



Ekonomi-tek

Volume 11
Cilt 11

Number 2
Sayı 2

May 2022
Mayıs 2022

Türkiye Tarım İstatistikleri: Bütünleşik Bir Veri Tabanı Önerisi
Haluk Kasnakoğlu

Ekonometri ve Makine Öğrenmesi Etkileşimi Üzerine
Hüseyin Taştan

Turkish Economic Association Foundation

Türkiye Ekonomi Kurumu Vakfı

ISSN 2146-6173
e-ISSN 2791-7991



Ekonomi-tek

A Journal of Turkish Economic Association Foundation / Türkiye Ekonomi Kurumu Vakfı Dergisidir

Editor / Editör

A. Suut Doğruel

(Marmara University, Emeritus / Marmara Üniversitesi, Emekli)

Associate Editor / Yardımcı Editör

Oytun Meçik

(Eskişehir Osmangazi University / Eskişehir Osmangazi Üniversitesi)

Board of Editors / Yayın Kurulu

Murat Donduran

(Yıldız Technical University / Yıldız Teknik Üniversitesi)

H. Alper Güzel

(Ondokuz Mayıs University / Ondokuz Mayıs Üniversitesi)

Hasan Kazdağlı

(Turkish Economic Association / Türkiye Ekonomi Kurumu)

Tolga Omay

(Atılım University / Atılım Üniversitesi)

S. Fatih Özatay

(TOBB University of Economics and Technology / TOBB Ekonomi ve Teknoloji Üniversitesi)

Ayşen Sivrikaya

(Hacettepe University / Hacettepe Üniversitesi)

Advisory Board / Danışma Kurulu

Daron Acemoğlu

(Massachusetts Institute of Technology)

Ufuk Akçığıt

(University of Chicago)

Yılmaz Akyüz

(The South Centre)

Manuel Arellano

(CEMFI)

Kaushik Basu

(Cornell University)

Guillermo Calvo

(Columbia University)

Dani Rodrik

(Harvard University)

Stephen Turnovsky

(University of Washington)

Language Editors / Dil Editörleri:

Turkish / Türkçe: Sırrı Emrah Üçer (Yıldız Technical University / Yıldız Teknik Üniversitesi)

English / İngilizce: İbrahim Engin Kılıç (Yıldız Technical University / Yıldız Teknik Üniversitesi)

© Türkiye Ekonomi Kurumu Vakfı
© Turkish Economic Association Foundation
Ankara, 2022

ISSN 2146-6173
e-ISSN 2791-7991

<https://ekonomitek.com/>

Ekonomi-tek is a peer-review journal published tri annually (January, May and September) by Turkish Economic Association Foundation. The journal accepts original papers on economics in English or Turkish. Ekonomi-tek is freely available online.

Ekonomi-tek, Türkiye Ekonomi Kurumu Vakfı tarafından yılda üç kez (Ocak, Mayıs ve Eylül) yayımlanan hakemli bir dergidir. Dergi ekonomi ile ilgili İngilizce veya Türkçe orijinal makaleleri kabul eder. Dergiye çevrimiçi olarak ücretsiz erişilebilir.

Türkiye Ekonomi Kurumu Vakfı adına sahibi: Hasan Kazdağlı
Türkiye Ekonomi Kurumu, Hoşdere Cad. No: 24/4, 06550
Çankaya/ANKARA
Basım Tarihi: Eylül 2022



Contents / İindekiler

Türkiye Tarım İstatistikleri: Bütünleşik Bir Veri Tabanı Önerisi <i>Turkish Agricultural Statistics: An Integrated Database Proposal</i>	Haluk Kasnakođlu	63
Ekonometri ve Makine Öğrenmesi Etkileşimi Üzerine <i>On the Interaction between Econometrics and Machine Learning</i>	Hüseyin Taştan	107

Türkiye Tarım İstatistikleri: Bütünleşik Bir Veri Tabanı Önerisi

Haluk Kasnakoğlu*

Öz

Çalışmanın ilk bölümlerinde, Türkiye’de tarım istatistiklerinin yapısı, durumu ve sunucuları üzerine bir değerlendirme yapılmış, kullanıcı akademisyenler gözünden 6 kalite göstergesi ve 8 tarım istatistiği alt grubu için kalite değerlendirmesi yapılmıştır.

