bu algoritmalar, ajanın öğrenmesini hızlandırmak için çeşitli stratejiler kullanmaktadır. Pekiştirmeli öğrenme, uygulama alanları geniş bir yelpazeye sahiptir. Örneğin, bir robotun belirli bir görevi yerine getirmesi veya bir yapay zekâ sisteminin bir oyunu oynaması için kullanılabilir. Bu yöntemin en büyük zorluklarından biri, ajanın öğrenme sürecinde sık sık yanlış yolu seçmesidir. Bu nedenle, ajanın hızlı ve doğru bir şekilde öğrenmesi için iyi bir şekilde tasarlanması gerekmektedir (Alpaydın, 2010).

3.3. Genetik Algoritma Süreci

ABFM çalışmalarında yatırımcılar ve piyasalar açısından optimizasyon sağlanmaya çalışıldığı görülmektedir. Finansal modellerle çalışıldığında yatırımcıların en iyi getiriye sağlamaya yönelik olarak stratejileri optimize etme düşüncesi olağan bir durumdur. Bu durum araştırmacıların optimizasyon algoritmalarından biri olan GA'ya olan ilgisini artırmıştır. Çalışmada optimizasyon gerekiyorsa GA kullanılarak yapılabilmektedir. GA en iyi sonucu üretmek için kurallara dayalı işlemleri çoklu simülasyon yaparak belirlemeye çalışmaktadır. Bu bölümde GA ile ilgili detaylar verilmektedir.

Kompütasyonel teknolojilerin gelişimi ile birlikte evrim yaklaşımını birleştirmeye çalışan ilk modeller 1950'lerin sonu ve 1960'ların başında yapılmıştır. Yapılan ilk nesil çalışmalar dönemin akademik eğiliminin, biyolojik evrim yaklaşımına ve mutasyon işlemine bağlı olması sebebiyle yeterli başarıyı elde edememişlerdir (Holland, 1992).

1960'ların ortalarında John Holland mutasyon işlemlerine, eşleşme ve çaprazlama işlemlerini eklemiştir. Bu ekleme ile zor problemlerin doğal seçim prensibi doğrultusunda çözülebilmeye olanak sağlayan bir programlama geliştirmiştir. Bu çalışmasıyla Holland akademik çevrelerce genetik algoritmaların kurucusu sayılmaktadır. Daha sonra literatürde Holland'ın orijinal yöntemine dayanan pek çok farklı yöntem geliştirilmiş ve araştırmacılar tarafından farklı alanlara uygulanmıştır (Drake ve diğerleri, 2002).

GA kısaca sistematik rassal arama ve en iyileme yapmaktadır (Shapiro, 1992). GA aslında probleme çözüm sunan her türlü yazılıma verilen genel bir tanımlamayı ifade etmektedir. Yani sabit bir genetik algoritma bulunmamaktadır. Her GA çeşitli aşamaları içeren bir prosedürden oluşmaktadır. Her çalışmada farklı yaklaşımlar sergilenebildiği için GA çeşitli şekillerde karışımına çıkmaktadır. GA, bir optimizasyon prosedürü olarak da bilinmektedir. GA'ların her ne kadar belirli bir şekli olmasa da Buseti'nin 2007 yılında yapmış olduğu çalışmada genel çerçevesinin çizildiği prosedürler şu şekilde özetlenebilir:

- Kodlama yönteminin belirlenmesi,
- İlk nesil olarak adlandırılan başlangıç popülasyonunun oluşturulması,
- İlk nesildeki her bireyin performansının amaç fonksiyonuna göre hesaplanması,
- Yeni neslin oluşturulmasında kullanılacak bireylerin seçilmesi,
- Seçilmiş bireylere genetik işlemler uygulanarak yeni neslin elde edilmesi,
- Yeni nesil birey performanslarının uygunluk fonksiyonuna göre hesaplanması,
- Bitiş koşulu sağlanmamışsa iv. adıma dönülmesi,
- Bitiş koşulu sağlanmışsa en iyi performansa sahip bireyin sonuç olarak verilmesi.

