

## Ekonometri ve Makine Öğrenmesi Etkileşimi Üzerine

Hüseyin Taştan\*

### Öz

İktisatta son dönemde üç eğilim göze çarpmaktadır: (1) ampirizmin yükselişi, (2) ekonometrik analizde deney bazlı nedensel çıkarım çerçevesinin genel kabul görmesi ve (3) makine öğrenmesi yaklaşımının yaygınlaşması ve ekonometri ile daha fazla etkileşimi. Bu çalışma bu ana eğilimler üzerinden ekonometrinin gelişim sürecini tartışmayı ve makine öğrenmesi ile ekonometri arasındaki etkileşimin doğasını anlamayı amaçlamaktadır. Ekonometri görece kısa tarihi içinde önemli atılımlar gerçekleştirmiş ve yönetsel/paradigmatik kırılmalar yaşamıştır. Günümüzde ekonometrik analizin temel amacı nedensel ekonomik ilişkilerin sapmasız/tutarlı ve etkin tahminine ilişkin yöntemler geliştirmektir. Makine öğrenmesinde (gözetimli) ise amaç kestirim/öngörü ve sınıflandırma problemlerinin çözümüne yönelik algoritmalar geliştirilmesidir. Ekonometrik analizdeki gibi sapmasız/tutarlı ve asimptotik etkin tahmin yapabilmek geri planda olduğu için makine öğrenmesi problemleri daha başarılı kestirim modelleri verebilmektedir. Ekonometri ile makine öğrenmesi etkileşiminin özellikle bu olağanüstü kestirim başarısı üzerinden şekillendiği söylenebilir. Devam eden bu etkileşim, nedensel çıkarım için yeni ekonometrik yöntemlerin geliştirilmesi ve mevcut olanların iyileştirilmesi ile sonuçlanmıştır.

**JEL Kodları:** B23, C01, C50

**Anahtar Kelimeler:** Ekonometri, makine öğrenmesi, nedensel çıkarım, ekonometrik modelleme.

---

\* Yıldız Teknik Üniversitesi, İstanbul, <https://orcid.org/0000-0002-2701-1039> (tastan@yildiz.edu.tr).

# On the Interaction between Econometrics and Machine Learning

## Abstract

Three recent trends in economics stand out: (1) the rise of empiricism, (2) general acceptance of the causal inference framework in econometric analysis, and (3) increasing adoption of the machine learning approach and its greater interaction with econometrics. This study aims to discuss the evolution of econometrics over these main trends and to understand the nature of the interaction between econometrics and machine learning. In its relatively short history, econometrics has made important breakthroughs and has also experienced methodological and paradigmatic shifts. More recently, the main purpose of the econometric analysis is to develop methods for unbiased/consistent and efficient estimation of causal economic relations. On the other hand, (supervised) machine learning aims to develop algorithms for solving estimation/prediction and classification problems. The machine learning approach generally provides more successful predictions since it can exploit the bias-variance trade-off optimally compared to the econometric approach where unbiased/consistent and asymptotically efficient estimation is the principal aim. It can be said that the interaction between econometrics and machine learning is shaped by the phenomenal predictive success of machine learning algorithms. This ongoing interaction has resulted in the development of new econometric methods for causal inference and the improvement of the existing ones.

**JEL Codes:** B23, C01, C50

**Keywords:** Econometrics, machine learning, causal inference, econometric modelling.

## 1. Giriş

Bilgi ve iletişim teknolojilerinin hızla yaygınlaşması ve hayatımızın ayrılmaz bir parçası haline gelmesine paralel olarak verilerin toplanması, saklanması ve işlenmesi daha az maliyetli hale gelmiştir. Sosyal bilimlerde ve özelde iktisat ve finans alanlarında kullanılan veri kümelerinin boyutları hem gözlem sayısı hem de değişken sayısı açısından önemli oranda artmıştır. Aynı zamanda, standart/geleneksel ekonometrik ve istatistiksel analizde çok yer bulmayan yeni veri türleri yaygınlaşmaya başlamıştır. Örneğin, metin verileri, uydu görüntüleri ve fotoğraflar iktisadi analizde geleneksel olarak yer almaz ve kullanılmaz. Ancak günümüzde bu veri türlerinin uygulamada daha fazla kullanılmaya başlandığı görülmektedir. Artık uydu görüntülerinden hareketle gelir veya gelişme düzeyi gibi ekonomik göstergeler tahmin edilebilmekte ve geleneksel olarak gözlemlenmesi zor bazı özellikler (dindarlık gibi) ölçülebilmektedir. Metin madenciliği ile yazışma, rapor, kitap, mektup, sosyal medya etkileşimleri (tweet, yorum), konuşma gibi büyük veri setlerinin özetlenmesi ve nicelleştirilmesi mümkün hale gelmiştir. Metin madenciliği araçları ile nicelleştirilen öznitelikler standart ekonometrik analizler için de anlamlı bir girdi olabilmektedir.

Büyük veri yığınlarındaki bilginin ortaya çıkarılmasında geleneksel istatistiksel yöntemlerin yetersiz kalması sonucu *makine öğrenmesi/istatistiksel öğrenme* ve *veri bilimi* gibi yeni disiplinler olarak ortaya çıkmıştır. Makine öğrenmesinin ne olduğunun tam olarak tanımını yapmak zor olsa da farklı açılardan bu alana katkı yapmış bilim insanlarının tanımlarını gözden geçirmek yararlı olabilir. İster istatistiksel öğrenme (James, Witten, Hastie ve Tibshirani, 2021) isterse yapay öğrenme (Alpaydin, 2018) isterse makine öğrenmesi adı verilsin bu araştırma alanının temelinde “verilerden öğrenme” yer almaktadır. Yapay zekanın temelinde öğrenme, öğrenmenin temelinde ise verilerden hareketle değişen ortama uyum sağlayabilme, hatalardan kaçınırken başarıları tekrarlama yer alır. Başka bir ifadeyle, “yapay zekanın ardındaki itici güç makine öğrenmesidir” (Alpaydin, 2018). Alpaydin’in bilgisayar bilimi bakış açısından yaptığı tanıma göre makine öğrenmesi (ya da yapay öğrenme) “bilgisayarların örnek veri ya da geçmiş deneyim kullanılarak bir performans ölçütünü optimize etmek için programlanmasıdır” (Alpaydin, 2018). Bu tanıma göre herhangi bir makine öğrenmesi algoritmasının üç bileşeni vardır: veri, performans ölçütü ya da model ve bilgisayar programı. Öğrenme eylemi ise modelin parametrelerinin tahmin edilmesi ile gerçekleşir. Makine öğrenmesinin disiplinler arası bir yaklaşım gerektirdiği görülmektedir. Verilerin sistematik analizi için matematiksel modellerin oluşturulmasında istatistik biliminin, bu modellerin tahmin edilmesi, verilerin hızlıca işlenmesi ve saklanması için de bilgisayar biliminin katkısı şarttır. Diğer taraftan, çalışma alanına ilişkin uzmanlık bilgisi de önemli bir girdidir.

Makine öğrenmesinin çok kısa sürede iktisat bilimini önemli ölçüde etkileyeceğini düşünen Susan Athey'nin görece daha dar kapsamlı tanımına göre “...Makine öğrenmesi,

temel amacı verilerden hareketle kestirim (*prediction*), sınıflandırma ve kümeleme problemlerinin çözümüne yönelik algoritmaların geliştirilmesidir” (Athey, 2018). Bu tanımın odak noktasında kestirim problemlerinin çözümü yer almaktadır. Bu tanım istatistiksel öğrenme alanının tanımına daha yakındır: “İstatistiksel öğrenme (*statistical learning*), karmaşık veri kümelerinin modellenmesi ve anlaşılması için bir dizi araç geliştirmekle uğraşır. İstatistik bilimi içinde yakın zamanda geliştirilen İstatistiksel Öğrenme alanı, bilgisayar bilimi ve özellikle makine öğrenimindeki paralel gelişmelerle yakından ilişkilidir.” (James vd., 2021).

Makine öğrenmesi kestirim problemlerinde oldukça başarılıdır. Ancak uygulamada iktisatçılar sadece öngörü/kestirim ile ilgilenmez. Uygulamada bizim ilgilendiğimiz ve ağırlıklı olarak öncelik verdiğimiz konu bireyler veya olgular arasındaki nedensellik ilişkilerinin sapmasız/tutarlı ve etkin tahminidir. Makine öğrenmesi doğrudan nedensel soruların nasıl cevaplanacağına ilişkin yöntemler önermez. Ancak, nedensel soruları cevaplamaya çalışan ekonometride yaygın olarak kullandığımız yöntemlerde kestirim kısmının çözümünde makine öğrenmesi faydalı olabilir. Diğer taraftan, en azından bazı durumlarda kestirim modelleri doğrudan iktisadi karar verme amacıyla da kullanılabilir. Kestirim politikası problemleri adı verilen bu alanda veri bazlı iktisat politikası önerileri oluşturulmaktadır.

Bu çalışmanın temel amacı ekonometrinin makine öğrenmesi alanındaki gelişmelerden nasıl etkilendiğinin ortaya çıkarılmasıdır. Bu amaçla makine öğrenmesi yaklaşımındaki temel kavramlar gözden geçirilerek, ekonometri ile benzerlik ve farklılıkları vurgulanacaktır. Geleneksel olarak nedensel ekonomik ilişkilerin sapmasız veya tutarlı tahminine ilişkin yöntemler geliştirmeye öncelik veren ekonometri disiplini ile makine öğrenmesinin nasıl bir etkileşim içinde olduğu tartışılacaktır.

Çalışmanın planı şu şekildedir. İkinci bölümde ekonometrinin kısa bir tarihçesi eşliğinde iktisatta ampirizmin yükselişi ele alınacaktır. Bu gelişim sürecindeki önemli eleştirilerden biri olan Leamer eleştirisi ile güvenilirlik devrimi arasındaki ilişki kurulacak ve ekonometrinin ana odak noktasının nedensel çıkarım olduğu ortaya konacaktır. Üçüncü bölümde makine öğrenmesi problemlerinin genel özellikleri ele alınacak ve ekonometrik yaklaşım ile farklılıkları tartışılacaktır. Makine öğrenmesindeki bazı temel kavramlar ve algoritmalar kısaca gözden geçirilecektir. Dördüncü bölümde ekonometride son dönemde ortaya çıkan bazı gelişmeler ve bunların makine öğrenmesi ile olan ilişkisi ele alınacaktır. Beşinci bölüm özet ve sonucu içermektedir.

## 2. Ekonometri: Nedensel Etkilerin Tahmini

Bu bölümde ekonometrinin kısa bir tarihsel panoramasıyla birlikte veri devriminden nasıl etkilendiği incelenecektir. Tarihsel perspektif ekonometriye getirilen eleştirilerin gelişim sürecini nasıl biçimlendirdiğini görmemize yardımcı olacaktır.

Ekonometri ve makine öğrenmesi özellikle kestirim ve öngörü açısından ortak amaçlara sahip olsalar da günümüzde bu iki disiplin arasında bir iş bölümü oluştuğunu söylemek mümkündür. Genel kabul gören anlayışa göre, ekonometri ve makine öğrenmesi iş bölümü şöyle özetlenebilir: ekonometri ekonomik ilişkilerde nedenselliği araştırırken makine öğrenmesi (özellikle gözetimli makine öğrenmesi) kestirim başarısıyla ilgilenir. Ekonometrik analizin amaçlarından birisi öngörü/kestirim olsa da özellikle nedensel (*causal*) etkilerin sapmasız/tutarlı ve etkin tahmini ön plandadır. Makine öğrenmesi ile istatistiksel/ekonometrik teknik araçlar birçok ortak özelliğe sahip olsalar da aralarında ciddi yaklaşım farklılıkları mevcuttur. Ekonometride model katsayılarının tahmini ana odak noktasıdır. Değişkenler arasındaki ilişkiyi özetleyen bu parametrelerin tutarlı tahmini ilk önceliktir.

Kabaca betimlediğimiz bu iş bölümüne nasıl ulaşıldı? Bunu anlamak amacıyla ekonomi biliminin daha fazla gözlemselleşmesinin (ampirizmin yükselişinin) arka planını incelemek faydalı olabilir. İktisatta veri analizinin (ekonometrinin) ciddiye alınabilmesi için gözlemsel verilerin “deneysel tasarım” ilkeleri çerçevesinde incelenmesini savunan “güvenilirlik devriminin” nasıl biçimlendiği ilk olarak ortaya konacaktır.

### 2.1 Ekonomi Biliminin Gözlemselleşmesi Üzerine

Etki faktörü yüksek akademik iktisat dergilerinde yayımlanan ve prestijli üniversitelerin ekonomi bölümlerinde yapılan bilimsel araştırmaların artık daha uygulamalı/gözlemsel hale geldiği bilinmektedir (örneğin, bkz. Hamermesh, 2013; Einav ve Levin, 2014; Angrist Azoulay, Ellison, Hill ve Feng Lu, 2017). Ekonomi biliminin son dönemde daha uygulama ağırlıklı hale gelmesi, saf teorik araştırma ve modellerin oranının azalması üzerine çeşitli çalışmalar yapılmıştır. İktisadi araştırmalarda verilerin ağırlık kazanması çalışmaların çok disiplinli (ya da disiplinler arası) ve çok yazarlı olmasıyla birlikte ortaya çıkmaktadır. Doğruel ve Doğruel’in (2015) vurguladığı “merkez akademik çevrelerdeki yayın yapma” sürecinin önemli parçalarından biri akademisyenlerin dar bir konuda uzmanlaşmaları olduğu için farklı alanlardan uzmanların bir araya gelerek iş birliği yapmaları ve yayınlarda yazar sayısının artması kaçınılmazdır.<sup>2</sup> Genel olarak

<sup>2</sup> “İktisatta yayın yapma telaşı” (Doğruel ve Doğruel, 2015) ile gözlemselleşmenin artması arasında bir bağ kurulabilir. Merkez dışındaki ülkelerde akademik yayın faaliyeti genellikle “merkezin taklit edilmesiyle” sonuçlanmaktadır. Bu süreçte kalite düşerken araştırma sorusu arka planda kalmakta ve kullanılan nicel yöntem ön plana çıkmaktadır. Bu tartışmanın farklı boyutları için bkz. Doğruel ve Doğruel (2015).

sosyal bilimlerde ve özelde iktisatta ampirizmin yükselme eğiliminin ardında daha kaliteli ve detaylı verilere ulaşmanın kolaylaşması ve bu verilerin analizinde yeni tekniklerin geliştirilmesi bulunmaktadır. Bu teorik iktisadın önemsizleşmesi anlamına gelmemektedir. Yeni veri setleri ve daha önce ölçülemeyen değişkenlerin artık gözlemlenebilir olması hem mevcut ekonomi teorilerinin sınanmasındaki zorlukların giderilmesini kolaylaştırmakta hem de gözlemlerden hareketle daha gerçekçi teorik modellerin geliştirilmesine yardımcı olmaktadır.

Nasıl ki teorinin ağırlıkta olduğu dönemde ekonomi biliminin “uygulamalı matematik” olarak değerlendirilmesi yanı sıra, günümüzde ağırlıklı olarak gözlemselleşmesinden hareketle “uygulamalı istatistik” değerlendirmesi yapmak da o kadar yanlıştır. Makine öğrenmesi tekniklerini de kapsayan tüm ekonometrik yöntemler teorinin dışlanması ya da önemsizleşmesini gerektirmez. Tam tersine, model kurma ve hipotez geliştirme aşamalarında teorik model ve yaklaşımlar son derece önemli katkılarda bulunur. Ayrıca, sosyal ve iktisadi problemler için geliştirilen teorik açıklamaların verilerde karşılık bulup bulmadığı gösterilebilir.

Bu tartışma bir yanı sıra ekonometrideki “teorisiz ölçüm” tartışmasıyla da ilişkilidir. 20nci yüzyılın başından günümüze kadar ekonometri tarihine baktığımızda teorinin veya ölçümün (gözlemlerin) daha fazla ağırlıkta olduğu dönemler göze çarpmaktadır. Tablo 1, Morgan (1990) tarafından 1980’e kadar olan dönem için önerilen tarihsel bölümlere temel alınarak bu kısa tarihi özetlemektedir.<sup>3</sup> Ekonometri Derneğinin kurucuları arasında yer alan ve bu alanda önemli katkılar yapan Ragnar Frisch ve Jan Tinbergen’in 1969 yılında verilen ilk Nobel Ekonomi ödülünü almaları ekonomi biliminin nitelden nicel analize doğru evrimini sembolize etmektedir. Frisch Nobel ödülü makalesinde ekonometrik yaklaşımın geliştirilmesiyle birlikte iktisat biliminin “doğa bilimlerinde olduğu gibi teorilerin gözlemlerden hareketle geliştirildiği ve teorinin de gözlemsel teknikleri etkilediği” bir aşamaya geçtiğini vurgulamıştır (Frisch, 1970). Bu perspektiften bakıldığında, verilerin çoğaldığı çeşitlendiği ve aynı zamanda hesaplama gücünün ucuzladığı günümüzde, iktisadın (ve aslında tüm sosyal bilimlerin) daha fazla gözleme dayalı hale gelmesi ve ampirik çalışmaların yaygınlaşması şaşırtıcı değildir.