İzleyen bölümlerde, **TAR-İST** adı verilen bütünleşik bir veri tabanı sistemi önerilmektedir. Bu sistem, üretim, girdiler, fiyatlar, dış ticaret gibi ayrıntılı istatistiklerin yer aldığı, kendi içlerinde oldukça bütünleşik ancak birbiri ile bağlantısı zayıf halkalardan oluşan kaynak veri tabanları ve ürün arzı, girdi kullanımı, katma değer, değer zinciri, girdi-çıktı tablosu gibi bütünleştirici kavramsal yapılarla bütünleşmiş bir **çekirdek** veri tabanından oluşmaktadır.

Son bölümlerde, TAR-İST kullanıcı arayüzü ve yönetimine ilişkin öneriler sunulmaktadır. TAR-İST’in Tarım ve Orman Bakanlığının ev sahipliğinde, verilerin büyük çoğunluğu veri tabanlarında bulunduran TÜİK’le işbirliği içinde geliştirilmesi ve kullanıma sunulması en doğalıdır. Bu kurumların, konuya sahip çıkmaması durumunda, tarımla ilgili STK’lardan, kâr amacı gütmeyen üniversite, vakıf, merkezlere ve hatta yaratılacak katma değeri ticari amaçla kullanacak özel teşebbüslere varan seçenekler söz konusu olabilecektir.

JEL Kodları: C80, L15, Q12, Q18, Y10

Anahtar Kelimeler: Tarım istatistikleri, bütünleşik veri tabanı, kalite göstergeleri.

* Orta Doğu Teknik Üniversitesi, Ankara, emekli öğretim üyesi, <https://orcid.org/0000-0002-9277-3160> (haluk.kasnakoglu@gmail.com). Türkiye’de tarım istatistiklerinin kalite değerlendirmesini yaparken görüşlerini benimle paylaşan akademisyen meslektaşlarıma ve bu çalışmayı ayrıntılı olarak okuyan, hem kavramsal hem biçimsel önerilerinden yararlandığım dergi hakemlerine çok teşekkür ederim.

Turkish Agricultural Statistics: An Integrated Database Proposal

Abstract

The first parts of the study, consist of a review of the state, structure and providers of agricultural statistics in Turkey, followed by quality evaluation of a group of academic users employing 6 quality indicators and 8 groups of agricultural statistics.

In the following sections, proposal for an integrated database system named **TAR-İST** is introduced. This system consists of a **source** databases with detailed statistics such as production, inputs, prices, foreign trade which are semi-integrated within but not between and a **core** database which is integrated via integrating structures such as commodity balances, value added, input accounts, input-output tables, value chains.

In the final sections, proposals are introduced regarding TAR-İST user interfaces and management. TAR-İST is proposed to be developed and disseminated by Ministry of Agriculture and Forestry in collaboration with TURKSTAT. In case of no interest, NGO's, universities, foundations, research centers and even private firms are viable options.

JEL Codes: C80, L15, Q12, Q18, Y10

Keywords: Agricultural statistics, integrated database, quality indicators.

1. 1. Giriş

Tarım, milli gelir ve nüfus içinde düşen paylarına rağmen önemini koruyor. Özellikle günümüzdeki gibi, salgın, savaş ve kriz gibi olağanüstü durumlarda, gelir dağılımının bozulması ve yoksulluğun artmasıyla, daha da öne çıkıyor. Tarımın öne çıkması ile, genelde ikinci plana itilen, tarım istatistiklerine de talep artıyor. Ancak, var olan çok sayıda ve detaylı tarım istatistiği taleplere cevap veremiyor. Başka bir deyişle, çok sayıda veri ve bilgi var ancak bunlar ya istenilen bilgiler değil, ya da bir şeyleri eksik olduğundan yararlı olamıyor.

Bu çalışmanın amacı, Türkiye tarımına ilişkin düzenli olarak derlenen ve yayınlanan istatistiklerin bir değerlendirmesini yapmak ve daha yararlı olabilmeleri için öneriler sunmaktır. Bu bağlamda “kaynak” ve “çekirdek” olmak üzere iki veri tabanından oluşan bütünlük bir veri tabanı sistemi (TAR-İST) önerilmektedir. Bu veri tabanı sistemi ile Türkiye tarımına ilişkin verilere tek bir arayüz aracılığıyla ulaşabilme, onları birlikte ve daha etkin kullanabilme hedeflenmiştir.