Kodlama yöntemi olarak ikili (binary), permütasyon, değer ve ağaç kodlama yöntemlerinden biri seçilebilmektedir. Başlangıç popülasyonu ile ilgili 1989 yılında Schaffer, Caruana, Eshelman ve Das tarafından yapılan çalışmalarda popülasyon büyüklüğü 20-30, çaprazlama oranı 0,75-0,95 ve mutasyon oranı 0,005-0,01 arasında seçilirse çalışmalar için daha uygun olacağı belirtilmiştir (Mitchell, 1998).

3.4. ODD Prosedürü

ABM yapılırken karşılaşılan tasarım sorunlarını aşmak için Grimm ve arkadaşları bir tasarım şablonu oluşturmuş ve sürecin hem daha kolay anlaşılmasını hem de daha kolay takip edilebilmesini sağlamışlardır (Grimm ve diğerleri, 2006). Bu şablon ilk kez Grimm ve diğerleri (2010) makalesinde Ek 2 olarak sunulmuş ve daha sonra Railsback ve Grimm tarafından (2019) yapılan değişikliklerle güncellenmiştir. Bu süreç genel bakış, tasarım konseptleri ve detaylar başlıklarının kısaltılması olan ODD ("Overview, Design Concepts, and Details") prosedürü olarak anılmaktadır. Yapılan çalışmalarda karmaşıklığı okuyucu açısından kolaylaştırmak için bu sürecin uygulanması uygun gözükmektedir. Aynı zamanda çalışmalar arasında karşılaştırmada kolaylık sağlamaktadır. Araştırmacı modeli kurarken aşağıda verilen sorulara yanıt aramaktadır. Bu bölümde çalışmada seçilen modellerin incelenmesi için ODD sürecinden kısaca bahsedilmiştir.

Genel Bakış: Üç alt başlıktan oluşmaktadır. Bunlar; Amaç ve Kalıplar, Varlıklar Durum Değişkenleri ve Ölçekler, Genel Bakış ve Zamanlama adlı başlıklardır (Grimm ve diğerleri, 2006).

Amaç ve Kalıplar: Modele başlarken şu soruların cevaplarına yönelik çalışılmaktadır: Model kurulurken nasıl bir amaç belirlenir? Bu model amaca ulaşmak için ne kadar yararlı şekilde kurulmuştur ve bunu belirlemek için başka ne tür modeller kullanılmaktadır?

Varlıklar ve Durum Değişkenleri: Modelde bulunan varlıklar açıklanmalıdır. Bu varlıkları karakterize eden durum değişkenleri ifade edilmelidir. Modelin zaman ve uzay çözünürlükleri ile kapsamının tanımlandığı ölçek belirtilmelidir.

Ölçekler ve Zamanlama: Bir simülasyonda temsil edilen uzay ve zamanı tanımlarken, modelin birimlerinin gerçekte neyi temsil ettiğini açıklamak son derece önemlidir. Örneğin, bir arazi kullanım modelinde, bir ızgara hücresi 100 metre kare alanı temsil edebilir ve modelin kapsamı, 10 km x 10 km alanı içerebilir. Zamansal çözünürlük,

bir yıl içindeki zaman adımlarının sıklığı ile belirlenebilmekte ve modelin zaman kapsamı, 20 yıla kadar olabilmektedir. Bu doğru ölçekleme yöntemleri, çalışmanın anlaşılabilirliği ve doğruluğu açısından kritik bir öneme sahiptir.

Tasarım Konseptleri: Bu konseptlerinin çoğu Railsback (2001) ve Grimm ve diğerleri (2005) tarafından araştırılmış ve özetlenmiştir. (Grimm ve Railsback, 2012).