Bilimsel ilerleme eleştirisiyle mümkündür. Sosyal bilimlerde içinde bunu en açık şekilde iktisadi düşünce tarihinde, daha özel olarak ekonometri tarihinde görebilmekteyiz. Ekonometrinin kuruluş yıllarındaki temel eleştirileri Tinbergen’in (1939) “*Statistical Testing of Business Cycle Theories*” başlıklı çalışmasını değerlendiren Keynes (1939) yapmıştır. Tinbergen bu çalışmada, ABD verilerini ve çoklu regresyon tekniklerini

<sup>3</sup> Ekonometri tarihinin ve iktisat metodolojisinin detaylı bir incelemesi bu makalenin amaçları dışındadır. Bu konu ile ilgili kapsamlı incelemeler için bkz. Epstein (1987), Morgan (1990), Qin (1993, 2013).

Tablo 1: Kuşbakışı Ekonometri Tarihi

Formasyon öncesi dönem	Kuruluş yılları	Kuruluştan Olgunlaşmaya	Olgunlaşma	Kriz yılları ve eleştiriler	Eleştiri ve arayışlar	Ampirizmin yükselişi	Ampirizmin yükselişi
<1930	1930' lar	1940' lar	1950-1970	1970' ler	1980-2000	2000-2020	2020+
Öncüler: Cournot, Jevons, Edgeworth, Pareto, vd. Modern İstatistik'in kurucuları: Galton, Pearson, Fisher, Yule, Kolmogorov, Slutsky, vd.	Kurucular: R. Frisch J. Tinbergen T. Koopmans Keynes eleştirisi (Keynes-Tinbergen tartışması) Ekonometri Derneğinin kurulması	Haavelmo (1944) "Ekonometriye olasılıksal yaklaşım", Mann and Wald (1943) Cowles Commission (Foundation for Research in Economics)	Büyük Doğrusal Makroekonometrik Modeller (L. Klein, A. Goldberger) Frisch, Tinbergen (Nobel Ödülü, 1969) Temel ekonometrik yöntemlerin geliştirilmesi: IV, 2SLS, 3SLS, ML, FIML, LIML, SURE, panel veri modelleri, yapısal mikro modeller, tercih modelleri	Keynesyen makroekonometrik modellerin başarısızlığı Lucas eleştirisi Rasyonel beklentiler Ekonomik ve finansal zaman serileri: Box-Jenkins ARIMA yaklaşımı, durağan olmama, birim kök testleri	Makroekonometri: VAR/SVAR RBC, DSGE Leamer (1983) eleştirisi Mikroekonometrik analizin yaygınlaşması D. Card, A. Krueger (1994) Zaman serileri ekonometrisi: Eşbütünleşme, VAR/ECM, Volatilite modelleri (Granger, Engle)	İktisatta ampirik analizlerin yaygınlaşmaya başlaması Veri devrimi: İktisadi veri türlerinin çeşitlenmesi ve yaygınlaşması "Güvenilirlik Devrimi" ve Leamer eleştirisi ile ilişkisi Banerjee, Duflo, Kremer (Nobel 2019)	Deneysel (RCT) çerçevesinin yaygınlaşması D. Card, G. Imbens, J. Angrist (Nobel, 2021) Makine öğrenmesi ve ekonometri etkileşimi, Veri Bilimi Disiplinler arası yaklaşım ve "birleşik nicel sosyal bilimler"

Not: 1980' li yıllara kadar olan tarihsel bölümlere Morgan (1990)' a dayanmaktadır.

kullanarak konjonktür dalgalanmalarının kaynaklarını ortaya koymaya çalışmıştır. Ekonometri tarihinde “Keynes-Tinbergen” tartışması olarak bilinen, bizim burada kısaca “Keynes eleştirisi” olarak isimlendirdiğimiz bu eleştirileri şu şekilde sıralayabiliriz: (1) Bu yöntem (çoklu regresyon analizi) sadece teorik olarak önemli tüm değişkenler gözlemlenebilirse (ölçülebilirse) uygulanabilir (dışlanmış değişken sapması, *omitted variable bias*) (2) Değişkenler arasındaki ilişkiler doğrusal olmayabilir (*nonlinearity*) (3) İncelenen dönem homojen değildir (yapısal kırılmalar ve rejim değişiklikleri) (4) Değişkenler arasında yüksek korelasyon olabilir (*multicollinearity*). Keynes’in bazıları tarafından sert ve yersiz bulunan eleştirileri ve Tinbergen’in cevapları ekonometrinin tarihsel gelişimi üzerinde etkili olmuştur.<sup>4</sup> Teknik eleştirilerin ötesinde metodolojik açıdan Keynes’in ekonometriye biçtiği rol sadece bilinen bir teorinin ölçümünü yapmaktan ibarettir; ekonometrinin teori geliştirmek veya alternatif teoriler arasından verilerle uyumlu olanı seçmek gibi bir görevi olamaz. Dolayısıyla, Keynes’e göre eğer ölçüm (ekonometrik analiz) teoriyi desteklemiyorsa sorun ya yöntemde ya da verilerdedir; teori yanlış olamaz (Morgan 1990, 123-4).

Kuruluştan olgunlaşma dönemine geçişi ekonometrinin olasılıksal/istatistiksel temellerinin ortaya konduğu Haavelmo (1944) makalesi temsil etmektedir. Bu makale bir anlamda Keynes’in ekonometrinin rolüne ilişkin eleştirilerine bir cevap olarak nitelendirilebilir (Morgan, 1990). Bu makalede olasılık teorisi kullanılarak iktisat teorileri ile gözlemler arasındaki bağlantı kurulmuş ve Neyman-Pearson hipotez testi teorisi ile birlikte En Yüksek Olabilirlik tahmin yöntemi kullanılarak istatistiksel çıkarım çerçevesi oluşturulmuştur. Bu dönemdeki diğer bir önemli çalışma Mann ve Wald (1943) makalesidir. Haavelmo’nun olasılıksal yaklaşımını kullanan bu makalede sonraki dönemlerde daha da geliştirilecek olan eşzamanlı denklem modellerinin temeli atılmıştır.

Yaklaşık olarak 1950-1970 dönemini kapsayan olgunlaşma döneminde orta/büyük boyutlu Keynesyen makroekonometrik lineer eş zamanlı denklem sistemleri yaygınlaşmıştır. 1970li yıllarda öngörü başarısızlığı ve Lucas (1976) eleştirisi nedeniyle bu modeller gözden düşseler de olgunlaşma döneminde ekonometri teorisine önemli katkılar yapılmış ve halen kullandığımız IV, 2SLS, 3SLS, SURE gibi temel tahmin yöntemleri geliştirilmiştir. Bu yapısal modeller ekonominin işleyişini temsil eden çok sayıda doğrusal denklem (örneğin IS, LM denklemleri) içermekteydi ve değişkenler içsel ve dışsal olarak sınıflandırılıyordu. Modelin belirlenmesi, yani indirgenmiş kalıptan hareketle yapısal katsayıların tahmini için çoğu zaman güçlü varsayımların yapılması gerekmektedir. Lucas’a göre bu yapısal parametrelerin bir kısmı “yapısal” değildi. Bunun nedeni iktisat politikası değiştiğinde yani sistemde bir değişiklik olduğunda bu parametrelerin sabit kalmasıydı. Oysa politika değişimleri iktisadi karar vericilerin davranışını değiştirir çünkü rasyonel bireyler sadece geçmişe bakarak

<sup>4</sup> Bu tartışma ve ekonometri tarihinin kısa bir özeti için bkz. Uygur (2006).



(adaptif) beklenti oluşturmazlar. Bireyler geleceğe yönelik davranışlarını oluştururken mevcut tüm bilgiyi kullanırlar (rasyonel beklentiler). Öyleyse makroekonomik modeller mikroekonomik temellere dayanmalı, yani bireyler stokastik ortamda geleceği de dikkate alarak rasyonel beklenti çerçevesinde modellenmelidir. Bu araştırma programı ilk olarak sadece teknoloji şoklarının yer aldığı RBC modellerinin geliştirilmesi ile sonuçlanmıştır. Bu modeller zamanla evrilerek günümüzde makroiktisatta hakim yaklaşımı temsil eden dinamik stokastik genel denge (DSGE) çerçevesine temel oluşturmuştur. Merkez bankalarının halen kullandığı DSGE modelleri Lucas eleştirisinden azade olsalar da başka açılardan, özellikle bazı varsayımlarının tartışmalı olması ve gereksiz karmaşıklık nedeniyle eleştirilmiştir (Gürkaynak ve Tille, 2017). 2008 Büyük Resesyununun ardından bu önemli küresel krizi öngöremeyen DSGE yaklaşımı, tıpkı 1970’li yıllardakine benzer şekilde bir kırılmayla yerini başka bir paradigmaya bırakmamıştır. Bunun başlıca nedenlerinden biri DSGE modellerinin öngörü amaçlı değil politika değerlendirme amaçlı olmasıdır. Diğer taraftan Büyük Resesyon’un öngörülmesinde Vektör otoregresyon (VAR) modelleri gibi veriye ağırlık veren zaman serisi modelleri ve uzman öngörülleri de başarısız olmuştur (Assenmacher, 2017). Blanchard’a (2017) göre DSGE modelleri teorik tartışmalar için esnek ve geliştirilebilir bir çekirdek oluştururken daha veri odaklı ya da *ad hoc* yaklaşımların da göz ardı edilmemesini önerir. Günümüzde özellikle merkez bankalarının DSGE modellerinin yanı sıra içinde makine öğrenmesi gibi veriye dayalı algoritmaların da yer aldığı geniş bir alet kutusu ile çalıştıkları gözlemlenmektedir.

## 2.2 Leamer Eleştirisi ve “Güvenilirlik Devrimi”

Lucas eleştirisi makroekonomik politikaların ekonometrik değerlendirmesine getirilen ciddi bir eleştiriydi. Daha az bilinen Leamer (1983) eleştirisi ise ağırlıklı olarak ekonometri pratiğinin en önemli parçasını oluşturan regresyon analizinin uygulamada kullanım biçimine yöneliktir. Edward Leamer’ın 1983 yılında yayımlanan makalesinin başlığı kabaca “(Hadi) Ekonometriden Hileyi Çıkaralım” şeklinde çevrilebilir.<sup>5</sup> Ekonometri yazınının klasikleri arasında yer alan bu makalede Leamer (1983) iktisatta ampirik analizlerin neden “daha fazla ciddiye alınmadığını” ve ikna edici olmadığını sorgulamaktadır. İktisatçıların, doğa bilimlerinin etkisi altında kalarak, “bilimsel çıkarımların nesnel olduğu” önermesine karşı çıkan Leamer kişisel inanç ve fikirlerin önemini vurgulamaktadır. Nesnel gerçek diye tanımlanan olguların ise aslında çoğunluğun konsensüs ile vardığı fikirler olduğunu belirtmektedir. Bilim tarihinde çoğunluğun inandığı ve bilimsel gerçek olarak sunduğu ancak daha sonra insanların daha iyi fikirlerle gelerek inanmayı bıraktığı açıklama ve kuramlarla doludur (örneğin, dünyanın merkez olduğu ve güneşin dünya çevresinde döndüğü sistem).

<sup>5</sup> Kelime oyunları ve renkli anlatımı ile tanınan Leamer’ın makalesinin başlığı şöyledir: “Let’s take the con out of econometrics”. İngilizce’deki kelime oyunu çeviride kaybolmaktadır.

Leamer eleştirisinin temelinde sosyal bilimlerde ve özellikle iktisatta nesnel gerçek (*objective truth*) diye bir kavramın olmadığı yer alır. Leamer'a göre, eksiksiz bir teorik modelle işe başlayan ekonometrisyen/iktisatçı, tüm değişkenleri ölçüm hatasız ve doğru olarak gözlemleyip fonksiyon kalıbını doğru kurarsa ve ekonometrik modelin diğer varsayımları da sağlanırsa nesnel gerçekliğe yaklaşabileceğini düşünür. Bu metodolojiyle hareket eden araştırmacı kendi inanç ve ön kabullerinden bağımsız olarak nesnel gerçekliğe ulaşacaktır. Yine Leamer'e göre zaten uygulamada bu metodoloji hemen hemen hiç takip edilmez ve anlamını yitirir. Uygulamalı iktisatçı muhtemelen yüzlerce, binlerce ve hatta milyonlarca model tahmin edecek ve bunların içinden anlamlı olanlarını raporlayacaktır. Leamer açıkça ekonometrisyenlerin modellerine “âşık olduklarını” belirtir ve ampirik analizin mutfağını hiç kimsenin izlemek istemeyeceği bir “sosis yapımı” sürecine benzetir.

Leamer iktisatta ampirik analizin (aslında naif OLS regresyonlarını kastediyor) hiç kimse tarafından ciddiye alınmadığını belirtir. Eğer ciddiye alınmak hedefleniyorsa ilk olarak “nesnel gerçek idolünün” imkânsızlığı kabul edilmelidir. Verilerin dağılımı ve araştırmacının bilinmeyen parametreler hakkındaki önsel inançları nesnel gerçek değil öznel fikirler olarak tanımlanmalıdır. Bayeşçi bir yaklaşım öneren Leamer istatistiksel çıkarımların öznel olduğunun altını çizmektedir.<sup>6</sup> Prestijli dergilerde yayımlanmış iki araştırmanın replikasyonu yapıldığında birbirinden farklı sonuçların elde edilmesi Leamer'ın bu görüşünü destekler niteliktedir (Huntington-Klein vd., 2021). Her bir makale için yedi uygulamalı iktisatçı replikasyon sürecinde birçok öznel kararlar vermiş ancak bunların önemli bir kısmını raporlamamıştır. Tahmin edilen nedensel etkiler ve standart hatalar orijinal makalelerden çok farklı olduğu gibi bazılarında gözlem sayısı dahi doğru raporlanmamıştır (Huntington-Klein vd, 2021).

Leamer eleştirilerinde yalnız değildi. Aynı dönemde Hendry, Keynes'in “istatistiksel simya” eleştirisine gönderme yaparak ekonometrinin simya mı yoksa bilim mi olduğunu sorguluyordu (Hendry, 1980). Hendry kurmaca etkilerin pratikte ayıklanmasında testlerin önemini vurgular. Leamer ise ekonometrik analiz sonuçlarının varsayımlara olan duyarlılığının açıkça ortaya konmasını önerir.

### 2.3 Gözlemsel verilerle nedensel sorular cevaplanabilir mi?

Angrist ve Pischke Leamer eleştirisinin, yani ekonometrik çalışmaların başkaları tarafından ciddiye alınmamasının, en azından ampirik mikro (özellikle emek ekonomisi) için artık geçerli olmadığını öne sürer (Angrist ve Pischke, 2010). Yazarlar ampirik mikro analizin bir “güvenilirlik/saygınlık devrimi” (*credibility revolution*) geçirdiğini,

<sup>6</sup> Leamer (1983) bu çalışmasında EBA (*extreme bounds analysis*) adını verdiği bir duyarlılık analizi önermektedir. Bu yaklaşım yaygın kabul görmemiştir. Bunun yerine uygulamalı çalışmalarda “*robustness analysis*” daha yaygın kullanılmaktadır. Ancak bu “direncillik analizlerinin” belirli bir metodolojik algoritmaya sahip olmadığını ve araştırmaya göre tasarlanması gerektiği söylenebilir.

ve böylece “daha az hile barındırdığını” öne sürer.<sup>7</sup> İktisatta uygulamalı analizlerin daha inandırıcı olması sürecinin temelinde “ampirik araştırma tasarımının” kalitesi yer alır. Yazarlara göre iyi bir araştırma tasarımının özünde rassal deneyler (RCT-*randomized controlled trials*) yer alır. Nedensel çıkarımda RCT’nin “altın standart” olduğu sıkça vurgulanmaktadır (örneğin bkz. Athey ve Imbens, 2017). RCT ile elde edilen sonuçların “hem seminer odalarında hem de mahkemelerde rahatça savunulabileceği” belirtilir (Angrist ve Pischke, 2010, s.4). RCT’ler ve saha deneyleri özellikle gelişme ekonomisi alanında yeniden popüler olmuştur.<sup>8</sup> Ancak RCT’ler hem çok zaman alır hem de genellikle çok pahalıdır veya fiziki olarak olanaksızdır (örneğin eğitimin yaşam boyu gelir üzerindeki etkisi RCT ile saptanamaz). Bazı durumlarda doğal deneyler ya da yarı-deneyler (*natural experiments, quasi-experiments*) nedensel etkilerin tahmininde araştırma tasarımı için bir çerçeve sunabilir. Angrist ve Pischke tasarım-bazlı ekonometrik çalışmaların kökeninde 1980 ve 1990’lardaki araç değişken (IV-*instrumental variables*) bazlı ampirik mikro çalışmalar olduğunu belirtir. Gözlemsel verilerle deney-benzeri tasarımların aslında yeni olmadığı ve ilginç bir tarihi olduğu görülmektedir.