Çalışmanın izleyen ikinci bölümünde, Türkiye tarım istatistikleri sunan ulusal ve uluslararası sunucular verilmekte ve hangi verilere, nerede, hangi ortamlarda ulaşılacağı özetlenmektedir. Üçüncü bölümde istatistiklerin kalitesini değerlendirmeye yönelik uluslararası kuruluşlar tarafından önerilen göstergeler karşılaştırılmakta ve Türkiye’deki uygulamalar özetlenmektedir. Dördüncü bölümde, yazar ve konu uzmanı 11 akademisyenin Türkiye’de yayınlanan tarım istatistiklerine ilişkin değerlendirmelerine yer verilmektedir. Beşinci bölümde, tarım istatistiklerinin, bu çalışmada iyileştirme önerilerine neden olan, sorunlarına değinilmektedir. Altıncı bölümde, çalışmada geliştirilecek bütünlük veri tabanının kavramsal yapısı anlatılmakta ve farklı bütünlük modelleri özetlenmektedir. Yedinci bölümde kaynak ve çekirdek veri tabanlarından oluşan bütünlük bir tarım istatistikleri veri tabanı sistemi olan TAR-İST kapsamlı olarak anlatılmaktadır. Bu bölümde TAR-İST’in temel yapısı ve bütünlüğü verilmeye çalışıldığından ayrıntılar ve akla gelebilecek soruların yanıtları sekizinci bölüme bırakılmıştır. Dokuzuncu bölümde, TAR-İST’in kullanımını kolaylaştırmak için önerilen kullanıcı arayüzleri, ana hatları ile tartışılmaktadır. Onuncu bölümde, TAR-İST’in yönetimi ele alınmakta, geliştirilmesi, güncellenmesi ve sunulmasından sorumlu olacak kurumsal yapı tartışılmakta ve öneriler getirilmektedir. On birinci ve son bölümde çalışmanın sonuçları ve önerileri özetlenmektedir.

2. Tarım İstatistikleri Sunucuları

Türkiye tarımına ilişkin düzenli istatistiklerin büyük bir çoğunluğunu Türkiye İstatistik Kurumu (TÜİK) web sitesinde yayınlıyor. TÜİK, tarım istatistiklerini, diğer istatistiklerde olduğu gibi Haber Bülteni, İstatistiksel Tablolar, Veri Tabanları, Raporlar başlıkları altında yayınlıyor. TÜİK’den sonra ikinci önemli veri kaynağı Tarım ve

Orman Bakanlıđı (TOB). Bakanlık web sitesinde istatistikler daha ok istatistik tablolar ve raporlar iinde sunulmakta. Yayınlanan istatistiklerin bir blm zgn, bir kısmı ise TİK verilerinin tekrarlanması eklinindedir.¹ Tarım sektrn tarlanın tesinde, rnn pazarlanması ve iřlenmesini de kapsayacak biimde dřndğmzde, Merkez Bankası (TCMB) web sitesindeki Tarım, Ormancılık ve Balıkılık Sektr Bilanolarını, Trkiye Odalar ve Borsalar Birliđi (TOBB) Ticaret Borsaları Bilgi Sistemindeki tarım rnlerinin gncel borsa fiyatlarını da listeye eklemek gerekir.

Tablo 1 'de, tarım sektr iin, hangi kurumda hangi istatistiklere, hangi formatlarda ulařılabileceđi zetlenmeye alıřılmıřtır.

Tablo 1: Trkiye'de Bařlıca Tarım İstatistik Sunucuları

Tarım İstatistik Sunucuları	Konular	Biim	Web Adresi
TİK	<i>retim, Girdi, Verim, Fiyatlar, Dıř Ticaret, Nfus, Gelir, İřgc, Tarım-Sanayi, evre, GSYH</i>	Blten, Tablo, Veri Tabanı	https://www.tuik.gov.tr
TOB	<i>retim, Destekler, İla, Gbre, Toprak, Su, řeker, ay</i>	Tablo, Rapor	https://www.tarimorman.gov.tr/
TCMB	<i>Sektr Bilanoları</i>	Tablo	https://www.tcmb.gov.tr
TOBB-TBBS	<i>Gnlk Borsa Fiyatları</i>	Veri Tabanı	https://www.tobb.org.tr/iframes/Sayfalar/borsa.php