Temel Prensipler: Bu başlık altında, model tasarımının altında yatan temel prensipler, kavramlar, teoriler, hipotezler veya modelleme yaklaşımları belirlenmelidir. Bu prensipler arasındaki ilişkiler, modelde genişletilen karmaşıklık ve çalışmanın amaçları açıklanmalıdır. Modelin kendisi, gerçek dünya senaryolarındaki yararları, doğrulama veya modifikasyon hakkında sağladığı içgörü anlatılmalıdır. Modelde, sistem dinamiklerinin ortaya çıktığı ajan özellikleri için yeni veya önceden geliştirilmiş bir teori kullanılıyorsa belirtilmelidir.

Ortaya Çıkma: Burada modelin ortaya çıkışında ajanların adaptif özelliklerinden kaynaklanan kilit sonuçlar veya çıktıların modelleme yaklaşımı ile belirlenip belirlenmediği anlatılmaktadır.

Adaptasyon: Ajanların adaptif özelliklerinin neler olduğu, kendileri veya çevrelerindeki değişimlere yanıt olarak nasıl kararlar aldıkları veya davranışlarını nasıl değiştirdikleri açıklanmaktadır. Bu özellikler, modelin amaçlarına ve hipotezlerine uygun olarak açıkça tanımlanmalıdır.

Hedefler: Adaptif özellikler, eğer açıkça bireyin belirli bir hedefi başarmasının ölçüsünü artırmak için hareket ederse, o hedefin tam doğası, ne olduğu ve nasıl ölçüldüğü belirtilmelidir. Ajanların alternatifleri sıralayarak karar verirken hangi kriterleri kullandıkları ifade edilmektedir.

Öğrenme: Bu bölümde çok sayıda ajan veya organizasyonun deneyimlerin bir sonucu olarak zamanla adaptif özelliklerini değiştirip değiştirmediği eğer değiştirilebiliyorsa, bu değişimin nasıl gerçekleştiği anlatılmaktadır.

Tahmin: Uyarlanabilir özellikler veya öğrenme prosedürleri, gelecekteki sonuçları tahmin etme yeteneğine sahip olmadan başarılı karar vermenin temelidir. Bu bağlamda, bir ajanın gelecekteki koşulları -çevresel veya dahili- nasıl tahmin edebileceği önemlidir. Bu tahminler, kararların sonuçlarını öngörmek için temel bir araç olarak kullanılabilir.

Algılama: Bireyin diğer kişi ve varlıkların hangi durum değişkenlerini algılayabileceği; örneğin, başka bir bireyin kasıtlı veya kasıtsız olarak gönderebileceği sinyallerin neler olduğu gösterilmektedir.

Etkileşim: Ajanların birbirleriyle olan etkileşimlerinin türü belirtilmektedir. Ajanların birbirleriyle karşılaştığı durumlar ve bu durumlarda varsa diğerleri ile etkileşimlerinin yöntemi açıklanmaktadır. Etkileşimin doğrudan mı, yoksa dolaylı olarak mı olduğu, iletişimi içeriyorsa, bu tür iletişimlerin modelde temsil edildiği durum ifade edilmelidir.

Stokastiklik: Modelin hangi süreçlerde kısmen veya tamamen rassal oldukları varsayılarak kurulduğu ifade edilmektedir.

Kolektivite: Ajanların hangi kümeye ait olduğu veya ajanları etkileyen ve bireylerden etkilenen kümelerin olup olmadığı belirtilmelidir. Bu tür ortak yönler, bir ABM'de önemli bir orta düzey organizasyon olabilmektedir. Ortak yönlerin nasıl temsil edildiği açıklanmalıdır.

Gözlem: Modeli test etmek, anlamak ve analiz etmek için hangi verilerin, nasıl ve ne zaman toplandığı belirtilmelidir. Tüm çıktı verileri serbestçe mi kullanılmakta, yoksa yalnızca belirli veriler örneklenip ampirik bir çalışmada gözlemlenebilecek sonuçları taklit etmek için mi kullanıldığı açıklanmalıdır.

Detaylar: Çalışma ile ilgili daha ileri bilgi edinmek isteyen araştırmacılar için iyi bir anlatım sunmaktadır. Bu detaylar, Başlatma, Giriş verileri ve alt modeller başlıklarından oluşmaktadır.