Araştırma tasarımında RCT/doğal-deney yaklaşımı gözlemsel verilere de uygulanabilir. Bu etkilerin belirlenebilmesi/ayırt edilebilmesi (*identification*) için kaliteli veri setlerine ve uygun ekonometrik yöntemlere ihtiyaç duyulur. Potansiyel çıktılar modeli (*potential outcomes*) tasarımın temelinde yer alır (Angrist ve Pischke, 2009; Athey ve Imbens (2017). Bu yaklaşımda kullanılan ekonometrik yöntemler şunlardır: araç değişkenler (IV), regresyon süreksizliği (*Regression Discontinuity*, RD), Farkların Farkları (*Difference-in-Differences*, DiD) ve sentetik kontrol yaklaşımı, Eşleştirme (*Matching*). Bu yöntemler arasında en yaygın olarak kullanılan DiD yöntemi, Card ve Krueger’in (1994) iki dönem-iki grup tasarımının ötesinde çoklu zaman ve grupların olduğu ve politika değişkeninin sürekli olduğu durumlara genelleştirilmiştir (bkz. Callaway ve Sant’Anna, 2021). Bu yöntemlerin özünde “politika/tedavi/program uygulanmasaydı ne olurdu” sorusu (karşıolgusal –*counterfactual*- durum, potansiyel çıktılar) yer alır.

Gözlemsel verilerle deneysel çerçeve kullanılarak nedensel çıkarım yapılmasına ilişkin en bilinen örneklerden biri Card ve Krueger (1994) asgari ücret makalesidir. İktisadi araştırmalarda güvenilirlik devriminin öncülerinden olan Card ve Krueger bu çalışmada farkların-farkları yöntemini kullanarak asgari ücret artışlarının istihdam üzerindeki etkisini ölçmeyi amaçlamıştır. ABD’de birbirine komşu olan iki eyaletten New Jersey’de asgari ücret yaklaşık %19 oranında artarken Pennsylvania’da sabit kalmıştır. En az iki dönemli panel veriyi gerektiren Farkların-farkları (*difference-in-differences*, DiD) yöntemi iktisadi ve sosyal yapı açısından birbirine çok benzeyen bu iki eyaleti asgari ücret değişikliği öncesi ve sonrasında birbiriyle karşılaştırır. Card ve

<sup>7</sup> Böylece hile (“con”) ekonometriden “çıkarılmıştır”.

<sup>8</sup> Bu alanın öncüleri E. Duflo, A. Banerjee, ve M. Kremer 2019 Nobel ekonomi ödülüne layık görülmüştür.

Krueger karşılaştırma için asgari ücret düzeyinde istihdamın görece daha yaygın olduğu fast-food endüstrisinin seçmiş ve ücret artışı öncesinde ve sonrasında aynı işletmelerden anket yoluyla veri toplamıştır. Deneysel yaklaşım terminolojisine göre New Jersey fast-food lokantaları *deney ya da program grubunu*, Pennsylvania lokantaları ise *kontrol grubunu* oluşturmaktadır. Hem gözlenebilen hem de gözlenemeyen özellikler bakımından bu iki bölge birbirine çok benzerdir ve aynı makroekonomik şoklardan etkilenirler. Bu nedenle Pennsylvania bölgesindeki lokantalar karşıolgusal durum için iyi bir gösterge olabilir. Ancak bunun için DiD yaklaşımında “paralel trend” adı verilen varsayımın sağlanması gerekir. Bu varsayım asgari ücret artışı olmasaydı (karşıolgusal durum) her iki bölgede istihdam trendinin aynı olacağını söylemektedir. Klasik teoriye göre asgari ücret artışlarının istihdam üzerinde azaltıcı bir etkiye sahip olacağı beklense de Card ve Krueger (1994) çalışmasında istihdam üzerinde pozitif bir etki bulunmuştur.

Ampirik büyüme alanında en önemli örneklerden biri Acemoglu, Johnson ve Robinson’un (2001) kurum kalitesi ve büyüme performansı çalışmalarıdır. Kurum kalitesinin içsel olması nedeniyle bu çalışmada araç değişken yöntemi kullanılmıştır. Araç değişken olarak da erken yerleşimcilerin yaşam beklentisi kullanılmıştır. Tıpkı Card ve Krueger (1994) çalışmasının paralel trend varsayımına dayanması gibi Acemoglu vd. (2001) çalışmasının bulguları araç değişkenlerin geçerli olması (dışlama kısıtlarının sağlanması) varsayımına dayanır. Gözlemsel verilerle ve hatta RCT’lerle nedensel çıkarımın inandırıcı ve güvenilir olabilmesi için gereken varsayımların (kimi zaman doğrudan test edilemeyen) sağlandığının gösterilmesi gerekmektedir. Angrist ve Pischke’nin savunduğu yaklaşım bu varsayımlar üzerinde daha fazla durulması ve çıkarım sürecinin şeffaf bir şekilde ortaya konmasını gerektirmektedir. Ancak bu şekilde ekonometrik analiz ile elde edilen çıkarımlar ikna edici, savunulabilir ve güvenilir olabilir.

### 3. Makine Öğrenmesi: “Correlation on Steroids”

Ekonometri ve makine öğrenmesi arasındaki etkileşimin doğasının anlaşılabilmesi için makine öğrenmesi alanının ilgilendiği problemlerin yapısının ne olduğunun ve kullanılan yöntem ve yaklaşımların kısaca incelenmesi faydalı olabilir. Makine öğrenmesi ve ekonometri hem amaçları hem de kullandıkları araçlar bakımından çok sayıda benzerliğe sahip olsalar da önemli yaklaşım farkları bulunmaktadır. Makine öğrenmesi yaklaşımında teorik model değil (çoğu zaman teorik bir model yoktur) veri baskındır. Bir başka ifadeyle “model” veriye uygun şekilde seçilir. Verilerin baskın olması beraberinde fazla uyum gibi bazı problemleri de getirmektedir. Bu problemi saptamak ve çözmek için çeşitli araçlar geliştirilmiştir. Bu bölümde makine öğrenmesi problemlerinin genel yapısına ilişkin bilgi verilmesi ve bazı önemli algoritma ve modellerin gözden geçirilmesi amaçlanmıştır.

Makine öğrenmesi yöntemlerinin iktisat ve sosyal bilimler alanlarında daha yaygın kullanılmaya başlanması araştırmacıların ilgisini çekmiştir. Makine öğrenmesinin iktisat

açısından değerlendirildiği çalışmalar arasında Varian (2014), Mullainathan ve Spiess (2017), Athey (2018), ve Athey ve Imbens (2019) sayılabilir. Ayrıca makine öğrenmesi alanında giriş düzeyinde kitaplar için James et al. (2021), Alpaydın (2018), daha ileri düzey için Hastie, Tibshirani ve Friedman (2009) faydalı olabilir.

Yapay öğrenme/makine öğrenmesi problemleri kabaca iki kısma ayrılabilir: gözetimli öğrenme (*supervised learning*) ve gözetimsiz öğrenme (*unsupervised learning*). Gözetimli öğrenmede bir çıktı değişkeni ( $Y \in \mathbb{R}$ ) ve bunu kestirebilecek  $p$  tane  $X = (X_1, X_2, \dots, X_p) \in \mathbb{R}^p$  değişkeni bulunur.  $Y$  ve  $X$  değişkenleri kategorik veya sürekli olabilir. Eğer  $Y$  sürekli değerler alıyorsa elimizde bir *regresyon* problemi, kesikli değerler alıyorsa (kategorik değişken) elimizde bir *sınıflandırma* problemi vardır. Gözetimsiz öğrenme problemlerinde ise önceden tanımlı ve gözlemlenen bir çıktı/hedef değişken yoktur. Gözetimsiz öğrenmenin amaçları arasında mevcut  $X$  değişkenlerinden hareketle gözlemlerin birbirine benzer ancak bilinmeyen kümelere ayrılması veya boyut küçültme sayılabilir. Temel bileşenler analizi (PCA, *principal components analysis*), K-ortalamalar kümelemesi ve hiyerarşik kümeleme bu alanda kullanılan başlıca yöntemler arasındadır.<sup>9</sup>

Gözetimli öğrenmede amaç bu  $X$  değişkenlerinden hareketle  $Y$  çıktı değişkeninin başarılı bir şekilde kestirilmesidir. Öyleyse bir kestirim fonksiyonuna,  $f(X)$ , ve örneklem-içi kestirim başarısını ölçmek için bir kayıp fonksiyonuna,  $L(Y, f(X))$ , ihtiyaç duyarız. Pratikte  $L(Y, f(X)) = (Y - f(X))^2$  şeklinde tanımlı bir karesel hata kayıp fonksiyonu yaygın olarak kullanılmaktadır. Kestirim fonksiyonu ya da modeli,  $f(X)$ , parametrik, yarı parametrik ya da parametrik olmayan biçimlerde tanımlanabilir. Parametrik yöntemlerde  $f(X)$ 'in fonksiyon kalıbının açıkça belirlenmesi gerekirken, parametrik olmayan yöntemlerde fonksiyon kalıbına ilişkin varsayım yapılmaz. Örneğin, ekonometrinin alet kutusundaki en temel araçlardan biri olan doğrusal regresyon analizinde kestirim fonksiyonunun yaklaşık olarak parametrelerde doğrusal olduğu varsayılır:

$$f(X) = \mathbf{X}\boldsymbol{\beta} \quad [1]$$

Burada  $\mathbf{X}$   $n \times p$  boyutlu kestirim değişkenleri matrisi ve  $\boldsymbol{\beta}$ ,  $p \times 1$  boyutlu bilinmeyen parametre vektörüdür. Bu model parametrelerde doğrusal olduğu için  $\mathbf{X}$  ve hedef değişkenin doğrusal olmayan dönüştürmeleri (örneğin polinom ve spline terimleri, etkileşim terimleri, logaritmik dönüştürmeler) kullanılabilir. Bu şekilde modelin esnekliği artsa da araştırmacının hangi dönüştürmeleri kullanacağına karar vermesi gerekir. Bunun yanı sıra pratikte çözülmesi gereken iki problem vardır. Birincisi  $\boldsymbol{\beta}$  vektörünün nasıl tahmin edileceğidir. İkincisi ise kestirim başarısının nasıl ölçüleceğidir. Standart varsayımlar altında Sıradan En Küçük Kareler (OLS) yöntemiyle  $\boldsymbol{\beta}$ 'nin tutarlı

<sup>9</sup> Bu bölümde ağırlıklı olarak gözetimli öğrenme problemleri gözden geçirilecektir.

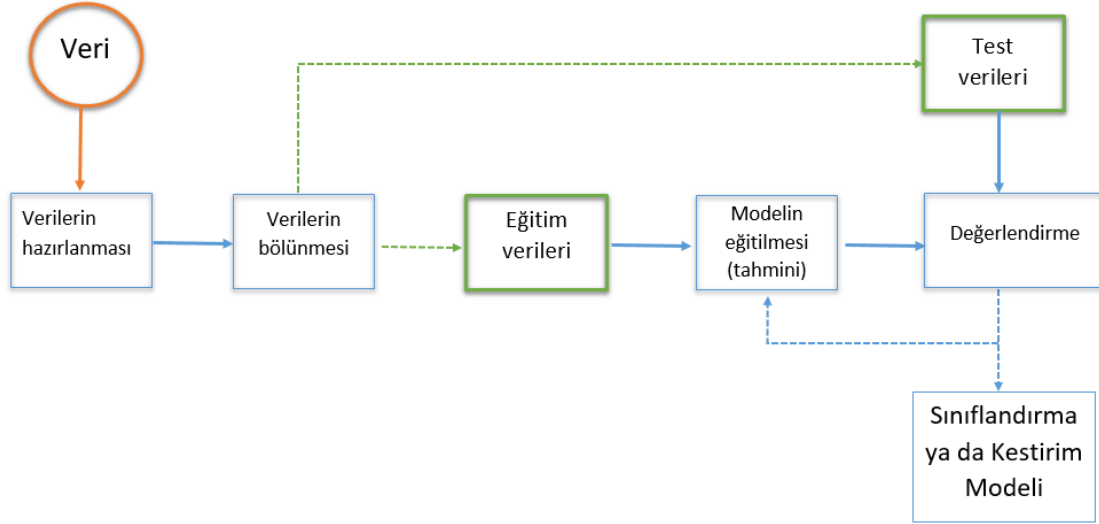
ve etkin tahmini mümkündür. Ancak OLS yöntemi değişken sayısı  $p$ 'nin çok büyük olduğu durumlarda işe yaramayabilir. Öyle ki kestirim değişkenlerinin gözlem sayısından fazla olduğu çok boyutlu problemlerde kullanılamaz. Makine öğrenmesinin üstün olduğu yanlardan biri kestirim değişkenlerinin seçimindeki başarısıdır ve bu nedenle  $p$ 'nin büyüklüğü önemli değildir.

Gözetimli öğrenmede amaç en başarılı tahminleri veren modelin (algoritma ya da programın) bulunmasıdır. Öyleyse kestirim başarısının yansız ve optimal bir şekilde ölçülmesi temel önceliktir. Kestirim başarısının ölçümünde dikkat edilmesi gereken en önemli konu aşırı uyum problemidir. Öğrenme (ya da model uydurma, tahmin) örneklem-içi bir kayıp fonksiyonunun en küçük yapılmasına dayandığı için kestirim başarısı abartılı şekilde tahmin edilebilir ve hatta mükemmel uyum ile sonuçlanabilir. Örneğin, ev fiyatlarını kestirmek istediğimiz bir modelde öğrenme (training) kümesinde 100 gözlem için evlerin 100 özneliğini<sup>10</sup> içeren bir regresyon modeli kurulursa mükemmel uyum ile sonuçlanır,  $R^2 = 1$  olur. Ancak örneklem-içi mükemmel uyum genellikle örneklem-dışı kestirim başarısını garanti etmez. Aşırı-öğrenme/uyum (overfitting) durumunda  $Y$ 'nin kestiriminde daha başarılı bir  $X$  alt kümesinin seçilmesi kaçınılmaz olur. Genel olarak bu işleme düzenleme (regularization) adı verilir.

Ekonometride uygulamada modellerin oluşturulmasında iktisat teorisi yol gösterici olduğundan aşırı uyum problemi daha az karşımıza çıksa da örneklem-içi başarıyı yükselten, gereksiz değişkenlerle (zayıf  $p$ -değerleri nedeniyle) şişirilmiş modellerin kurulma riski her zaman mevcuttur. Makine öğrenmesinde asıl amaç tahminde kullanılmayan, algoritmanın “görmediği” yeni verilerde kestirim başarısıdır (örneklem-dışı kestirim veya öngörü başarısı). Pratikte elimizde sadece bir veri seti varken kestirim başarısını “yeni verilerde” nasıl ölçeriz?

Şekil 1 gözetimli makine öğrenmesi problemlerinde takip edilen aşamaları şematik olarak göstermektedir. Bu metodolojinin en önemli aşaması verilerin “eğitim” ve “test” kümeleri olmak üzere rassal olarak iki parçaya ayrılmasıdır. Eğitim kümesi sadece modelin tahmin edilmesinde kullanılır ve test kümesindeki hedef değişken kestirilir. Yani modelin başarısı tahmin edildiği kümede değil bağımsız başka bir veri kümesinde değerlendirilmektedir. Kestirim performansının doğru bir şekilde ölçümü için çeşitli yaklaşımlar geliştirilmiştir.

<sup>10</sup> Bu öznelilikler arasında  $X$  değişkenlerinin kareleri, kübik veya daha yüksek dereceden polinom terimleri, ve etkileşim terimlerinin yer alacağı unutulmamalıdır. Örneğin evlerin sadece 10 özelliğine ilişkin değişken varsa doğrusal, karesel, kübik ve ikili etkileşimler dikkate alındığında toplam parametre sayısı 75 olur.