Tarım sektrne iliřkin verilere eriřilebilecek ve diđer lkelerle karřılařtırılabilecek bir diđer kaynak da uluslararası kuruluşların veri tabanları. Bu kuruluşlar arasında Birleřmiř Milletler Gıda ve Tarım rgt (FAO), Dnya Bankası (WB), Birleřmiř Milletler İstatistik Direktrlđ (UNSD), Ekonomik İřbirliđi ve Kalkınma Teřkilatı (OECD), Avrupa İstatistik Ofisi (EUROSTAT), Dnya Ticaret rgt (WTO), Uluslararası Ticaret Merkezi (ITC) sayılabilir.

¹ TİK verilerinin bir blm de TOB tarafından derlenmekte ancak TİK tarafından dzenlenip yayınlanmaktadır.

Tablo 2: Türkiye Tarım İstatistikleri Sunan Uluslararası Veri Tabanları

Kurum	Veri Tabanı Adı	Web Adresi	Konular
FAO	FAOSTAT	www.fao.org/faostat	<i>Üretim, Tüketim, Dış Ticaret, Üretici Fiyatları, Kaynaklar, Gıda Güvenliği, Ürün Piyasaları, Toprak Mülkiyeti, Toprak Dağılımı, İklim, Ürün Denge Tabloları</i>
UNSD	COMTRADE UNdata	https://comtrade.un.org/ https://unstats.un.org/home/	<i>Dış Ticaret, Nüfus, Tarım Sanayi, Ulusal Gelir Hesapları, Enerji</i>
OECD	OECD.Stat	https://stats.oecd.org	<i>Çevre, Tarımsal Destekler, Göç, Yatırım, Resmi Kalkınma Yardımları</i>
EU	EUROSTAT/ FADN	https://ec.europa.eu/eurostat https://agridata.ec.europa.eu/extensions/FarmEconomyFocus/FarmEconomyFocus.html	<i>Ekonomik Hesaplar, Tarımsal İşletme Yapıları, Gıda Zincirleri, Tarım Fiyatları</i>
WB	DATABANK/ WDI	https://data.worldbank.org	<i>Tarım Göstergeleri, Satın Alma Gücü Paritesi, Altyapı, Yoksulluk, Kalkınma, Yardım</i>
IMF	IMFDATA	https://www.imf.org/en/Data	<i>GSMH, TÜFE, Finansman</i>
ILO	ILOSTAT	https://ilostat.ilo.org	<i>İş Gücü, Aktif Nüfus, Ücretler, İşsizlik, TÜFE</i>
WTO	WTODATA	https://data.wto.org	<i>Tarifeler, Tarife-Dışı Önlemler, Dış Ticaret Politika Önlemleri, Dış Ticaret Miktar ve Değerleri, İkili Dış Ticaret</i>
ITC	TRADE MAP	https://www.trademap.org	<i>Dış Ticaret Göstergeleri, Performans, Tutarlılık, Uzaklık, Tarife, Yoğunluk</i>

Kaynak: Kasnakoglu (2009 ve 2021).

Tablo 2’de bu kuruluşlarda Türkiye tarımı ile ilgili hangi verilere ulaşılabileceği özetlenmeğe çalışılmıştır. Uluslararası veri tabanları genelde Türkiye’den gönderilen verilerle oluşturulurken zaman zaman ulusal kaynaklarda sunulanlardan farklılıklar göstermekte, çoğunlukla uluslararası kıyaslamalara da fırsat verecek farklı göstergeler içermekte ve veri tabanı arayüzleri ile kullanım kolaylığı sağlamaktadırlar.²

Görüldüğü gibi, gerek ulusal kaynaklarda, gerekse uluslararası kaynaklarda, Türkiye tarım sektörü için, geniş bir konu yelpazesine yayılan, oldukça kapsamlı veriler bulunmaktadır. Çalışmamızın bundan sonraki bölümlerinde var olan tarım istatistiklerinin ne denli ihtiyaca cevap verdiklerini ve kullanıcılarını tatmin ettiği sorularına cevap arayacağız. Daha sonra da sorunları belirleyip, iyileştirme önerileri getireceğiz.