Başlatma, model dünyasının başlangıç durumu veya simülasyon çalışmasının t=0 anındaki durumu, modelin nasıl başladığını belirlemek için önemlidir. Bu başlangıç

durumu, modelde var olan varlıkların ve durum değişkenlerinin tam değerlerini veya stokastik olarak ayarlandıkları parametreleri içermektedir. Başlatma işlemi her zaman aynı olabilmekte veya simülasyonlar arasında değişken olabilmektedir. Başlangıç değerleri keyfi olarak seçilebilmekte veya verilere dayalı olabilmektedir. Başlangıç değerleri, belirli bir veri kümesine dayanıyorsa, bu veriler referans olarak sağlanabilmektedir. Ayrıca, başlangıç durumu, modelde kullanılan varsayımlar ve diğer parametrelerin değerlerine de bağlı olabilmektedir.

Giriş verileri: Modelde dinamik bir şekilde değişen süreçleri temsil etmek için veri dosyaları veya diğer modellerden gelen harici girdilerin kullanıldığı açıklanmalıdır.

Alt modeller: "Genel bakış" bölümünde listelenen süreçleri temsil eden alt modeller, modelin ayrıntılı olarak incelendiği bölümdedir. Bu alt modellerin her biri, belirli bir süreci temsil etmekte ve bu süreçleri açıklayan bir dizi denklem veya işlevsel formül içermektedir. Bu alt modellerin parametreleri, boyutları ve referans değerleri, her bir sürecin özelliklerine bağlı olarak değişebilmektedir. Örneğin, bir sürecin hızı veya etkinliği, parametrelerin değerine bağlı olarak değişebilmektedir. Ayrıca, boyutlar veya referans değerleri, ölçülen veya tahmin edilen verilere dayalı olarak belirlenebilmektedir. Alt modeller nasıl tasarlanmış veya seçilmiş ve bunlara nasıl parametre uygulanmış ve ardından nasıl test edilmiştir gibi sorular önem verilmesi gereken bir diğer faktördür. Tüm bunlara yanıt arayan araştırmacı, sürecin sonunda tam olarak istediği modeli anlaşılır hale getirmiş olur. ODD süreci bunu sağlamaktadır.

Tablo 1’de ilk dönem ABFM çalışmaları verilmiştir. Bu çalışmalar kurulacak modele örnek teşkil edeceği için kullanılan temel tercihler ve teknik bakımdan araştırmacılar tarafından incelenmeleri uygun görülmüştür.

Tablo 1. Erken dönem ABFM çalışmalarının model yapıları

Yazar	Tercih	Fiyat Belirleme	Evrım, Uygunluk	Strateji Temsili
Arifovic (1996)	CRRA	Piyasa Temizleme	GA, fayda	Gerçek Parametreler
Arthut vd. (1997)	CARA	Piyasa Temizleme	GA, Tahmin	Sınıflandırma
Belrtatti ve Margarita (1992)	CRRA	Rassal Eşleşme	Tepe Tırmanma Algoritması	YSA
Bullard ve Duffy (2001)	CRRA	Piyasa Temizleme	OLS, tahmin	Gerçek Parametreler
Chen ve Yeh (2001)	CARA	Fiyat Ayarlaması	GP, tahmin	Genetik Fonksiyonlar
Chiarella ve Iori (2002)	-	Emir defteri	-,-	Gerçek Parametreler
Farmer ve Joshi (2002)	-	Fiyat Ayarlaması	-,-	Gerçek Parametreler
LeBaron (2001)	CRRA	Piyasa Temizleme	GA, fayda	YSA
Lettau (1997)	CARA	Dışsal	GA, fayda	Gerçek Parametreler
Levy vd. (1994)	CRRA	Piyasa Temizleme	-, fayda	Gerçek Parametreler
Raberto vd. (2001)	-	Emir defteri	-, fayda	Gerçek Parametreler
Routledge (2001)	CRRA	Piyasa Temizleme	GA, fayda	Gerçek Parametreler
Tay ve Linn (2001)	CRRA	Piyasa Temizleme	GA, tahmin	Bulanık mantık