**Şekil 1: Tipik Bir Gözetimli Makine Öğrenmesi Probleminin Aşamaları**


### 3.1 Kestirim Başarısının Ölçümü

Kestirim başarısının ölçümünde doğrudan ve dolaylı olmak üzere iki yaklaşım kullanılabilir. Dolaylı tahminde veriye dayalı bir bilgi ölçütüyle modelin karmaşıklığı için bir ceza terimi tanımlanır. Pratikte en çok kullanılan bilgi ölçütleri arasında Mellow's  $C_p$ , Akaike (AIC), ve Bayesçi bilgi ölçütleri (BIC) sayılabilir. Model seçiminde *Düzeltilmiş  $R^2$*  de kullanılabilir. Veriye dayalı bilgi ölçütlerinin en küçük olduğu model veya *Düzeltilmiş  $R^2$* 'nin en büyük olduğu model seçilir. Bu yaklaşım ekonometrik uygulamalarda özellikle zaman serileri modellerinin tahmininde yaygın olarak kullanılmaktadır.

Doğrudan tahminde ise veriler Şekil 1'de özetlendiği gibi eğitim ve test kümeleri olarak iki parçaya ayrılır. Örneğin veri setinin rassal olarak seçilmiş<sup>11</sup> %75'i modelin eğitilmesinde (tahmininde) kalan %25'i ise (test verileri) kestirim performansının hesaplanmasında kullanılır. Böylece aynı veri setinde hem tahmin yapıp hem de performans ölçmekten kaçınmış oluruz.

<sup>11</sup> Burada verilerin bağımsız ve türdeş dağıldığı (*identically and independently distributed, i.i.d.*) varsayılmıştır. Zaman serilerinde rassal seçim yapılamayacağı için veriler kronolojik olarak bölünebilir.

**Şekil 2: Kestirim Hatası ile Modelin Karmaşıklığı Arasındaki İlişki**



Kaynak: Hastie, Tibshirani ve Friedman (2009)

Kestirim modeli  $f(X)$ 'in karmaşıklığı arttıkça aşırı uyum probleminin ortaya çıkma olasılığı da artar. Regresyon problemleri için kestirim hatasının karesinin beklenen değeri (MSE) üç parçadan oluşur (James vd., 2021):

$$\text{MSE} = \text{Kestirim Varyansı} + \text{Sapma Kare} + \text{İndirgenemez Hata Varyansı}$$

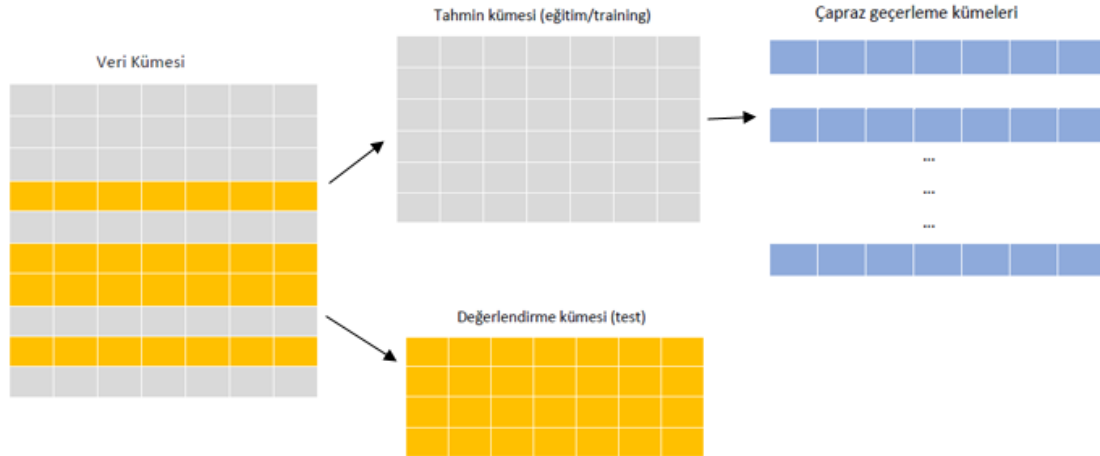
İndirgenemez hata varyansı gözlenemeyen hata teriminin varyansıdır ve makine öğrenmesi algoritmalarıyla açıklanamayan kısmı temsil eder. Eğitim verileriyle kestirim hatasını en küçük yapmaya çalışmak istersek sonuçta yüksek karmaşıklığa sahip bir modele ulaşabiliriz. Ancak bu, yeni bir veri setinde başarılı kestirimler vermeyebilir (*overfitting*). Uygulamada hem kestirimdeki sapmaların hem de değişkenliğin (varyansın) düşük olmasını isteriz. Genel olarak örneklem-içi kestirim hatası modelin karmaşıklığı arttıkça (örneğin değişken sayısı  $p$  artarken) azalmaya devam eder ancak örneklem-dışı (test) kestirim hatası bir noktaya kadar azalır ve daha sonra artmaya başlar. Test hatasının en düşük olduğu bu noktaya “optimal model karmaşıklığı” adı verilir. Makine öğrenmesi algoritmalarında modelin karmaşıklığı genellikle *hiper-parametre* ya da *ayarlanma parametreleri* adı verilen modele özgü sabitlerin bir fonksiyonudur. Örnek olarak K en yakın komşu algoritmasında hesaba katılacak gözlem sayısı, karar ağaçlarında ağacın büyüklüğü, LASSO'da ceza terimi, rassal ormanlarda



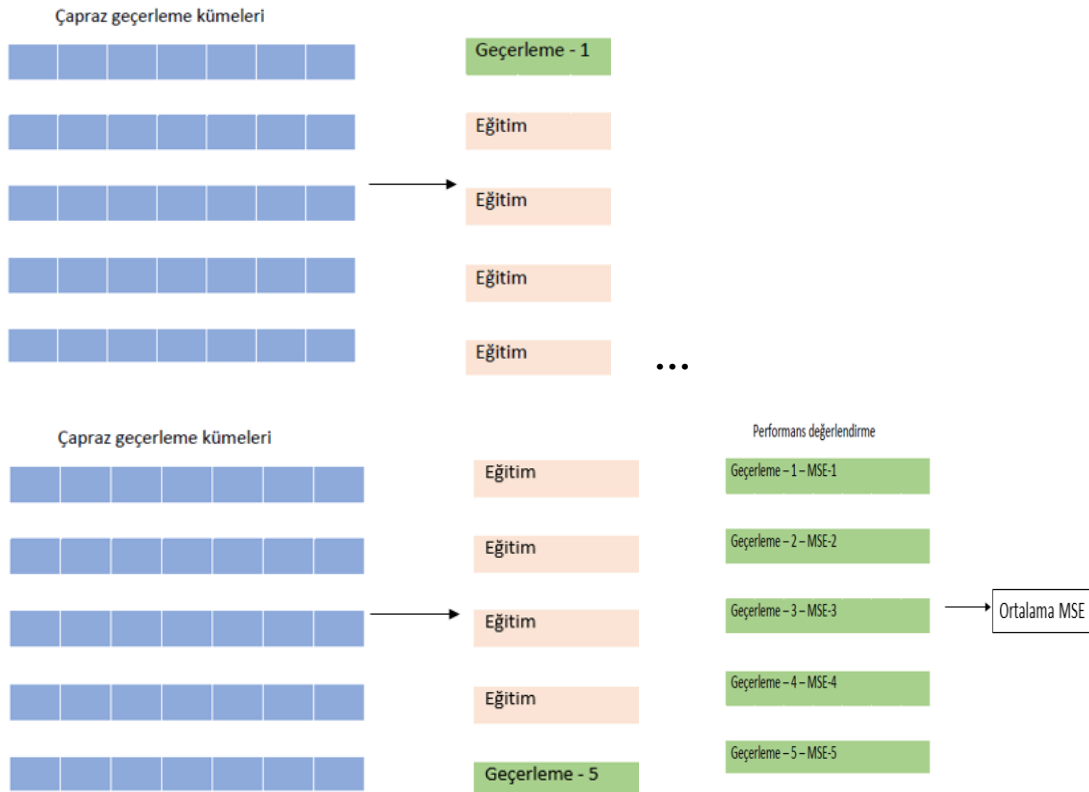
(*random forest*) deęişken sayısı, takviye (*boosting*) yönteminde öğrenme hızı ve iterasyon sayısı verilebilir.

## Şekil 1: Gözetimli Makine Öğrenmesinde Model Performansının Çapraz Geçerleme ile Doğrudan Ölçümü

### (a) Verilerin Bölünmesi ve Çapraz Geçerleme Kümesinin Belirlenmesi



### (b) Çapraz Geçerleme Verilerinden Hareketle Kestirim Performansının Ölçümü



Ayarlanma parametrelerinin seçiminde modelin kestirim başarısının tekrar ölçümü gerekir. En başarılı (en az hatalı) kestirimleri veren ayarlanma parametrelerini seçmek isteriz. Test verileri model karmaşıklığının seçiminde kullanılmaz. Şekil 1’te gösterildiği gibi eğitim kümesi içinde yeniden geçleme (*validation*) kümeleri oluşturularak optimal karmaşıklık düzeyi belirlenebilir. Ayarlanma parametrelerinin seçiminde en yaygın kullanılan yöntem “çapraz-geçerleme” (*cross-validation*) yöntemidir.<sup>12</sup> Çapraz-geçerleme yönteminde eğitim kümesi rassal olarak alt örneklemelere (ya da gruplara/katlara) ayrılarak eğitim ve geçerleme hesaplamaları ayrı ayrı yapılır (Şekil 1). Biri hariç çapraz geçerlemede, eğitim kümesindeki gözlemlerden biri geçerleme için ayrılır ve geriye kalan  $(n - 1)$  gözlem ile model eğitilir. Her bir gözlem ile bu tekrarlanır ve en sonunda elde edilen  $n$  kestirim hatasının (örneğin MSE veya RMSE) ortalaması alınır. Gözlem sayısının çok fazla olduğu veya algoritmanın hesaplama yoğunluğunun yüksek olduğu problemlerde modelin tekrar tekrar çözümü çok vakit alabilir. Alternatif olarak  $k$ -katlı çapraz-geçerleme uygulanabilir. Bu yaklaşımda eğitim örnekleme rassal olarak  $k$  gruba ayrılır (verilerin türdeş ve bağımsız dağıldığını varsayıyoruz) ve sırasıyla her grup geçerleme kümesi olarak kullanılarak kestirim performansı ölçülür. Sonunda  $k$  geçerleme hata ölçütünün ortalaması alınarak test performansı tahmin edilir. Her bir ayarlanma parametresi için bu hesaplamalar tekrarlanarak en düşük çapraz geçerleme hatasını veren model tercih edilir. Dikkat edilirse makine öğrenmesinde tahmin (ya da öğrenme) algoritmik olarak ele alınmaktadır. Ayarlanma parametreleri ile endekslenmiş bir modeller dizisinin tahmini ve içlerinden en başarılısının seçimi söz konusudur. Makine öğrenmesinde en iyi model test verisinde en başarılı olan modeldir.

Gözetimli makine öğrenmesinde temel problem aşırı-öğrenme probleminden kaçınmak amacıyla optimal model karmaşıklığının belirlenmesidir. Öğrenme algoritmalarının genel olarak iki kısımdan oluştuğunu söyleyebiliriz: kestirim fonksiyonu ve düzenleme (*regularizer*) fonksiyonu:

$$\min_{f \in F} \underbrace{\sum_{i=1}^N L(f(x_i), y_i)}_{\text{örneklem-içi kayıp fonksiyonu}} \quad \text{s. t.} \quad \underbrace{R(f) \leq c}_{\text{karmaşıklık kısıtı}} \quad [2]$$

Kestirim fonksiyonu bir kayıp (yitim, *loss*) fonksiyonunun minimum yapılmasıyla optimize ediliyorken, denklem 2’deki  $R(f)$  ile optimal karmaşıklık düzeyi bulunur. Bu çerçevede ML algoritmaları bir kısıtlı optimizasyon problemi olarak formüle edilebilir (Mullainathan ve Spiess, 2017).

<sup>12</sup> İstatistikte verilerin ikiye bölünerek bir kısmında tahmin/hipotez geliştirme diğer kısmında ise değerlendirme (*validation*) yapılmasının uzun bir tarihi vardır (bkz. Stone, 1974). Bu literatürün bir gözden geçirmesi için bkz. Arlot ve Celisse (2010).

### 3.2 LASSO, Ridge, Elastik Net

Düzenleştirme yaklaşımına (bkz. Denklem 2) örnek olarak kestirim fonksiyonunun parametrelerde doğrusal ve karmaşıklık düzeyinin karesel olduğu Ridge regresyonunu verebiliriz:

$$\widehat{\beta}_R = \operatorname{argmin} \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p \beta_j^2 \quad [3]$$

Burada  $\lambda$  düzenleştirmenin düzeyini belirleyen bir ayarlanma parametresidir. Alternatif olarak LASSO (*Least Absolute Shrinkage and Selection Operator*) kayıp fonksiyonu parametrelerin mutlak değerinin toplamını kullanır:

$$\widehat{\beta}_L = \operatorname{argmin} \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p |\beta_j| \quad [4]$$

Her iki yöntemde de  $\beta$  parametreleri ayarlanma parametresine bağlı olarak sıfıra doğru “küçültülür” (shrinkage). Ayarlanma parametresi  $\lambda = 0$  olduğunda OLS çözümüne ulaşılırken  $\lambda \rightarrow \infty$  durumunda parametreler küçülür ve limite 0 olur. Ridge ve LASSO arasındaki temel fark LASSO'nun bazı katsayıları tam olarak sıfır yapabilmesi yani bir bakıma değişkenleri seçebilmesidir. Ridge regresyonunda ise tüm değişkenler modelde yer alır. Pratikte bu iki uç durum yerine Zou ve Hastie (2005) tarafından önerilen elastik net modeli de kullanılabilir. Elastik net modelinde amaç fonksiyonu aşağıdaki gibi yazılabilir:

$$\sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda_1 \sum_{j=1}^p \beta_j^2 + \lambda_2 \sum_{j=1}^p |\beta_j| \quad [5a]$$

veya

$$\text{Kalıntı Kareleri Toplamı} + \lambda \left[ (1 - \alpha) \sum_{j=1}^p \beta_j^2 + \alpha \sum_{j=1}^p |\beta_j| \right] \quad [5b]$$

Denklem 5b'de  $\alpha$  sıfır ile bir arasında bir sabittir.  $\alpha = 0$  olduğunda ridge regresyonu,  $\alpha = 1$  durumunda ise LASSO elde edilir. Pratikte  $\alpha$  çapraz-geçerleme yaklaşımı ile tahmin edilebilir.

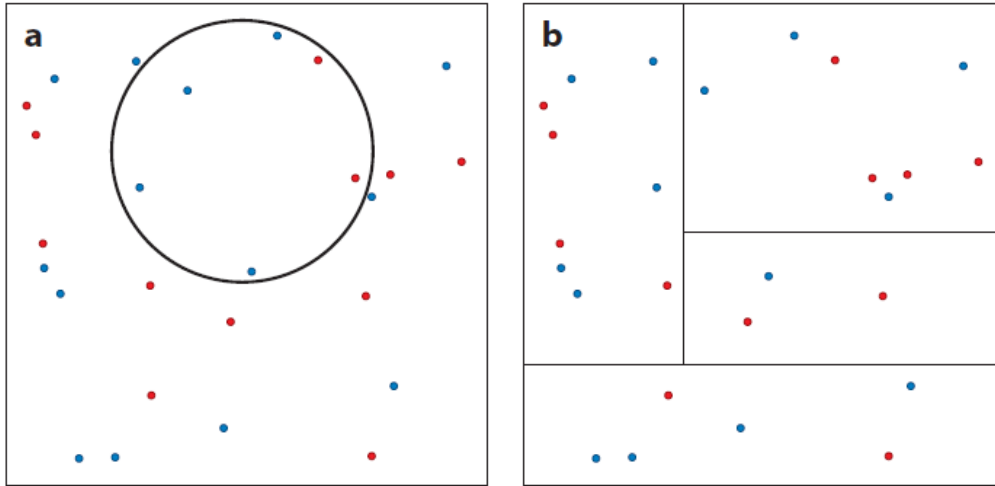
Makine öğrenmesi algoritmaları ile eğittiğimiz modelden hareketle istatistiksel çıkarsama yapabilir miyiz? Daha genel olarak tahmin edilen model yapısal veri üretim süreci olarak yorumlanabilir mi? Her iki soruya da hayır cevabı verilebilir. İstatistiksel çıkarsama yapmak için gerekli olan standart hataların nasıl hesaplanacağı (ya da

hesaplanıp hesaplanamayacağı) belirsizdir. Aynı veri setinden hareketle çok sayıda model tahmin ettiğimizde t-istatistiklerine ilişkin p değerleri geçersiz olur. Bunun nedeni standart hataların model seçim sürecini dikkate almamasıdır. İkincisi, tahmin edilen parametreler yapısal olarak yorumlanamazlar çünkü verilerin rassal olarak tekrar partiyonu yapıp eğitildiğinde aynı kestirim performansına sahip farklı parametre değerleri bulunabilir. Sonuç olarak tahmin edilen parametre değerlerini naif bir şekilde yapısal olarak yorumlamak yanlıştır (Mullainathan ve Spiess, 2017). Makine öğrenmesi algoritmaları katsayıların yorumlanmasının ön planda olduğu problemlerden ziyade en iyi kestirim ve öngörülerin oluşturulmasının amaçlandığı problemlere uygulanmalıdır.