3. Kalite Göstergeleri ve Tarım İstatistikleri

Yayınlanan istatistiklerin kalitesini değerlendirmek için uluslararası kuruluşlar tarafından geliştirilmiş ilkeler ve göstergeler bulunmaktadır. Bunların en yaygın olarak kullanılanları BM, IMF, OECD, AB ve FAO tarafından geliştirilen ve üyelerine önerilen kalite standartlarıdır.

BM İstatistik Ofisi tarafından geliştirilen Resmi İstatistikler Ulusal Kalite Güvence Çerçevesi (UN-NQAF), ülkelerin ulusal kalite çerçevelerini oluşturmak ve uygulamak üzere genel bir yapı ve şablon sağlamaktadır (UNSD, 2015, 2019, 2022a).

Eurostat tarafından geliştirilen Avrupa İstatistik Sistemi Kalite Güvence Çerçevesi (ESS-QAF), AB üye ülkeleri ulusal istatistik ofisleri ve Eurostat tarafından Avrupa İstatistik Uygulama Esaslarını uygulanmak üzere faaliyet, yöntem ve araç önermektedir (EUROSTAT, 2022).

IMF İstatistik Ofisi tarafından geliştirilen Veri Kalite Değerlendirme Çerçevesi (IMF-SQAF ve IMF-GSQAF), kendisine veri sağlayan ulusal istatistik ofisleri ve devlet kurumlarının veri derleme ve yayınlamada kullanmaları içindir (IMF, 2003).

OECD İstatistik Ofisi tarafından geliştirilen İstatistik Faaliyetler için Kalite Çerçevesi ve Yönergesi (OECD-QFGSA) daha çok kurum bünyesinde kalite yönetimini hedeflemektedir (OECD, 2011).

FAO, kalite göstergelerini sayısallaştırmayı ve yayınladığı istatistiklerde kalite damgasını kullanmayı ilk gündeme getiren uluslararası kurumlardan birisiydi

² Bunların dışında araştırma enstitüleri, araştırma projeleri, meslek kuruluşları, akademik çalışmalar ve tezler de çok yararlı ve kapsamlı tarım verileri ve göstergeleri sunabilmektedir. Ancak bunlar düzenli ve sürekli olmadıklarından bu çalışma kapsamına dahil edilmemişlerdir.

(Kasnakoglu ve Mayo, 2004). Ancak daha sonra kalite göstergelerini sayısallaştırmadan vazgeçilerek diğerleri gibi, geliştirilen İstatistik Kalite Güvence Çerçevesi (FAO-SQAF) ile bir taraftan FAO'nun yayınladığı tarım istatistikleri için bir kalite çerçevesi, diğer taraftan tarım istatistiklerine özgün kalite göstergeleri geliştirmeyi amaçlamıştır (FAO, 2014 ve 2018, Orazio ve Gennari, 2020).

Yukarıda adı geçen kuruluşların önerdiği kalite göstergeleri Tablo 3'de özetlenmektedir. Görüldüğü gibi önerilen tüm gösterge setleri bir iki farklılık ve tasnif değişikliği dışında birbirinin aynısıdır.

Tablo 3: Uluslararası Kuruluşların Önerdiği Çıktı Kalite Göstergeleri

BM	IMF	AB	OECD	FAO
İlgililik	İlgililik	İlgililik	İlgililik	İlgililik
Doğruluk ve Güvenilirlik	Doğruluk	Doğruluk ve Güvenilirlik	Doğruluk	Doğruluk ve Güvenilirlik
	Güvenilirlik			
Zamanlılık ve Dakiklik	Zamanlılık	Zamanlılık ve Dakiklik	Zamanlılık	Zamanlılık ve Dakiklik
	Dakiklik			
Tutarlılık ve Karşılaştırılabilirlik	Tutarlılık	Tutarlılık ve Karşılaştırılabilirlik	Tutarlılık	Tutarlılık ve Karşılaştırılabilirlik
Erişilebilirlik ve Açıklık	Erişilebilirlik	Erişilebilirlik ve Açıklık	Erişilebilirlik	Erişilebilirlik ve Açıklık
	Yorumlanabilirlik		Yorumlanabilirlik	
Meta Veri	İnanılabilirlik		İnanılabilirlik	
			Maliyet Etkinliği	

Not: Relevance: İlgililik, Accuracy: Doğruluk, Reliability: Güvenilirlik, Timeliness: Zamanlılık, Punctuality: Dakiklik, Accessibility: Erişilebilirlik, Clarity: Açıklık, Coherence: Tutarlılık, Comparability: Karşılaştırılabilirlik, Meta Data: Meta Veri, Credibility: İnanılabilirlik, Interpretability: Yorumlanabilirlik Cost Efficiency: Maliyet Etkinliği.