Kaynak: (Tsfatsion ve Judd, 2006)

Tablo 1 ‘de Tercih başlığı altında ajanlar tarafından kullanılan tercih türleri tanımlanmaktadır. Fiyat belirleme, varlık fiyatlarının belirlenme yöntemini açıklamaktadır. Evrim, varsa hangi hesaplamalı evrim mekanizmalarının kullanıldığını ifade etmektedir. Uygunluk, stratejileri geliştirmek ve ajan strateji seçimlerini belirlemek

için kullanılan uygunluk ölçüsüdür. Strateji temsili, stratejilerin bilgisayarda saklanma şeklidir. Genellikle bu, önceden tanımlanmış bir fonksiyonel formdur ve gösterim, basitçe gerçek parametrelerin bir vektörüdür. GA, genetik algoritma, CARA ve CRRA, sırasıyla sürekli mutlak riskten kaçınma ve sürekli göreceli riskten kaçınmadır. (Tesfatsion ve Judd, 2006).

4. GASM ve SFI-ASM Karşılaştırması

Bu iki çalışma ABFM literatüründe borsa yapay piyasa modelleri arasında en çok bilinen çalışmalar arasında yer almaktadır. SFI-ASM temeline GASM'ı alarak ondan daha gelişmiş bir çalışma olarak yayımlanmıştır. İki çalışma da temelde piyasada ajanların incelenmesi üzerine kurgulanmıştır. Erken dönem çalışmaları olmaları sebebiyle oldukça kısıtlı olan iki çalışma da alanının ilk genel borsa yapısı modelleri olmuştur. Bu modeller Tablo 2'de kısaca karşılaştırılmıştır.

Tablo 2. GASM ve SFI-ASM Karşılaştırması

Model	GASM (2000)	SFI-ASM (2002)
Piyasa Yapısı	Yapay Piyasa Modeli	Yapay Piyasa Modeli
Ajanlar	100 ajan - alıcı ve satıcı - Otonom	100 alıcı - 50 satıcı
Varlık	Tek varlık ve sınırsız arz	İki varlık: Bir riskli ve bir risksiz
İşlemler	Rassal olarak eşleşme	Kurala dayalı eşleşme
Zaman	1000 zaman adımı	25 farklı simülasyon zamanı
Kalibrasyon	Yok	Sadece modelin ilk adımında var
Öğrenme	Yok	Var
Market Yapıcı	Var	Var
Fiyat Mekanizması	Market yapıcı fiyatı belirlemede ve sonraki zaman adımını başlatmaktadır.	Market yapıcı belirlemektedir. Ajanlar nakit ve portföylerini güncellemekte ve sonraki zaman adımını başlatmaktadır.
Strateji	Optimist ve Pesimist ajanlar sebebiyle %90 oranında nakit tutulmakta veya %90 hisse alımı gerçekleşmektedir.	100 kural arasından GA ile 20 si elenmekte ve sadece bir adet işlem yapılmaktadır.
Programlama	Extreme Programing (XP)	C ile Smalltalk – NeXT Comp.

Kaynak: Yazar tarafından hazırlanmıştır.

GASM çalışmasında 100 heterojen ajan otonom olarak hareket etmektedirler. Yalnızca alıcı ve satıcı şeklinde iki çeşit olarak piyasada mevcuttur. Ajanların belirli stratejileri bulunmamaktadır. Piyasada tek bir varlık bulunmakta ve ajanlar bu varlığı sınırsız olarak alabilmektedirler. Ticari işlemler zaman adımının başında rassal olarak belirlenmektedir. Tüm piyasa bin işlem adımından oluşmakta ve gerçek piyasalar ile kalibrasyonu bulunmamaktadır. Ajanlar GASM içerisinde öğrenme sürecine sahip değildirler. Market yapıcı her işlem zamanından önce fiyatları özgürce belirlemektedir. Alım-satım kararları bu adımdan sonra rassal olarak belirlenmekte ve simülasyon başlatılmaktadır. Piyasada bulunan ajanların yarısı optimist, diğer yarısı pesimist olarak kurgulanmıştır. Optimist ajanlar ellerinde bulunan nakit parayı %90 oranında harcamakta, pesimist ajanlar ise ellerindeki hisseleri %90 oranında tutmaktadırlar. GASM içerisinde nakit miktarı, ticari varlığın arzı ve market yapıcının fiyatı saptaması süreçleri özgürce belirlenmektedir. Çalışma "extreme programming" yöntemiyle adım adım olacak şekilde inşa edilmiştir.