### 3.3 Ağaç Bazlı Yöntemler

Yaygın olarak CART (*Classification and Regression Trees*) kısaltmasıyla ifade edilen sınıflandırma ve regresyon ağaçları oldukça popüler bir gözetimli öğrenme yöntemidir (Breiman vd., 1984). Bu yöntemde doğrusal regresyon ya da lojistik regresyonda olduğu gibi bir kestirim denkleminin açıkça oluşturulması gerekmez. CART yaklaşımında kestirim değişkenleri uzayı alt gruplara (*partition*) ayırılır ve böylece her alt grupta çıktı değişkeninin (sürekli ya da kesikli değerler alabilir) aşağı yukarı benzer (homojen) olması sağlanır. Bu alt kümelerin ya da partiyonların ortalamasına veya sınıflandırma problemlerinde sıklığına göre kestirimler hesaplanır. Bu bir ağaç yapısıyla temsil edilebilir. En altta ağacın yaprakları yani o alt gruba ait (*terminal node*) kestirimler yer alır. Her alt grup için kestirimler o alt grubun (yaprakın) ortalaması alınarak bulunur.


**Şekil 2: Komşuluk Tanımları: (a) Kernel Regresyonu (b) Ağaç-Bazlı Yöntemler**



Kaynak: Athey ve Imbens (2019, s.698).


Ağaç bazlı yaklaşım ile (kernel) regresyonu komşuluk tanımları üzerinden karşılaştırılabilir (bkz. Şekil 2, Athey ve Imbens, 2019). Kernel regresyonunda (a) bir hedef gözlemin çevresindeki Euclid uzaklığı temel alınırken ağaç yöntemlerinde (b) komşuluklar dikdörtgenlerle tanımlanır. Yeni bir gözlem için kestirim hesaplanmak istenirse bu gözlemin yer aldığı dikdörtgenin ortalaması kullanılır.

**Şekil 5: Vücut Ölçüleri ve Cinsiyet Verisi, Boy (cm) ve Kilo (kg)**




Sınıflandırma ağaçlarında da benzer bir yol takip edilir. Örnek olarak Şekil 5’de gösterilen vücut ölçüleri ve cinsiyet verisini düşünelim. Burada amaç sadece kilo ve boy özniteliklerinden hareketle yeni bir gözlemin kadın ya da erkek sınıflarına atanmasıdır. Kilo ve boy arttıkça erkeklerin sıklığının arttığı görülse de iki cinsiyet grubu arasındaki sınırlar çok da keskin değildir. Bu sınıflandırma probleminin karar ağacı çözümü aşağıda verilmiştir.

Şekil 6: Cinsiyet Sınıflandırması İçin Karar Ağacı



Şekil 7: Cinsiyet Sınıflandırması Karar Ağacının Alt Bölgeleri



Şekil 6 cinsiyet sınıflandırması probleminin karar ağacı çözümünü göstermektedir. Şekil 7 ise bu karar ağacının kilo-boy düzlemindeki alt bölgelerini göstermektedir. Ağacın yorumuna her zaman en üst düğüm noktasından başlanır. Buna göre en tepedeki (Şekil 6) kilo değişkenine göre veriler ikiye ayrılır:  $kilo < 64$  koşulu doğruysa sol taraftaki dal üzerinden, değilse sağ taraftaki dal üzerinden ilerlenir. Kilosu 64 kg'dan düşük bir gözlem için boy üzerinden veriler tekrar ikiye ayrılır. Boyu 175 cm'den küçükse Şekil 7'de sol alt tarafta yer alan alt bölgeye ulaşılır. Bu bölgede hangi grup çoğunluktaysa o gruba sınıflandırma yapılır. Buna göre bir gözlemin kilosu 64 kg'dan küçükse ve boyu 175 cm'den kısaysa “kadın” olarak sınıflandırılır. Kilosu 64 kg'dan az ancak boyu 175 cm'den uzun olan bireyler için “erkek” sınıflandırması yapılır. En üst düğüm noktasında  $kilo < 64$  koşulu yanlıssa, sağ taraftaki alt dallar üzerinden kırılım yapılır. Buna göre  $boy < 171$  koşulu yanlıssa, yani boyu 171 cm'den büyükse “erkek” sınıflandırması yapılır (verilerin %43'ü, sağ üstteki alt-bölge). Boy 171 cm'den kısa ise yine boy üzerinden alt bölgelere ayrılır (bkz. Şekil 7).

Görüldüğü gibi bir karar ağacının yorumlanması oldukça kolaydır. En üst düğümünden başlanarak değişkenlerin belirli koşulları sağlayıp sağlamadığına göre alt dallara ve en sonunda yapraklara doğru ilerlenir. Yorum kolaylığı açısından ağaçlar önemli bir avantaja sahip olsalar da genellikle tahmin kesinliği açısından aynı başarıya sahip değildirler (Breiman, 2001b). Bunun nedeni fazla uyumdur.

Tipik olarak bir CART genellikle aşırı uyumla (*overfitting*) sonuçlanır; ulaşılan ağaç çok büyük olma eğilimindedir (limitte her dalda bir gözlem bulunur). Ayrıca tahmin edilen ağaç istikrarsız, yani verilerde küçük değişimlere aşırı duyarlı olabilir. Bu problemlerden kaçınmak için genellikle ya budama (*pruning*) yapılır ya da, pratikte daha popüler olan, toplulaştırma yöntemlerine başvurulur. Budama yönteminde çapraz geçişleme ile ağacın büyüklüğü (modelin karmaşıklığı) belirlenebilir. Yaygın uygulanan bir alternatif sadece bir ağaç tahmin edip budamak yerine çok sayıda ağaç tahmin edip (büyütüp) bunların bir bileşkesi ile (ortalaması) kestirimleri hesaplamaya dayanan toplulaştırma (*aggregation*) yöntemleridir. Toplulaştırma yöntemleri ağırlıklı olarak karar ağaçları ile kullanılsa da diğer öğrenme algoritmaları ile de kullanılabilir.

### 3.4 Toplulaştırma Yöntemleri: Bagging, Rassal Ormanlar, Boosting

Makine öğrenmesi algoritmalarının yaygınlaşmasıyla birlikte toplulaştırma yaklaşımı da popülerleşmeye başlamıştır. Farklı modellerin bir şekilde bir araya getirilmesiyle daha başarılı kestirim yapılabilir. Özellikle 2006 yılındaki bir milyon dolarlık Netflix ödülünü kazanan takımın kurduğu kestirim modelinin çok sayıda modelin bileşkesi olması bu yaklaşımlara ilgiyi arttırmıştır (Bennett ve Lanning, 2007).

Breiman (1996) tarafından geliştirilen *Bagging*<sup>13</sup> yaklaşımının temelinde elimizdeki veri setinden hareketle yeniden yerine koyma usulüyle rassal örneklemeler oluşturulması

<sup>13</sup> “Bagging” terimi “Bootstrap Aggregating” kelimelerinden türetilmiştir.

(*bootstrap*) yer alır. Her bir *bootstrap* örnekleme için model yeniden eğitilir ve kestirimler oluşturulur. Toplamda  $B$  *bootstrap* yinelemesi yapıldıysa toplulaştırma sonucu elde edilen kestirim bu  $B$  kestirimin ortalaması olacaktır. Bu yöntemde ayrıca test kümesi tanımlamaya gerek kalmaz. *Bootstrap* örnekleme girmeyen gözlemler test kümesi olarak kullanılabilir.

*Bagging* yöntemi özellikle karar ağaçlarında yaygın olarak kullanılmaktadır. Torbalama (*bagging*) yönteminde her *bootstrap* örnekleminde yer alan kestirim değişkenleri aynıdır. Yani ağaç tahmininde tüm değişkenler dikkate alınmaktadır. Bunun sonucunda modellerin kestirim değerleri birbiriyle yüksek ilişkili olmaktadır. Gözlemler farklı olsa da değişkenlerin aynı olması kestirim ortalamasının varyansını yükseltmektedir. Karar ağaçlarında korelasyon ve dolayısıyla kestirim varyansını düşürmek amacıyla ağaçların dal ayrımlarında tüm değişkenler değil bunların  $m$  gibi bir rassal alt kümesi dikkate alınabilir. Bu yöntem “rassal orman” adı verilir (Breiman, 2001a). Dal ayrımlarında değişkenlerin rassal olarak seçilmiş bir alt kümesi dikkate alındığı için tahmin edilen ağaçlar farklı olma eğilimindedir. Ağaç bazlı yaklaşımlarda torbalama yöntemi rassal ormanların özel bir halidir.

Takviye (*boosting*) yönteminde *bootstrap* örneklemleri oluşturulmaz. Bunun yerine her yinelemede önceki kestirim sonuçlarının, örneğin karar ağacının, iyileştirilmesi amaçlanır. Boosting algoritmasının temelinde tek başına zayıf ve başarısız performansa sahip bir kestirim kuralının (örneğin küçük bir sınıflandırma ya da regresyon ağacının) birleştirilerek daha az hatalı kestirim kuralının elde edilmesi bulunmaktadır (Schapire ve Freund, 2012).

Popüler bir sınıflandırma algoritması olan Adaptive Boosting (AdaBoost) yönteminde kestirimler bir öncekine bağlı olarak yinelemeli bir şekilde oluşturulur. Kullanılan kestirim modeli zayıf olsa da her yinelemede önceki sonuçlar iyileştirilerek ilerlenir. Örneğin epostaların “gerekli-gereksiz” olarak sınıflandırılması probleminde epostanın “indirim” kelimesini içerip içermemesi gibi zayıf ancak tümünden başarısız da olmayan bir kural tanımlanabilir. Algoritmanın adımları aşağıdaki gibi yazılabilir:

1. Tek kırılımlı bir ağaç oluştur (örneğin eposta “indirim” sözcüğünü içerip içermemesi)
2. Yanlış sınıflandırılan gözlemlere doğru olanlara göre daha büyük ağırlık ver
3. Bu ağırlıkları kullanarak yeni bir ağaç oluştur
4. Ağırlıkları yeniden hesapla
5. Örnekleme dışı performans ölçütü sağlanıncaya kadar Adım 3-4’ü tekrar et

Friedman vd. (2000) hesapsal öğrenme alanında geliştirilen *boosting* yaklaşımının istatistikte temel tahmin ilkelerinden biri olan en yüksek olabilirlik çerçevesinde yeniden yorumlanabileceğini göstermiştir. *Boosting* algoritması regresyon problemlerine de uygulanacak şekilde geliştirilmiştir. Günümüzde yaygın olarak kullanılan *Gradient*



*Boosting Machine* (GBM) algoritmasının (Friedman, 2001) adımları benzer şekilde aşağıdaki gibi yazılabilir:

1. Sadece birkaç kırılımın olduğu basit (sıg) bir ağaç tahmin et
2. Oluşturulan ağacın kestirim kalıntılarını ve ortalama hata karesini (MSE) hesapla
3. Kalıntıları kullanarak yeni bir ağaç tahmin et
4. Örnekleme dışı performans ölçütü sağlanıncaya kadar Adım 2-3'ü tekrarla


Ağaç bazlı yöntemler ile *boosting* yaygın olarak birlikte kullanılır. Bu durumda *boosting* algoritmasının üç ayarlanma parametresi vardır: ağaç sayısı (iterasyon), öğrenme oranı (*shrinkage*), ve ağaçlardaki düğüm sayısı. Tipik olarak pratikte çapraz geçişleme yöntemiyle en başarılı kestirimleri veren ayarlanma parametre kümesi tercih edilir.

### 3.5 Yapay Sinir Ağları

Yapay sinir ağları (*artificial neural networks*) ve derin öğrenme (*deep learning*) algoritmaları özellikle bilgisayar görüşü ve doğal dil işleme alanlarında oldukça başarılı sonuçlar vermektedir. İktisat ve finans alanında ise ağırlıklı olarak geleceğe dönük öngörülerin oluşturulması ve kestirimlerin hesaplanması amacıyla kullanıldığını görüyoruz.

Yapay sinir ağları (YSA) nöronların davranış biçimleri taklit edilerek oluşturulmuş doğrusal olmayan ve oldukça esnek tahmin modelleridir. Tipik olarak bir yapay sinir ağı çok sayıda girdiden, bir ya da daha fazla “gizli” katmandan ve çıktı katmanından oluşur. Gizli katmanlardaki hücre sayısı bir ya da daha fazla olabilir. Yapay sinir ağlarının yapısı genellikle bir şebeke grafiği ile stilize bir şekilde temsil edilebilir.

**Şekil 8: Örnek Bir Yapay Sinir Ağı Şebeke Grafiği**



Şekil 8 tipik bir üç gizli katmanlı ve tek çıktılı bir YSA mimarisini göstermektedir. Her bir gizli katmanda girdilerin ağırlıklandırıldığı bir toplama fonksiyonu hesaplanır ve 0-1 arasında değerler alan bir aktivasyon fonksiyonuna gönderilir. Aslında yapay sinir ağları doğrusal sınıflandırma ve regresyon problemlerinin doğrusal olmayan bir genelleştirilmesi olarak düşünülebilir.

Tek katmanlı ve  $K$  gizli hücreli bir YSA aşağıdaki gibi yazılabilir:

$$f(X_1, X_2, \dots, X_p) = \beta_0 + \sum_{k=1}^K \beta_k g \left( w_{k0} + \sum_{j=1}^p w_{kj} X_j \right) \quad [6]$$

Burada  $K$  gizli hücre sayısını  $g(\cdot)$  ise aktivasyon fonksiyonunu göstermektedir (detaylar için bkz. James vd., 2021, s.404). Aktivasyon fonksiyonu bire ya da sıfıra yakın değerler alabilir. Böylece doğrusal olmayan ilişkiler esnek bir şekilde modellenebilir. Doğrusal regresyon modeli YSA'nın özel bir hali olarak düşünülebilir. Örnek olarak Şekil 9 üç girdili tek gizli katmanlı, tek hücreli ve birim aktivasyonlu,  $g(\cdot) = 1$ , basit bir yapay sinir ağını göstermektedir. Bu örnekte tahmin edilen YSA ve ağırlıklar aşağıda verilmiştir:


$$\hat{y} = -3.01408(-2.46247 - 0.76578x_1 + 1.49965x_2 - 1.29388x_3) + 2.17061 \quad [7]$$

Şekil 9'da gösterilen örnek YSA aslında çıktının girdiler üzerine doğrusal regresyonu olarak düşünülebilir. Bu regresyonun sıradan en küçük kareler (OLS) çözümü aşağıdaki gibidir:

$$\hat{y} \approx 9.593 + 2.308x_1 - 4.52x_2 + 3.90x_3 \quad [8]$$

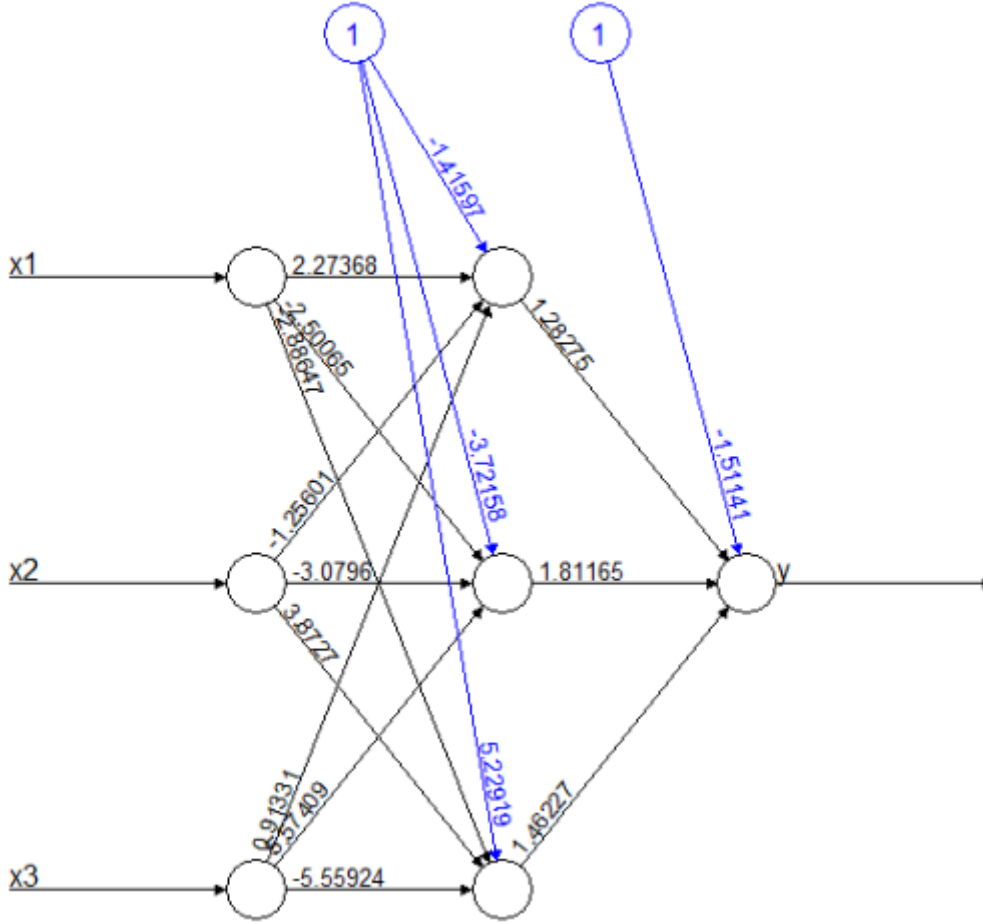
Bu kestirim kuralının (denklem 8) YSA (denklem 7) ile aynı olduğu görülebilir. Bir YSA'nın asıl gücü doğrusal olmayan ilişkileri esnek bir şekilde yakalayabilmesinde gizlidir. YSA'da gizli katmanları ve hücre sayısını arttırdığımızda  $X$  değişkenlerinin çıktı değişkeni  $Y$  üzerindeki doğrusal olmayan etkilerini (etkileşim ve polinom terimlerini) açıkça belirtmeden yakalayabiliriz.