Türkiye'ye gelince, 5429 sayılı Türkiye İstatistik Kanunu ile Avrupa İstatistikleri Uygulama Esaslarına uyum için gerekli yasal düzenlemeler yapılmış ve resmi istatistik üretim süreçlerinde bu ilkeler esas alınmaktadır. Bu ilkeler çerçevesinde, Resmi İstatistik Programı kapsamında bulunan tüm kurum ve kuruluşlar bu TÜİK'e karşı sorumludur. Avrupa İstatistikleri Uygulama Esasları ile istatistik kurumlarına resmi istatistiklerin kalitesinin düzenli olarak izlenmesi ve değerlendirilmesi tavsiye edilmektedir. Bu bağlamda, TÜİK hem kendi ürettiği resmi istatistiklere hem de diğer kurum ve kuruluşlar tarafından resmi istatistik programı kapsamında üretilen istatistikler

için kalite değerlendirmeleri yapmaktadır. TÜİK'in kendi ürettiği istatistikler için yaptığı değerlendirmeler Kalite İzleme ve Değerlendirme Aracı (KİDA) kapsamında, diğer kurum ve kuruluşlar tarafından resmi istatistik programı kapsamında üretilen istatistiklere uygulanan kalite değerlendirme çalışmaları ise Kalite Logosu kapsamında yürütülmektedir (TÜİK, 2022e, 2022f).

İstatistik derleyen tüm ulusal ve uluslararası kurum ve kuruluşlar yukarıda sıraladığımız kalite göstergelerini ve daha fazlasını benimsediklerini ve ürettikleri, yayınladıkları istatistiklerin bu ilkeler ile uyum içinde olduğunu ima ederler. İstatistiklerin kalite değerlendirmesi en iyi ihtimalle bir Kontrol Listesi (Check List) yöntemiyle yapılır ve sonuçları hemen hemen hiç istatistiklerin kullanıcıları ile paylaşılmaz.³

4. Türkiye'de Tarım İstatistiklerinin Kalitesi

Bu bölümde, Türkiye'de tarım istatistiklerini araştırmalarında yoğun olarak kullanan, üretim aşamalarında yer almış 11 değerli akademisyen⁴ ile bu çalışmanın yazarının **öznel** değerlendirmelerine yer vereceğiz. Akademisyenlerden, tarımsal üretim, girdi, fiyat, dış ticaret, üretici, refahı, tüketici refahı, tarım politikaları ve tarımsal yapı olarak 8 konuda tarım istatistiklerini ilgililik, kapsayıcılık, tutarlılık/kıyaslanabilirlik, güncellik/dakiklik, erişilebilirlik/anlaşılabilirlik, güvenilirlik/doğruluk olmak üzere 6 kalite göstergesine göre 0-10 arasında bir puan (not) ile değerlendirmeleri istenmiştir.

Tablo 4'te 11 akademisyenden doldurmaları istenen tablonun çalışmanın yazarı tarafından doldurulmuş olanı sunulmaktadır. Tablo 5'te ise 11 Akademisyenin kalite değerlendirme ortalaması sunulmaktadır. Bu değerlendirmelerden şu sonuçları çıkarabiliriz:

- a. Yazar, tarım istatistiklerinin kalitesi konusunda diğer akademisyenlerden daha iyimserdir.
- b. Yazar, tarım istatistiklerinin görece olarak en güçlü yönünün güncellik ve dakiklik, en zayıf yönünün erişilebilirlik ve anlaşılabilirlik olduğunu düşünürken, 11 akademisyen görece olarak en güçlü yönün ilgililik en zayıf yönün ise güncellik ve dakiklik olduğunu düşünmektedir.

³ TÜİK İstatistik alt konuları itibarıyla her yıl bir kurumsal kalite raporu hazırlamakta ancak burada uluslararası tanım, uluslararası sınıflamalara uygunluk ve uluslararası paylaşımın yapıldığının teyid edilmesi dışında bir kalite ölçümü yapılmamaktadır (TÜİK, 2022e).