SFI-ASM'de ise 100 adet alıcı ajan ve 50 adet satıcı ajan bulunmaktadır. Modelde iki varlık bulunur ve riskli, risksiz olarak birbirinden ayrılmıştır. Risksiz varlık %10 oranında faiz ödemesi yaparken riskli varlık stokastik bir süreç sonucu temettü dağıtmaktadır. Piyasada işlemler belirli kurallara göre gerçekleşmektedir. Her seferinde ajanlar bir adet hisseyi alıp satabilmektedir. Optimizasyon yaparken toplamda bulunan yüz farklı

eşleşme kuralından en kötü yirmi tanesi GA kullanılarak elenmektedir. Ajanlar sürekli olarak öğrenmektedir. Modelde beklenti bulunmamaktadır. Piyasada yalnızca ilk adımda kalibrasyon bulunmaktadır. 25 farklı simülasyon yapılmıştır. Market yapıcı bu piyasada da fiyatı belirlemekte ve işlemleri gerçekleştirmektedir. İşlemlerin gerçekleşmesinden sonra ajanlar portföylerini güncellemekte ve hacim bilgisi kayıt altına alınmaktadır.

5. Sonuç ve Öneriler

Çalışmada ele alınan iki model ve erken dönemde yapılan ilk çalışmalar incelendiğinde görülecektir ki bir piyasa diğerinin özelliklerinin üzerine konarak daha ileri bir piyasaya dönüşmektedir. Bu bağlamda GASM tek varlıklı olmasına rağmen onu temel alarak geliştirilen SFI-ASM iki varlıktan oluşmaktadır. Sonrasında daha karmaşık çalışmalar yapılmış, temel ve teknik yatırımcılar modellere girmeye başlamıştır. Bunun yanında ticaret sistemini geliştiren hatta bu çalışmaları spesifik olarak revize eden çalışmalar da mevcuttur.

Araştırmacılar ABM literatürünü ve erken dönem çalışmaları inceledikten sonra ODD süreci üzerinden çalışmaya başlayabileceklerdir. Burada önemli olan ilk etapta piyasa, ajanlar ve varlıkların özelliklerinin iyi belirlenmesidir. Detayların sürecin başında iyi belirlenmesi çalışma ilerledikçe ortaya çıkacak karmaşıklıkla mücadeleyi kolaylaştıracaktır. ABFM çalışmanın ortasında parametrelerin kolaylıkla değiştirilebileceği bir alan değildir. Araştırmacılar bu sebeple varlık özelliklerini netleştirdikten sonra çalışmaya başlamalıdır. Bir diğer önemli nokta ajanların stratejileridir ki, burada oldukça karmaşık süreçlerden bahsedilmesi gerekmektedir. Alım-satım ve hatta elde tutma ya da nakit tutup bunun üzerinden faiz gelirinin olması gibi detaylar büyük önem taşımaktadır ve oldukça karmaşık süreçlerdir. Her bir parametredeki değişim veya yeni bir parametre eklenmesi çalışmada bambaşka sonuçlara yol açabilmektedir. Piyasada ne kadar çok ajan birbirleriyle etkileşime sahipse süreç o kadar karmaşılaşmakta ve simülasyon süresi buna bağlı olarak üssel olarak artmaktadır. Dolayısıyla araştırmacı en baştan senaryoyu iyi belirlemek zorundadır. Bu sayede uzun süreçlerin hatalı şekilde tekrar edilmesinin önüne geçilebilmektedir.