Şekil 9: Tek Gizli Katmanlı ve Tek Hücreli Basit Bir YSA (bkz. Denklem 7)



Şekil 10'da gösterilen tek gizli katmanlı ve üç hücreli YSA modeli girdiler arasındaki yüksek dereceden etkileşimleri yakalayabilir. Tipik olarak bir YSA modelinde ağırlıklar (katsayılar) ana odak noktası değildir. Pratikte YSA modelleri yüzlerce veya binlerce katsayı içerebilir (derin öğrenmede ise bu çok daha fazla olabilir). Burada hedeflenen kestirim ya da sınıflandırma başarısının yükseltilmesidir. Diğer öğrenme algoritmalarında olduğu gibi YSA'da da katman ve hücre sayısı arttıkça ağırlıkların sayısı da artar ve fazla uyum problemi ortaya çıkabilir. YSA modelleri genellikle fazla uyumu kontrol etmek amacıyla öğrenme hızının ayarlanma parametresi olarak eklendiği gradyan iniş (*gradient descent*) algoritması ile eğitilir (detaylar için bkz. Hastie, Tibshirani ve Friedman, 2009).

Şekil 10: Tek Gizli Katmanlı ve Üç Hücreli Bir YSA



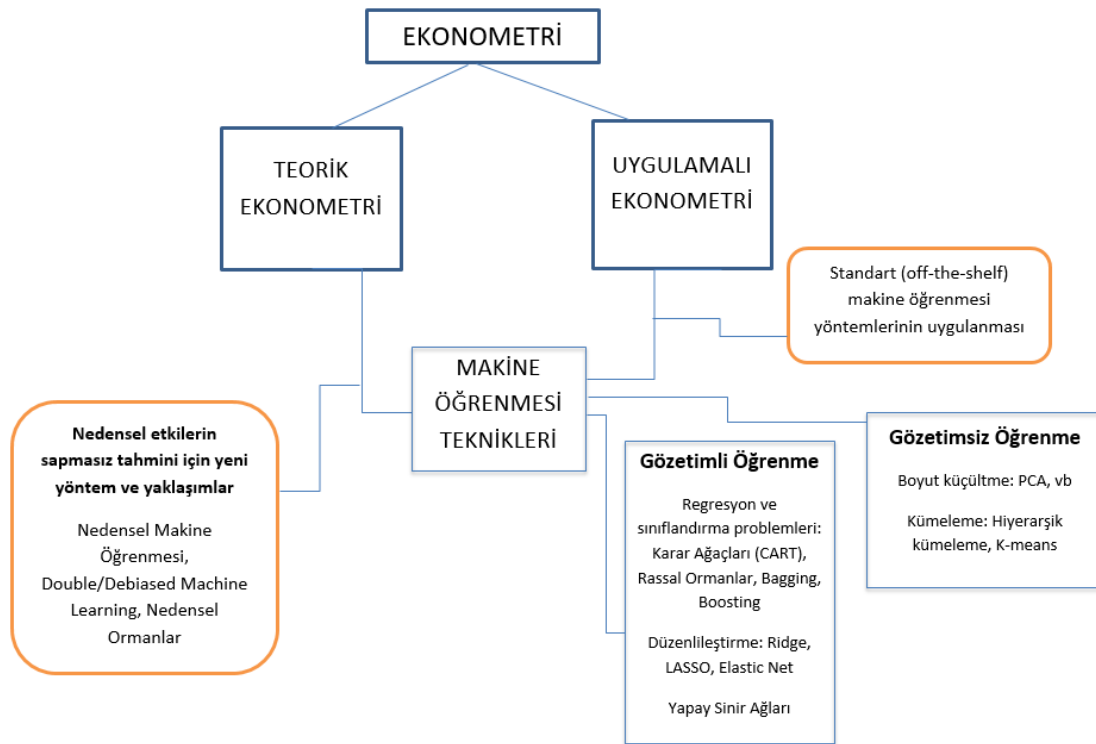
### 3.6 Diğer yöntemler

Bu kısa gözden geçirmede ele alamadığımız çok sayıda öğrenme algoritması mevcuttur. Bunlar arasında destek vektör makineleri (*support vector machines*), MARS yaklaşımı, en yakın komşu modelleri ve grafik bazlı yöntemler sayılabilir (bkz. Hastie, Tibshirani ve Friedman, 2009). Ayrıca, bir hedef değişkenin yer almadığı kümeleme, boyut küçültme ve temel bileşenler analizi gibi gözetimsiz öğrenme problemleri bu gözden geçirmenin dışında tutulmuştur.

#### 4. Makine Öğrenmesi ve Ekonometri Etkileşimi: Öğrenme Yaklaşımını Kullanan Yeni Ekonometrik Yöntemler

Makine öğrenmesinin “kestirim/öngörü” problemlerinde çok başarılı olduğunu ancak nedensel yorumların genellikle pek mümkün olmadığını belirtmiştik. Regresyon ve sınıflandırma ağaçları gibi makine öğrenme algoritmaları yorumlanabilecek bir parametre kümesi bile içermez (parametrik olmayan veya yarı parametrik). Kestirim problemlerinde temel soru “genellikle ne olacağı” iken ekonometrinin uğraştığı nedensel çıkarımda temel soru “sisteme dışarıdan bir müdahale olduğunda ne olacağı” yani “ne kadar” sorusudur. Bazı durumlarda makine öğrenmesi algoritmaları için çeşitli araçlarla yorumlanabilir sonuçlar üretilmeye çalışılsa da bu yorumların nedensel etki olarak yorumlanması genellikle mümkün değildir.<sup>14</sup>

Şekil 11: Ekonometri ve Makine Öğrenmesi Etkileşimi



<sup>14</sup> Örneğin rassal ormanlar (*random forests*) algoritması çok sayıda ağacın bileşkesi olduğu için yorumlanması çok kolay değildir. Ancak çeşitli “değişken önem ölçütleri” (*variable/feature importance plots*) yardımıyla hangi değişkenlerin kestirimlerin oluşturulmasında ağırlık ya da öneme sahip olduğu bulunabilir ve grafikte temsil edilebilir. Yorumu yardımcı olabilecek diğer araçlar arasında *Partial Dependence Plot* ve *Shapley Values* sayılabilir (daha fazla bilgi için bkz. Molnar (2022) ve Rothman (2020)).

Ekonometri ve makine öğrenmesi arasındaki etkileşimi teorik ve uygulamalı ekonometri açısından ele almak mümkündür (bkz. Şekil 11). Gözetimli ve gözetimsiz makine öğrenmesi yöntemleri uygulamalı ekonometrik analizlerde doğrudan kestirimlerin/öngörüler oluşturulması amacıyla kullanılabilir. Son yıllarda standart makine öğrenmesi algoritmalarının iktisat ve sosyal bilimler alanlarında özellikle öngörü problemlerinde yaygın olarak kullanıldığı görülmektedir. Bu algoritmalar ve yaklaşımlar hızla uygulamalı sosyal bilimcilerin alet kutusunun bir parçası haline gelmektedir.

Ekonometri ile makine öğrenmesi etkileşiminin belki de en önemli ayağını teorik alandaki gelişmeler oluşturmaktadır. Karşıolgusal (*counterfactual*) ilişkilerin düşük hatalı tahmininin önemli olduğu nedensel çıkarım problemlerinde makine öğrenmesi algoritmaları yeni çözümler getirebilmektedir. Son yıllarda geliştirilen ekonometrik yöntemlerin makine öğrenmesinin bu özelliğinden daha fazla faydalandığını gözlemliyoruz. Özellikle çok boyutlu problemlerde değişken seçiminde LASSO ve bunun uzantıları yaygın olarak kullanılmaktadır. Makine öğrenmesi yöntemlerinin yüksek derecede ilişkili çok sayıda değişkenin yer aldığı (*collinear*) büyük veri setlerinde kolayca uygulanabilmesi, doğrusal olmayan ilişkilerin açıkça belirtilmeden tahmin edilebilmesine imkan vermesi ve model seçimini sürece kolayca dahil edebilmesi diğer önemli avantajları arasında sayılabilir. Ekonometride nedensel etkilerin tahmininde sapmanın giderilmesi ya da azaltılması amacıyla da makine öğrenmesi algoritmaları, özellikle ağaç bazlı yaklaşımlar geliştirilmiştir. Bunlar arasında nedensel ağaçlar, nedensel ormanlar, ve genelleştirilmiş rassal ormanlar sayılabilir. Bu alt bölümde ekonometri/makine öğrenmesi kesişiminde yer alan seçilmiş bazı yöntemlere değinilecektir.

#### 4.1 Model/Değişken Seçimi: Çift Seçimli LASSO

Veri setlerinin zenginleşmesi ile birlikte hem ekonometrik modellerde kullanabileceğimiz değişkenlerin sayısı hem de gözlem sayısı artmıştır. Bunun sonucunda da değişken seçimi daha fazla önem kazanmaya başlamıştır. Ekonomi teorileri hangi değişkenlerin kontrol değişkeni olarak kullanılacağı konusunda genellikle sessiz ya da yetersiz kalır.

Her ne kadar makine öğrenmesi problemlerinde parametrelerin sapmasız/tutarlı tahmini amaçlanmasa da ekonometrik yaklaşım ile birlikte özellikle başarılı kestirime ihtiyaç duyulan durumlarda kullanılabilir. Bu alanda yapılan son dönemdeki en önemli katkılardan biri LASSO yöntemine dayanmaktadır (Belloni vd., 2014). Standart LASSO ile değişken seçimi yapılırken teorik olarak önemli olan değişkenlerin dışlanma ihtimali de vardır. Sonuçta ulaşılan regresyon modeli teorik olarak yorumlanamayabilir. Belloni, Chernozhukov ve Hansen (2014) böyle durumlarda kullanılmak üzere istatistiksel çıkarsamayı ön planda tutan Çift Seçimli LASSO (*Double Selection LASSO*)

adını verdikleri bir yöntem önermiştir. Yöntemin başlangıç noktası bir iktisat teorisinden hareketle oluşturulan aşağıdaki gibi bir modeldir:

$$y = \alpha D + X\beta + u \quad [9]$$

Burada  $y$  hedef değişken,  $D$  potansiyel olarak içsel olan bir politika ya da tedavi (treatment) değişkeni,  $X$  ise  $p$  boyutlu bir kontrol değişkenleri matrisidir. Kontrol değişkenleri  $D$  ile ilişkili olabilir ve boyutu çok yüksek olabilir. Teori bu değişkenlerin hangilerinin modele dahil edilmesi konusunda yol gösterici olamıyorsa pratikte araştırmacının değişken seçimi yapması zorunlu olur. Bazı durumlarda  $p$  gözlem sayısından fazla olabilir ve bu durumda standart tahmin yöntemleri (OLS, En Yüksek Olabilirlik, GMM) işe yaramaz. LASSO yöntemi ile değişken seçimi yapılmak istendiğinde ise iktisadi olarak önemli olan değişkenin, yani  $D$ 'nin, seçilmemesi gibi bir sonuç ortaya çıkabilir. Standart LASSO kestirim değişkenleri arasında ayırım yapmaz ve en başarılı tahmini verenleri seçer. Ayrıca standart LASSO sapmalı sonuçlar vereceği için istatistiksel çıkarım yapmak zorlaşır.

Burada iktisatçıların aşına olduğu iki örnek verilebilir (Belloni vd., 2014). Birincisi kurum kalitesi ile iktisadi büyüme arasındaki ilişkiyi inceleyen Acemoğlu, Johnson ve Robinson (2001) çalışmasıdır. Bu çalışmada yer alan temel model aşağıdaki gibi yazılabilir:

$$\log(GDP) = \alpha Q + X\beta + u \quad [10]$$

Burada  $Q$  kurum kalitesini temsil etmektedir. Kontrol değişkenleri  $X$  çok sayıda ülke özelliğini ve coğrafi değişkenleri içermektedir.  $Q$ 'nun içsel olması nedeniyle uygun yöntem IV yöntemidir (erken dönem yerleşimcilerin yaşam beklentisi araç değişken olarak kullanılmaktadır). Araç değişkenler yönteminin tüm varsayımları sağlansa bile hangi kontrol değişkenlerinin modele eklenmesi gerektiği ampirik bir sorundur. Kurum kalitesi ile ilişkili olan ve büyümeyi etkileyen değişkenlerin dışlanması sapmalı sonuçlar elde edilmesine yol açabilir.

İkinci örnek ise neoklasik büyüme teorisine dayanan yakınsama modelidir:

$$Y_{i,T} = \delta_0 + \beta Y_{i,0} + \sum_{j=1}^p \delta_j X_{ij} + u_i, \quad i = 1, 2, \dots, n \quad [11]$$

Bu modelde  $Y_{i,T}$  1965-1985 dönemi için büyüme oranını,  $Y_{i,0}$  başlangıçtaki gelir düzeyini ve  $X_{ij}$  başlangıç gelir düzeyi ile ilişkili olabilen ve büyüme oranını etkileyebilecek kontrol değişkenlerini ifade etmektedir. Yakınsama hipotezine göre göreceli daha yoksul ülkeler daha hızlı büyürler ve daha zengin ülkeleri yakalarlar. Koşullu yakınsama hipotezine göre, başlangıç koşulları dikkate alındıktan sonra,

başlangıç gelir düzeyinin katsayısı negatif işaretli ve anlamlı olmalıdır. Bu hipotezin test edildiği Barro-Lee veri setinde ülke sayısı  $n=90$  değişken sayısı  $p=60$ 'tır. Standart LASSO veya benzeri model seçim algoritmaları uygulandığında iktisat teorisine göre modelde yer alması gereken  $Y_{i,0}$  dışlanmaktadır.<sup>15</sup> Tipik olarak LASSO fazla uyumdan kaçınmak adına parametre tahminlerini sıfıra doğru büzdüğü için sapma ortaya çıkar. “Çift Seçimli LASSO” bu problemi çözmek için geliştirilmiştir.

Belloni vd. (2014) tarafından geliştirilen bu yaklaşımda hem tutarlı hem de istatistiksel çıkarsamanın geçerli sonuçlar vermektedir. Yöntem üç adımdan oluşmaktadır:

1. Adım: LASSO veya başka bir düzenleme yöntemi ile  $y$ 'yi en iyi kestiren  $X$  değişkenlerinin seçimi,
2. Adım: LASSO veya başka bir düzenleme yöntemi ile  $D$ 'yi en iyi kestiren  $X$  değişkenlerinin seçimi,
3. Adım: Önceki adımlarda seçilen  $X$  değişkenlerinin birleşim kümesi kullanılarak modelin OLS ile yeniden tahmin edilmesi.

Dikkat edilirse “Çift Seçimli LASSO” yönteminde düzenleme algoritması iki kere uygulanmaktadır. Birincisinde hedef değişken  $y$  iken ikincisinde hedef değişken  $D$  politika ya da tedavi değişkenidir. Burada amaç dışlanmış değişken sapmasını en küçük yapmaktır.