⁴ 11 Akademisyen, Ankara, Çukurova, Akdeniz, ODTÜ, Samsun, Gazi üniversitelerinden, ekonomi ve ziraat kökenli Tarım Ekonomistleridir.

- c. Hem yazar hem de akademisyenler en kaliteli istatistiklerin dış ticaret istatistikleri, en düşük kalitenin ise, akademisyenler üretici ve tüketici refah göstergelerinde, yazar ise tarımsal yapı ve tüketici refahı istatistiklerinde olduğunu düşünmektedir.

Görüldüğü üzere akademisyenler arasında konulara ve kalite göstergelerine göre hem benzerlikler hem de farklılıklar vardır. Ancak ortalama notlar genelde 4-6 arasında, iyi-kötü sınırında ve iyileştirmelere yer olduğu yönündedir.

Tablo 4: Kasnaçoğlu: Türkiye’de Tarım İstatistikleri Değerlendirmesi

Kalite Öğeleri	Üretim	Girdiler	Fiyat	Dış Ticaret	Üretici Refahı	Tüketici Refahı	Tarım Politika	Tarımsal Yapı	Ortalama
İlgililik+Kullanıcı Talepleri	7	4	7	9	6	3	4	5	5,6
Kapsayıcılık	7	5	7	9	4	4	5	6	5,9
Tutarlılık+ Kıyaslanabilirlik	8	6	7	8	5	5	6	3	6,0
Güncellik+ Dakiklik	8	7	9	8	6	6	6	1	6,4
Erişilebilirlik+ Anlaşılabilirlik	8	5	7	6	3	3	3	2	4,6
Güvenilirlik+ Doğruluk	6	6	6	8	5	4	7	3	5,6
Ortalama	7,3	5,5	7,2	8,0	4,8	4,2	5,2	3,3	5,7

Tablo 5: 11 Akademisyen: Türkiye’de Tarım İstatistikleri Değerlendirmesi

Kalite Öğeleri	Üretim	Girdiler	Fiyat	Dış Ticaret	Üretici Refahı	Tüketici Refahı	Tarım Politika	Tarımsal Yapı	Ortalama
İlgililik+Kullanıcı Talepleri	6,8	5,8	6,5	8,2	5,0	5,2	6,2	5,8	6,2
Kapsayıcılık	6,6	5,1	5,3	7,7	3,4	3,6	4,6	4,3	5,1
Tutarlılık+ Kıyaslanabilirlik	5,0	4,4	4,9	6,2	3,2	3,3	3,9	3,9	4,3
Güncellik+ Dakiklik	5,6	4,5	4,8	6,7	2,8	2,8	3,4	3,2	4,2
Erişilebilirlik+ Anlaşılabilirlik	6,1	4,8	4,6	6,3	3,1	3,0	3,9	3,5	4,4
Güvenilirlik+ Doğruluk	4,7	4,1	4,8	7,0	3,3	3,3	4,3	3,8	4,4
Ortalama	5,8	4,8	5,2	7,0	3,5	3,5	4,4	4,1	4,8

5. Tarım İstatistiklerinin Sorunları

Aşağıdaki gayet makul ve gündemdeki çıkarımları sınamak istediğimizi düşünelim. Gerekli verilere kolayca erişebilir miyiz?

- a. Son yıllarda çiftçinin geliri maliyetini karşılayamamaktadır.
- b. Aşırı, gıda fiyat artışlarının sorumlusu aracılar ve büyük marketlerdir.
- c. Çiftçinin eline geçen fiyatlar dünya fiyatlarının altındadır.
- d. İthalat ve ihracat yoluyla, çiftçimiz yerine başka ülke çiftçileri desteklenmektedir.
- e. Temel gıda ürünlerinde net ithalatçı durumundayız.
- f. Artan ürün fiyatlarının sorumlusu artan girdi fiyatlarıdır.
- g. Yeterli beslenemeyen ve aç sayısı hızla artıyor.
- h. Türkiye tarımda kendi kendine yeterli bir ülkedir.

Ya da tarım politikalarını değerlendirmek için bir tarım sektör modeli veya tarımı genişletilmiş bir genel denge modeli yapmak isteyen bir araştırmacı gerekli verilere kolayca erişebilir mi? Evet demek zor, peki sorun ne?