Simülasyonlar yapıldıkça çalışmadaki parametrelerin değişimi ve incelemeler sonrasında araştırmacılar başta hiç tahmin etmedikleri sonuçlara ulaşabileceklerdir. ABM bu sebeple çokça çalışılması gereken ve çalışıkça derinleşen bir yöntemdir.

Kaynakça

- Agrawal, A., Gans, J.S., & Goldfarb, A. (2019). Artificial Intelligence: The Ambiguous Labor Market Impact of Automating Prediction. *Journal of Economic Perspectives*, 33(2), 31-50.
- Alpaydın, E. (2010). *Introduction to Machine Learning*. MIT Press.
- Aras, G. (2003). Sermaye piyasalarının gelişmesinde kurumsal yatırımcıların rolü: OECD ülkeleri ve Türkiye örneği. Kurumsal Yatırımcı Yöneticileri Derneği, İstanbul
- Arifovic, J. (1994). Genetic algorithm learning and the cobweb model. *Journal of Economic dynamics and Control*, 18(1), 3-28.
- Bajari, P., Nekipelov, D., Ryan, S. P., Yang M. (2015). Machine Learning Methods for Demand Estimation, *Journal American Economic Review*, 105(5), 481-485.
- Binmore, K., & Samuelson, L. (1999). Evolutionary drift and equilibrium selection. *The Review of Economic Studies*, 66(2), 363-393.
- Demirtaş, Ö., ve Güngör, Z. (2004). Portföy yönetimi ve portföy seçimine yönelik uygulama. *Havacılık ve Uzay Teknolojileri Dergisi*, 1(4), 103-109.
- Demirtaş, Ş. C., & Şahin, S. Ç. (2022). Algorithmic trading versus human traders at different information levels. *Ullakbilge*, 75, 825-835.
- Drake, Adrian E., Marks, Robert E. (2002). Genetic algorithms in economics and finance: Forecasting stock market prices and foreign exchange- A review, In Shu-Heng Chen (Ed.) *Genetic Algorithms and Genetic Programming in Computational Finance*, 29-54.