## 4.2 Yanlıktan Arındırılmış Makine Öğrenmesi

Yanlıktan arındırılmış makine öğrenmesi (*double/debiased machine learning, DML*) yaklaşımı çift seçimli LASSO yaklaşımının bir genelleştirmesi olarak düşünülebilir. Chernozhukov vd. (2018) tarafından geliştirilen bu yöntem örneği kısmi doğrusal regresyon modeli verilebilir:

$$Y = D\theta_0 + g_0(X) + U, \quad E[U|X, D] = 0 \quad [12]$$

$$D = m_0(X) + V, \quad E[V|X] = 0 \quad [13]$$

Önceki alt bölümdeki modele benzer şekilde  $D$  politika/tedavi değişkenini ve  $X$  ise  $p$  boyutlu kontrol değişkenlerini temsil etmektedir. Burada amaç nedensel etkiyi ölçen  $\theta_0$  parametresinin sapmasız/tutarlı ve etkin tahmin edilmesidir. İkinci denklem politika değişkeninin kontrol değişkeni ile ilişkisini özetlemektedir. Her iki denklemde de fonksiyon kalıbı belirsizdir ve *nuisance* parametrelerini<sup>16</sup> içermektedir.

<sup>15</sup> Detaylar için bkz. Chernozhukov, Hansen ve Spindler (2016).

<sup>16</sup> İstatistikte araştırmacının doğrudan ilgilenmediği ancak modelde bulunması ve tahmin edilmesi zorunlu olan parametrelere “nuisance” parametreleri adı verilmektedir. Denklemler (12) ve (13)'de yer alan kontrol değişkenlerinin katsayıları bu sınıfa girmektedir. Araştırmacının asıl amacı  $\theta_0$ 'ın tutarlı tahmin



Makine öğrenmesi algoritmalarının doğrudan uygulanması sapmalı sonuçlara yol açmaktadır. Örneğin  $g_0(X)$  fonksiyonunu rassal ormanlar, LASSO veya başka bir makine öğrenmesi algoritması ile tahmin edip daha sonra  $Y - \hat{g}_0(X)$ 'in  $D$  üzerine OLS regresyonu ile  $\theta_0$  parametresini tahmin etmeye çalıştığımızda sapmalı ve tutarsız sonuçlar elde ederiz. Bu sorunu çözmek için DML Frisch-Waugh-Lovell teoremini (bkz. Greene, 2018, ch.3, s.36) uygulayarak aşağıdaki adımları önerir:

1. Adım:  $Y$  ve  $D$  değişkenlerini makine öğrenmesi yöntemleriyle tahmin et ve koşullu beklenen değer tahminlerini oluştur,
2. Adım: Kalıntıları, sırasıyla  $\hat{U} = Y - \hat{g}_0(X)$  ve  $\hat{V} = D - \hat{m}_0(X)$ , hesapla
3. Adım:  $\hat{U}$  kalıntılarının  $\hat{V}$  üzerine regresyonunu kur ve  $\hat{\theta}_0$  parametresini tahmin et.

DML algoritması verilerin eğitim-test kümesi olarak ikiye ayrılmasına dayanır. Makine öğrenmesi algoritmalarının kullanıldığı ilk iki adımda eğitim verileri kullanılırken, üçüncü adımda test verileri kullanılır.

Pratikte DML algoritması uygulanırken değişkenlerin dışsallık varsayımını sağlaması gerektiğinin altı çizilmelidir. Hem  $X$  hem de  $D$ 'nin dışsal olması için genellikle titizlikle tasarlanmış bir deneysel veya yarı-deneysel çerçeve gereklidir. Makine öğrenmesi nedensel tahmin için bir *deus ex machina* değildir.

### 4.3 Nedensel Ağaçlar ve Ormanlar

Nedensel etkilerin tahmininde ağaç bazlı makine öğrenmesi yöntemlerini kullanan çeşitli yaklaşımlar geliştirilmiştir. Bu yöntemlerin temel amacı öğrenme yöntemlerinin doğrudan kullanımı durumunda oluşan sapmanın giderilmesi ve geçerli istatistiksel çıkarımanın yapılabilmesidir.

Athey ve Imbens (2016) CART yaklaşımını adapte ederek heterojen nedensel etkilerin tutarlı ve asimptotik normal tahmini için bir yöntem geliştirmiştir. Bu yöntemde yazarların “dürüst (*honest*) yaklaşım” ismini verdiği bir yöntem uygulanır. Bu yaklaşımda modelin yapısını belirlemekte kullanılan veriler ile ekonometrik tahminde kullanılan veriler farklıdır. Eğitim verileri rassal olarak iki parçaya ayrılır; bir kümede çapraz geçişleme ile ağaç oluşturulurken diğer kümede ise nedensel etkiler tahmin edilir. Athey ve Imbens (2016) bu yöntem ile asimptotik olarak standart istatistiksel çıkarımanın geçerli olduğunu göstermiş ve özellikle saha deneylerinde (RCT) heterojen etkilerin tahmini için faydalı olduğunu belirtmiştir.

Wager ve Athey (2017) nedensel ağaçları (*causal trees*) rassal ormanlar yaklaşımıyla genişletmiştir. Yazarlar bu yönteme nedensel ormanlar (*causal forests*) ismini vermiştir.

---

edilmesidir. Chernozhukov vd. (2018) DML yönteminde bu *nuisance* parametrelerinin (ya da fonksiyonlarının) tahmininde uygun makine öğrenmesi algoritmalarının kullanılmasını önermiştir.

Ayrıca bu yöntemde standart istatistiksel çıkarım yöntemleri uygulanabilmektedir. Athey, Tibshirani ve Wager (2019) rassal ormanlar yöntemini belirlenmiş bir lokal moment koşulları kümesinin sapmasız tahmini için genelleştirmiştir.

#### 4.4 Zaman Serisi ve Panel Veri

Verilerin bağımsız ve türdeş dağıldığı (*i.i.d.*) durumda standart çapraz geçişleme yöntemleri öngörülerin<sup>17</sup> değerlendirilmesinde ve uygun algoritmanın seçiminde kullanılabilir. Zaman serilerinde ise geçmiş değerlere bağımlılık, durağan olmama ve dizisel korelasyonun varlığı nedeniyle örneklem-dışı öngörü değerlendirme yaklaşımı daha yaygın olarak kullanılmaktadır. Bergmeir, Hyndman ve Koo (2018) otoregresif modeller için k-katlı çapraz geçişleme yaklaşımının belirli varsayımlar altında örneklem-dışı öngörü yaklaşımına göre daha başarılı olduğunu göstermiştir.

Zaman serileriyle öngörü problemlerinde makine öğrenmesi yöntemleri yaygın olarak kullanılmaktadır. ARIMA ya da üstel yumuşatma gibi geleneksel zaman serileri yaklaşımlarıyla modern makine öğrenmesi algoritmalarının (rassal ormanlar, derin öğrenme gibi) öngörü başarısı açısından karşılaştırıldığı çok sayıda çalışma vardır.<sup>18</sup> Ekonometrik zaman serileri analizinde kullandığımız geleneksel yöntemleri makine öğrenmesi yaklaşımıyla zenginleştiren ya da yeni yöntemler ve yaklaşımlar geliştiren çalışmalar da yapılmıştır. Bu alanda Phillips ve Shi (2021)'nin *takviye (boosting)* yöntemiyle HP filtresini tekrar ele alması güzel bir örnektir.

Phillips ve Shi (2021) makine öğrenmesinde oldukça başarılı kestirim modelleri oluşturulmasında yaygın olarak kullanılan *boosting* yaklaşımını HP filtresine uygulayarak yeni bir *trend-çevrim* ayrıştırması önermiştir. HP filtresinin kalıntılara yinelemeli bir şekilde uygulanması olarak kabaca betimleyebileceğimiz bu yöntemde trend-çevrim ayrıştırmasının ayarlanma parametresine duyarlı olmadığı gösterilmiştir. HP filtresinde ayarlanma parametresinin yanlış seçimi çevrim bileşeninin trend bileşeniyle kontamine olabileceği bilinen bir problemdir. Phillips ve Shi (2021) *boosting* ile kalıntılara HP filtresinin yinelemeli olarak uygulanmasıyla çevrim bileşeninde olası stokastik trend bulaşısını asimptotik olarak bertaraf edebileceğini göstermiştir. Ayrıca Phillips-Shi *boosted HP* yaklaşımıyla çoklu kırılmaların da tespit edilebileceğini göstermiştir.

*Boosting* yaklaşımının başka ekonometrik problemlerde de sıklıkla kullanılmaya başlandığını görüyoruz. Bu konuda kısa bir özet için Phillips ve Shi (2021) çalışmasının literatür taramasına bakılabilir. Örneğin Bai ve Ng (2009) *boosting* yaklaşımını

<sup>17</sup> Zaman serisi analizinde geleceğe dönük kestirimler “öngörü” olarak isimlendirilmiştir.

<sup>18</sup> Örnek olarak makine öğrenmesi yöntemlerinin enflasyon öngörüsündeki başarısını inceleyen Medeiros vd (2021) çalışmasına bakılabilir. Makine öğrenmesi yöntemlerinin iktisat ve finans alanındaki öngörü ve model seçimi problemlerine uygulanmasına ilişkin literatür taraması için bkz. Masini vd (2022).

faktörlerle genişletilmiş (*factor-augmented*) otoregresyon modellerinde değişkenlerin seçiminde kullanmayı önermiştir.

Öngörü problemlerinde makine öğrenmesi ve büyük veri yöntemlerinin uygulanmasının artık standart hale gelmeye başladığına değinmiştik. Bu alandaki çalışmaların bir kısmı değişkenlerin (özellikle makroekonomik ve finansal değişkenlerin) şimdiki değerlerinin öngörülmesidir (*nowcasting*). Bilindiği gibi GDP, enflasyon, işsizlik gibi değişkenler belli bir gecikmeyle ölçülüp açıklanmaktadır. Bu nedenle ekonominin içinde bulunduğumuz dönemdeki durumuna ilişkin gerçek zamanlı öngörüler son derece önemlidir. Bu alandaki çalışmalarda geleneksel veri türlerinin yanı sıra sosyal medya ve internet ortamlarında gözlemlenen metin verileri, arama motoru verileri, çevre ve iklim verileri, ve uydu verileri gibi geleneksel olmayan veriler de kullanılmaktadır.<sup>19</sup>

Ekonometride nedensel çıkarımda temel çerçeveyi oluşturan potansiyel çıktılar modelinde her bir birey için sadece tek bir doğa durumu gözlemlenebilir; bir birey ya kontrol ya da deney grubunda yer alır. Bir politika, karar, ya da tedavinin uygulandığı birimler için tedavinin uygulanmadığı durumda ne olacağı bilinmez. Benzer şekilde tedavinin uygulanmadığı bireyler için “uygulansaydı ne olurdu” sorusunun cevabı bilinmez. Brodersen vd. (2015) özellikle pazarlama alanındaki müdahale ve politika değişikliklerinin nedensel etkisinin tahmin edilmesi için sentetik kontrol yönteminin Bayesçi bir zaman serisi versiyonunu önermiştir. Sentetik kontrol yaklaşımında amaç gözlenemeyen karşıolgusal durumun gözlemlenen bazı değişkenlerden hareketle tahmin edilmesidir (bkz. Abadie, 2021). Karşıolgusal durumun gözlemlenememesi bir kayıp gözlem problemi olarak formüle edilebilir. Athey vd. (2021) tarafından geliştirilen “matris tamamlama (*matrix completion*) yöntemi” panel veri çerçevesinde gözlemlenen kestirim değişkenlerinden hareketle gözlenemeyen duruma ilişkin çıkarım yapmayı amaçlamaktadır.

#### 4.5 Kestirim Politikası Problemleri

Bazı durumlarda karşıolgusal modellemenin dikkatlice yapıldığı nedensel analizlere gerek kalmadan doğrudan makine öğrenmesi algoritmalarıyla politika oluşturma veya karar verme mümkün olabilir. Kleinberg vd. (2015)’nin “kestirim politikası problemleri” (*prediction policy problems*) adını verdiği bu durumlarda makine öğrenmesi yöntemleri ve yaklaşımları faydalı olabilir. Makine öğrenmesi en iyi kestirimleri/öngörülerini oluşturmak için sapma-varyans dengesini ön plana almaktadır. Bu nedenle oluşturulan tahmin algoritmalarında bir miktar sapma olması kaçınılmazdır.

Kestirim politikası problemlerine örnek olarak sağlık alanında operasyon öncesinde mevcut verilerden hareketle hangi ameliyatların gereksiz olacağını öngörülmesi; ceza

<sup>19</sup> Şimdiki değer öngörüsünde makine öğrenmesinin kullanımına ilişkin bazı örnekler için bkz. Babii vd. (2022), Dauphin vd. (2022), ve Richardson vd. (2021).

hukuku alanında bir tutuklunun serbest bırakıldığında bir suç işleme olasılığının kestirimi; eğitim alanında hangi öğretmenin en yüksek katma değere sahip olacağının tahmin edilmesi; emek piyasalarında işsizlik süresinin öngörülmesi; ve finans alanında potansiyel borçluların kredi değerliliğinin öngörülmesi verilebilir (detaylar için bkz. Kleinberg vd. (2015) ve Kleinberg vd. (2018a)).

Yapay zekanın (yani makine öğrenmesinin) sosyal problemlere uygulanmasının yol açabileceği birçok potansiyel problem bulunmaktadır. Makine (bilgisayar) sadece verilerden öğrendiği için geçmiş tecrübelerin bir özeti olarak düşünebileceğimiz verilerdeki içerilmiş yanlılık (ırkçılık, cinsiyetçilik vb.) algoritma tarafından öğrenilebilir ve yeni veri noktaları için hesaplanan öngörülere aktarılabilir. Dolayısıyla algoritmik karar verme problemlerinde etkinliğin yanı sıra eşitlik ve adaletin nasıl sağlanabileceği önemli bir tartışma konusudur. Eşitliği sağlamak adına yanlı kararlara yol açabilecek özniteliklerin (ırk, cinsiyet, din vb.) modelin eğitilmesi aşamasında dışarıda bırakılması önerilse de Kleinberg vd. (2018b) bu yaklaşımın bilgi kaybı nedeniyle yanlıtıcı olabileceğini göstermiştir. Algoritmik karar verme süreçlerinde, tercih kümesinde eşitliğin de yer aldığı ve amaç fonksiyonu iyi tanımlanmış bir sosyal planlamacının olduğu iktisadi yaklaşım bu alanda önemli katkılar yapma potansiyeline sahiptir (Rambachan vd., 2020).

## 5. Özet ve Sonuç

Bu çalışmada ekonometri ile makine öğrenmesi arasındaki etkileşimin doğasının anlaşılması amaçlanmıştır. Bunun için öncelikle ekonometrinin tarihsel gelişimi kısaca özetlenmiş ve günümüzde ekonometrik analizin nasıl yapıldığı ortaya konmuştur. Kullandıkları yöntemler açısından ortak noktaları olsa da ekonometri ve makine öğrenmesinin temelde farklı sorulara odaklandıkları görülmektedir. Ekonometri “nasıl” ve “ne kadar” sorularına yanıt ararken makine öğrenmesi “ne olacak” sorusuna yanıt aramaktadır. Diğer taraftan, öngörü/kestirim yapmak da ekonometrik analizin ayrılmaz bir parçasıdır. Ancak çoğu durumda iktisadi olarak yorumlanabilir parametre tahmininin ve istatistiksel çıkarsamanın gölgesinde kalır. Ekonometrik analizde sapmasız/tutarlı ve etkin tahmin önceliği kestirim başarısının azalmasıyla sonuçlanabilir. Sapma-varyans ödünümü üzerine inşa edilen gözetimli makine öğrenmesi problemleri ise kestirim başarısını hedeflediği için modelin sapmalı olması mümkündür.

Ekonometride nedensel çıkarımın artık genel kabul görmüş çerçevesinin oluşturan deneysel yaklaşım ve buna eşlik eden yöntemler (araç değişkenler, farkların farkları, eşleştirme, regresyon süresizliği) çok sayıda güçlü varsayıma dayanmaktadır. Leamer’ın belirttiği gibi araştırmacıların tek bir nesnel gerçeklik olduğu inancını terk ederek ulaştıkları sonuçların verilere ve yaptıkları varsayımlara bağlı olduğunu unutmamaları gerekir. Eğer öyle olsaydı iktisatta sorduğumuz her soru için sadece bir ekonometrik analiz yeterli olurdu veya aynı veri setiyle her araştırmacının aynı sonuca

ulaşması beklenirdi. Ekonometrik analiz sürecinde verilen kararların ve kullanılan yöntem ve araçların araştırmacının dünya görüşünden ve değer yargılarından bağımsız olmadığı açıktır. Ekonometrinin daha inandırıcı hale gelmesi aslında iktisatta veri analizinin bu boyutlarının daha şeffaf ve görünür olması anlamına gelmektedir.