- Galindo J. & Tamayo P. (2000). Credit Risk Assessment Using Statistical and Machine Learning: Basic Methodology and Risk Modeling Applications, *Computational Economics*, 15, 107–143.
- Grimm, C. M., Lee, H., Smith, K. G., & Smith, K. G. (Eds.). (2006). *Strategy as action: Competitive dynamics and competitive advantage*. Oxford University Press on Demand.
- Grimm, V., & Railsback, S. F. (2012). Designing, formulating, and communicating agent-based models. In *Agent-based models of geographical systems* (pp. 361-377). Springer, Dordrecht.
- Grimm, V., Berger, U., DeAngelis, D. L., Polhill, J. G., Giske, J., & Railsback, S. F. (2010). The ODD protocol: a review and first update. *Ecological modelling*, 221(23), 2760-2768.
- Grimm, V., Revilla, E., Berger, U., Jeltsch, F., Mooij, W. M., Railsback, S. F., Thulke, H.-H., Weiner, J., Wiegand, T., & DeAngelis, D. L. (2005). Pattern-oriented modeling of agent-based complex systems: Lessons from ecology. *Science*, 310, 987–991.
- Grossman, S. J., & Stiglitz, J. E. (1980). On the impossibility of informationally efficient markets. *The American economic review*, 70(3), 393-408.
- Holland, J. H. (1992). Genetic algorithms. *Scientific American*, 267(1), 66-73.
- Hommes, C., & LeBaron, B. (Eds.). (2018). *Computational economics: heterogeneous agent modeling*, Amsterdam & Oxford, Elsevier.
- Horst, U. (2005). Financial price fluctuations in a stock market model with many interacting agents. *Economic Theory*, 25(4), 917-932.
- Kirman, A. (2002). Reflections on interaction and markets. *Quantitative Finance*, 2(5), 322.
- Kirman, A. (2010). *Complex economics: individual and collective rationality*, London & New York, Routledge.
- LeBaron, B. (2001). A builder's guide to agent-based financial markets, *Quantitative Finance*, 1(2), 254-261, doi: 10.1088/1469-7688/1/2/307.
- LeBaron, B. (2002). Building the Santa Fe artificial stock market. *Physica A*, 1, 20.
- LeBaron, B. (2006). Agent-based computational finance. In L. Tesfatsion & K. L. Judd (Eds.), *Handbook of computational economics* (pp. 1187–1233). Amsterdam: Elsevier.
- LeBaron, B. (2021). Microconsistency in simple empirical agent-based financial models. *Computational economics*, 58(1), 83-101.
- Maehara, T., Yabe, A., Kawarabayashi, K. (2015). Budget Allocation Problem with Multiple Advertisers: A Game Theoretic View, Proceedings of the 32 nd International Conference on Machine Learning, Lille, France, 2015. JMLR: W&CP volume 37.
- Mahfoud S., Mani G. (1996). Financial Forecasting Using Genetic Algorithms, *Applied Artificial Intelligence*, 10, 543- 565.
- Mitchell, M. (1998). *An introduction to genetic algorithms* MIT Press. Cambridge, Massachusetts. London, England.
- O'Halloran, S., Maskey, S., McAllister, G., Park, D. K., & Chen, K. (2016). Data science and political economy: application to financial regulatory structure. *RSF: The Russell Sage Foundation Journal of the Social Sciences*, 2(7), 87-109.
- Pabuçcu, H. (2019). Borsa endeksi hareketlerinin makine öğrenme algoritmaları ile tahmini. *Uluslararası iktisadi ve idari incelemeler dergisi*, (23), 179-190.
- Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert systems with applications*, 42(1), 259-268.
- Poledna, S., Miess, M. G., Hommes, C., & Rabitsch, K. (2023). Economic forecasting with an agent-based model. *European Economic Review*, 151, 104306.
- Railsback, S. F. (2001). Concepts from complex adaptive systems as a framework for individual-based modelling. *Ecological modelling*, 139(1), 47-62.
- Railsback, S. F., & Grimm, V. (2019). *Agent-based and individual-based modeling: a practical introduction*, Princeton & Oxford, Princeton university press.
- Routledge, B. R. (1999). Adaptive learning in financial markets. *The Review of Financial Studies*, 12(5), 1165-1202.
- Schaffer, J. D., Caruana, R., Eshelman, L. J., & Das, R. (1989). A study of control parameters affecting online performance of genetic algorithms for function optimization. In *Proceedings of the 3rd international conference on genetic algorithms* (pp. 51-60).
- Shapiro, S. C. (1992). *Encyclopedia of artificial intelligence second edition*. New Jersey: A Wiley Interscience Publication.
- Subramanian S., Venugopal M.S., Rao U.S. (2004). Usefulness of Genetic Algorithm Model for Dynamic Portfolio Selection, *Journal of Financial Management and Analysis*, 17(1), 45-53.

Tesfatsion, L., & Judd, K. L. (Eds.). (2006). Handbook of computational economics: agent-based computational economics, Amsterdam & Oxford, Elsevier.

Topal Koç, D. (2021). Algoritmik İktisat. *İktisat ve Toplum*, 110-124.

Yu, Q., Miche, Y., Séverin, E., & Lendasse, A. (2014). Bankruptcy prediction using extreme learning machine and financial expertise. *Neurocomputing*, 128, 296-302.

Çıkar Çatışması: Yoktur.

Finansal Destek: Yoktur.

Etik Onay: Yoktur. (Çalışmamız etik onay gerektirmemektedir. Web ortamına sunulmuş ikincil veriler kullanılarak veri havuzu oluşturulmuştur.

Yazar Katkısı: Şükrü Can DEMİRTAŞ (%50), Senem ÇAKMAK ŞAHİN (%50)

Conflict of Interest: None.

Funding: None.

Ethical Approval: None. (Our study does not require ethical approval. A data pool was created using secondary data submitted to the web.

Author Contributions: Şükrü Can DEMİRTAŞ (50%), Senem ÇAKMAK ŞAHİN (50%)