Ekonometrideki yeni gelişmeler öğrenme yöntemlerinin nedensel çıkarım problemlerinde başarılı bir şekilde kullanılabileceğini göstermiştir. Nedensel çıkarım için hala güçlü varsayımlar gerekse de hata oranı düşük kestirimlerin gerekli olduğu durumlarda veya değişken sayısının çok fazla olduğu yüksek boyutlu problemlerde makine öğrenmesi yaklaşımları çözümler üretebilmektedir. Makine öğrenmesi ile yapılan görece daha zahmetsiz “korelasyonel” analizin dikkatlice tasarlanmış nedensel çıkarım analizlerinin yerini alması söz konusu değildir. Tam tersine makine öğrenmesinin en güçlü olduğu kestirim/öngörü alanında nedensel çıkarım analizine destek olduğunu görüyoruz. Bu nedenle teorinin artık önemsizleştiğini veya geri planda kaldığını söylemek doğru olmayabilir.

Ekonometri-makine öğrenmesi ilişkisi ile makroekonometrideki VAR analizi-yapısal modelleme ilişkisi birçok açıdan benzerlik göstermektedir. Herhangi bir yapısal kısıtlama olmadan istatistiksel bir VAR modeli bir grup değişken arasındaki dinamik ilişkiyi özetlemekte ve öngörü oluşturmada oldukça başarılıdır. Ancak VAR parametrelerinin iktisadi yorumu (belirli kısıtlamalar olmadan) mümkün değildir. Granger-nedenselliği veya varyans ayrıştırması gibi öngörü başarı ölçütleri ve testleri yorumlanabilse de bunlara teorik anlam veya geleneksel nedensellik anlamı yüklenemez. Makroiktisat alanında halen hakim çerçeveyi oluşturan DSGE modellerinden hareketle nedensel çıkarım yapılması ve karşıolgusal analiz mümkündür. Benzer şekilde bir mikroekonometri probleminde bir gözetimli öğrenme yöntemi, örneğin GBM karar ağacı, kestirim açısından rakipsiz olabilir. Ancak politika değişimi veya sistemsel bir değişiklik olduğu durumda ne olacağını öngöremeyebilir. Bu gibi durumlarda yapısal modelleme ya da ekonometrik nedensel çıkarım yöntemlerinin kullanılması gerekir.

Bu gözden geçirmenin bulgularını aşağıdaki gibi özetleyebiliriz:

- Ekonometrik analizin temel amacı nedensel çıkarımdır. Bunun için hakim ampirik çerçeve potansiyel çıktılar modelidir. Deney bazlı yaklaşım verilerin niteliğine göre karşıolgusal durumun belirli varsayımlar altında tahmin edilebilmesine dayanır.
- Kestirim/öngörü ekonometrinin amaçları arasında önemli bir yer tutsa da öncelik nedensel çıkarımdır. Makine öğrenmesinin önceliği ise fazla uyumdan kaçınarak en başarılı kestirim modelinin kurulmasıdır.

- Nedensel çıkarımda önemli yer tutan kontrol değişkenlerinin seçimi, yüksek boyutlu problemlerde model seçimi, ekonometrik analizde karşıolgusal durumun tahmini gibi problemlerde makine öğrenmesi yaklaşımı çözümler sunabilmektedir. Makine öğrenmesi ekonometri etkileşiminin özellikle bu alanda yoğunlaştığı görülmektedir.
- Makine öğrenmesi ve veri madenciliği yöntemleri verilerden tümevarım (*inductive*) yöntemiyle gizli bilgiyi ortaya çıkarabilir. Bazı durumlarda hızlı ve zahmetsiz korelasyonel analiz karar verme sürecine yardımcı olabilir. Nedensel analizin gerekli olmadığı kestirim politikası problemleri buna örnektir. Ancak bu sosyal bilimlerin her alanında kullanılamayabilir.

Verilerin boyutunun yanı sıra çeşitliliğinin de artması disiplinler arası yaklaşımın daha fazla kullanılması ile sonuçlanmaktadır. Burada makine öğrenmesinin istatistik, bilgisayar bilimi ve matematik alanlarının kesişiminde aslında disiplinler arası bir yaklaşım sunmasının ötesinde bir durumdan bahsediyoruz. İktisatta ampirizmin yükselişine sosyal bilimciler arasında iş birliğinin artması da eşlik etmektedir. Yakın gelecekte bu iş birliğinin daha fazla artarak devam edeceğini ve iktisatçıların öncüsü olduğu bir “birleşmiş nicel sosyal bilimler” alanının kurulacağını öngörebiliriz.

## Kaynakça

- Abadie, A. (2021). Using synthetic controls: feasibility, data requirements, and methodological aspects. *Journal of Economic Literature*, 59(2), 391-425.
- Acemoglu, D., Johnson, S. ve Robinson, J. A. (2001). The colonial origins of comparative development: an empirical investigation. *American Economic Review*, 91(5): 1369-1401.
- Alpaydın, E. (2018). *Yapay Öğrenme*, 4. Baskı (Ethem Alpaydın, *Introduction to Machine Learning*, 2. baskıdan çeviri), İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Angrist, J. D. ve Pischke, J.-S. (2009). *Mostly harmless econometrics: An Empiricist's Companion*, Princeton University Press.
- Angrist, J. D. ve Pischke, J.-S. (2010). The credibility revolution in empirical economics: How better research design is taking the con out of econometrics. *Journal of Economic Perspectives*, 24(2), 3-30.
- Angrist, J., Azoulay, P., Ellison, G., Hill, R. ve Feng Lu, S. (2017). Economic research evolves: fields and styles. *American Economic Review*, 107(5): 293-97.

- Arlot, S. ve Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4, 40–79.
- Assenmacher, K. (2017). Bridging the gap between structural VAR and DSGE models. ed. Gürkaynak R. ve Tille, C. (Der.). *DSGE Models in the Conduct of Policy: Use as Intended*, içinde (s 23-30). A VoxEU.org Book. London: CEPR Press.
- Athey, S. (2018). The impact of machine learning on economics. Agrawal A., Gans, J. ve Goldfarb, A. (Der.), *The Economics of Artificial Intelligence: An Agenda*. içinde (s. 507-547). University of Chicago Press. URL: <http://www.nber.org/chapters/c14009>
- Athey, S. ve Imbens, G. (2016). Recursive partitioning for heterogeneous causal effects. *Proceedings of the National Academy of Sciences*, 113(27), 7353-7360, <https://www.pnas.org/doi/10.1073/pnas.1510489113>
- Athey, S. ve Imbens, G. W. (2017). The state of applied econometrics: causality and policy evaluation. *Journal of Economic Perspectives*, 31(2), 3-32.
- Athey, S. ve Imbens, G. W. (2019). Machine learning methods that economists should know about. *Annual Review of Economics*, 11(1), 685-725.
- Athey, S., Tibshirani, J. ve Wager, S. (2019). Generalized random forests. *The Annals of Statistics*, 47(2), 1148-1178.
- Athey, S., Bayati, M., Doudchenko, N., Imbens G. ve Khosravi K. (2021). Matrix completion methods for causal panel data models. *Journal of the American Statistical Association*, 116, 1716-1730 <https://doi.org/10.1080/01621459.2021.1891924>
- Babii, A., Ghysels, E. ve Striaukas, J. (2022). Machine learning time series regressions with an application to nowcasting. *Journal of Business & Economic Statistics*, 40(3), 1094-1106.
- Bai, J. ve Ng, S. (2009). Boosting diffusion indices. *Journal of Applied Econometrics*, 24(4), 607-629.
- Belloni, A., Chernozhukov, V. ve Hansen, C. (2014). Inference on treatment effects after selection among high-dimensional controls. *The Review of Economic Studies*, 81(2 (287)), 608-650.
- Bennett J. ve Lanning S. (2007). The Netflix prize. *Proceedings of KDD Cup and Workshop 2007*. içinde (s. 3-6) New York: ACM.

- Bergmeir, C., Hyndman, R. J. ve Koo, B. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics & Data Analysis*, 120, 70-83.
- Blanchard, O. (2017). Do DSGE models have a future? *DSGE Models in the Conduct of Policy: Use as Intended*. içinde (s 93-100). A VoxEU.org Book. London: CEPR Press.
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24, 123-140.
- Breiman, L. (2001a). Random Forests. *Machine Learning*, 45, 5-32.
- Breiman, L. (2001b). Statistical modeling: the two cultures. *Statistical Science*, 16(3), 199-215.
- Breiman, L., Friedman, J. H., Olshen, R. A. ve Stone, C. J. (1984). *Classification and Regression Trees*. Wadsworth: CRC Press reprint.
- Brodersen, K. H., Gallusser, F., Koehler, J., Remy, N. ve Scott, S. L. (2015). Inferring causal impact using Bayesian structural time-series models. *Annals of Applied Statistics*, 9 (1), 247-274.
- Callaway, B. ve Sant'Anna, P. H. C. (2021). Difference-in-differences with multiple time periods. *Journal of Econometrics*, 225, 200-230.
- Card, D., ve Krueger, A. (1994). Minimum wages and employment: a case study of the fast-food industry in New Jersey and Pennsylvania. *American Economic Review*, 84(4), 772-793.
- Chernozhukov, V., Hansen, C. ve Spindler, M. (2016). hdm: High-Dimensional Metrics. *The R Journal*, 8(2), 185-199. <https://doi.org/10.32614/RJ-2016-040>
- Chernozhukov, V., Chetverikov, D., Demirer, M., Duflo, E., Hansen, C., Newey, W. ve Robins, J. (2018). Double/debiased machine learning for treatment and structural parameters. *The Econometrics Journal*, 21(1), C1-C68.
- Dauphin, j. F., Dybczak, K., Maneely, M., Sanjani, M. T., Suphaphiphat, N., Wang, Y. ve Zhang, H. (2022) Nowcasting GDP: A Scalable Approach Using DFM, Machine Learning and Novel Data, Applied to European Economies. International Monetary Fund Working Paper Series, WP/22/52.
- Doğruel, A. S. ve Doğruel, F. (2015). İktisatta yayın yapma telaşı. *Ekonomi-tek*, 4(3), 69-88.
- Einav, L. ve Levin, J. (2014). The data revolution and economic analysis. *Innovation Policy and the Economy*, 14, 1-24.



- Epstein, R. J. (1987). *A History of Econometrics*. Amsterdam: Elsevier North Holland.
- Friedman, J. H., Hastie, T. ve Tibshirani, R. (2000). Additive logistic regression: a statistical view of boosting. *Annals of Statistics*, 28(2), 337-407.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232.
- Frisch, R. (1970). From Utopian Theory to Practical Applications: The Case of Econometrics. Lecture to the memory of Alfred Nobel, June 17, 1970, <https://www.nobelprize.org/uploads/2018/06/frisch-lecture-1.pdf>
- Greene, W., (2018), *Econometric Analysis*, 8th ed., Pearson, New York, NY.
- Gürkaynak, R. S. ve Tille, C. (2017). *DSGE Models in the Conduct of Policy: Use as Intended*. A EoxEU.org Book, London: CEPR Press. <http://voxeu.org/content/dsge-models-conduct-policy-use-intended>.
- Haavelmo, T. (1944). The probability approach in econometrics. *Econometrica*, 12, Supplement.
- Hamermesh, D. S. (2013). Six decades of top economics publishing: who and how? *Journal of Economic Literature*, 51(1), 162-72.
- Hastie, T., Tibshirani, R. ve Friedman, J. (2009), *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd ed., New York NY: Springer.
- Hendry, D. F. (1980). Econometrics-alchemy or science? *Economica*, 47(188), 387-406.
- Huntington-Klein, N., Arenas, A., Beam, E., Bertoni, M., Bloem, J. R., Burli, P., Chen, N., Grieco, P., Ekpe, G., Pugatch, T., Saavedra, M. ve Stopnitzky, Y. (2021). The influence of hidden researcher decisions in applied microeconomics. *Economic Inquiry*, 59(3), 944-960.
- James, G., Witten, D., Hastie, T. ve Tibshirani, R. (2021). *An Introduction to Statistical Learning*, 2nd ed., New York, NY: Springer.
- Keynes, J. M. (1939). Professor Tinbergen's method. *The Economic Journal*, 49 (195), 558-577.
- Kleinberg, J., Ludwig, J., Mullainathan, S. ve Obermeyer, Z. (2015). Prediction policy problems. *American Economic Review, Papers and Proceedings*, 105(5): 491-495. <http://dx.doi.org/10.1257/aer.p20151023>

- Kleinberg, J., Lakkaraju, H., Leskovec, J., Ludwig, J. ve Mullainathan, S. (2018a). Human decisions and machine predictions. *Quarterly Journal of Economics*, 133(1), 237-293.
- Kleinberg, J., Ludwig, J., Mullainathan, S. ve Rambachan, A. (2018b). Algorithmic fairness. *American Economic Review, Papers and Proceedings*, 108: 22-27.
- Leamer, E. E. (1983). Let's take the con out of econometrics. *American Economic Review*, 73(1), 31-43.
- Lucas, R. E. (1976). Econometric policy evaluation: a critique. *Carnegie Rochester Conference Series on Public Policy*, 1, 19-46
- Mann, H. B. ve Wald, A. (1944). On the statistical treatment of linear stochastic difference equations. *Econometrica*, 11 (3/4), 173-220.
- Masini, R. P., Medeiros, M. C. ve Mendes, E. F. (2022). Machine learning advances for time series forecasting. *Journal of Economic Surveys*, 1-36.  
<https://doi.org/10.1111/joes.12429>
- Medeiros, M. C., Vasconcelos, G. Veiga, A. ve Zilberman, E. (2021). Forecasting inflation in a data-rich environment: the benefits of machine learning methods. *Journal of Business & Economic Statistics*, 39(1): 1-45. DOI: 10.1080/07350015.2019.1637745
- Molnar, C. (2022). *Interpretable Machine Learning: A Guide For Making Black Box Models Explainable*, ISBN-13: 979-8411463330,  
<https://christophm.github.io/interpretable-ml-book/>
- Morgan, M. (1990). *The History of Econometric Ideas*, (Historical Perspectives on Modern Economics). Cambridge: Cambridge University Press.
- Mullainathan, S. ve Spiess, J. (2017). Machine learning: an applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87-106.
- Phillips, P. C. B. ve Shi, Z. (2021). Boosting: why you can use the hp filter. *International Economic Review*, 62(2), 521-570.
- Qin, D. (1993). *The Formation of Econometrics: A Historical Perspective*. Oxford: Oxford University Press.
- Qin, D. (2013). *A History of Econometrics: The Reformation from the 1970s*. Oxford: Oxford University Press.

- Rambachan, A., Kleinberg, J., Ludwig, J. ve Mullainathan, S. (2020). An economic perspective on algorithmic fairness. *American Economic Review, Papers and Proceedings*, 110, 91-95.
- Richardson, A., van Florenstein Mulder, T. ve Vehbi, T. (2021). Nowcasting GDP using machine-learning algorithms: A real-time assessment. *International Journal of Forecasting*, 37(2), 941-948.
- Rothman, D. (2022). *Hands-On Explainable AI (XAI) with Python*. Packt Publishing.
- Schapiro, R. E, ve Freund, Y. (2012). *Boosting: Foundations and Algorithms*. Cambridge, MA: MIT Press
- Stone, M. (1974). Cross-validators choice and assessment of statistical predictions. *Journal of the Royal Statistical Society. Series B (Methodological)*, 36(2), 111-147.
- Tinbergen, J. (1939). *Statistical Testing of Business Cycle Theories: vol. I, A Method and Its Application to Investment Activity*. Geneva: The League of Nations.
- Uygun, E. (2006). Ekonometrinin gelişimi: iktisadın bilim olma çabası. Türkiye Ekonomi Kurumu Tartışma Metni, 2006/8.
- Varian, H. R. (2014). Big data: new tricks for econometrics. *Journal of Economic Perspectives*, 28 (2), 3-28.
- Wager, S. ve Athey, S. (2018). Estimation and inference of heterogeneous treatment effects using random forests. *Journal of the American Statistical Association*, 113(523), 1228-1242.
- Zou, H. and Hastie, T. (2005). Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 67, 301-320.

---

**BEYANLAR:**

**Araştırma ve Yayın Etiği Beyanı:** Bu çalışma bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır.

**Yazarların Makaleye Katkı Oranları:** Tek yazar (%100).

**Çıkar Beyanı:** Yazarlar açısından ya da üçüncü taraflar açısından çalışmadan kaynaklı çıkar çatışması bulunmamaktadır.

**Araştırma Desteği:** Yok

**Etik Kurul Onayı Bilgileri:** Makalede açıklanan çalışmada insan denekleri kullanılmadığı için etik kurul onayı alınmamıştır.

---