- a. **Veriler Farklı Kaynaklarda:** Tarım istatistiklerine tek bir kaynaktan erişmek mümkün değil. Çoğunu TÜİK'ten almak mümkün ama bazılarını Tarım ve Orman Bakanlığında (örn. destekler, tarımsal ilaç), bazılarını borsalardan (örn. toptan fiyatlar), bazılarını gazetelerden (çarşı-pazar fiyatları), bazılarını üretici birliklerinden (üretim maliyetleri), bazılarını FAO, OECD gibi uluslararası kuruluşlardan (yeterli beslenemeyen sayıları, üretici destekleri, pazar destekleri) elde etmek gerekiyor.
- b. **Aynı Kaynaktaki Veriler Farklı Yerlerde:** Kurumsal kaynağa ulaşılsa bile, veriler (bazen aynı veriler) aynı kurumda farklı yerlerde. TÜİK'te İstatistik Veri Portalı, Bölgesel İstatistikler, İl Göstergeleri, Merkezi Dağıtım Sistemi (Medas), Tarım ve Orman Bakanlığında, Bakanlık Bilgi Merkezi, Genel Müdürlükler verilerin bulunabileceği adreslerden bir bölümü.
- c. **Farklı Veriler Her Zaman Uyumlu Değil:** Farklı konularda (alan-üretim-fiyat-ticaret-tüketim) farklı sınıflamalar, farklı ürün detayı, farklı zaman aralığı ve mekan kullanıldığından birlikte değerlendirerek katma değer sağlamak her zaman kolay olmuyor.
- d. **Değişik Kaynak Verileri Tutarlı Olmayabiliyor:** Farklı kaynaklarda ve veri tabanındaki veriler, tanım farklılıkları, değişik güncelleme tarihleri, farklı yöntem kullanımı nedeniyle farklılık gösterebiliyor.
- e. **Veriler Farklı Güncellikte:** Bazı veriler son ay, son yıl güncelliğinde olurken, bazı veriler bir yıl veya daha geride kalmış olabiliyor. Bunun bir kısmı verilerin niteliğinden kaynaklanıyor olabilir.

- f. Bazı Veriler Sürekli Değil:** Özellikle anket ve sayıma dayalı veriler değişik nedenlerle bu anket ve sayımların ertelenmesi veya yapılamaması durumunda güncelliğini ve sürekliliğini kaybetmektedir.⁵
- g. Veriler Farklı Ortamlarda ve Biçimlerde:** Veriler farklı kaynaklarda, farklı ortamlarda (Word-Excel-Pivot-Pdf-Rapor-Bülten) ve biçimlerde (nokta, virgül, boşluk kesir ve binlik ayraçları ile) sunulabiliyor.
- h. Meta Veri Eksik: TÜİK** ve uluslararası kurum istatistikleri dışında yayınlanan verilere ilişkin meta veri hemen hemen hiç bulunmuyor.
- i. Kullanımı Kolay Değil:** Verilerin farklı kaynaklarda ve farklı ortamlarda olması kullanımlarını güçleştiriyor. O nedenle pek çok araştırmacı birincil ulusal veri kaynakları yerine, ikincil uluslararası veri tabanlarını kullanıyor. Özellikle dış ticaret ve zaman serisi gerektiren durumlarda ikincil kaynak kullanımı artıyor. Bazı durumlarda verinin üreticisi bile kendi kaynakları yerine uluslararası kaynağı tercih edebiliyor.
- j. Verilerin Güvenirliliği Sorgulanıyor:** Genelde istatistik kurumuna ve verilerine güvensizlik, tarım verilerine de yansıyor. Ayrıca, özellikle verilerin önemli bir bölümünün idari kayıtlara dayanması, kapsamlı bir çerçevenin olmaması ise anket örneklerinde güven sorunu yaratıyor.
- k. Veri Arz Talep Dengesizliği:** Bir kesim girdi ve çıktı verilerinin detayını, diğer bir kesim ise fiyat, maliyet gibi iktisadi verileri, yine bir kesim ise gelir, dağılım, yapısal verilerin derinliğini yetersiz buluyorlar. Bir tarafta, ortalıkta çok miktarda derlenmiş ancak kullanılmayan veri, öbür tarafta talep edilen ancak derlenmeyen çok sayıda veri var.
- l. Zaman Dizisi Yetersizliği:** Verilerin tanımları ve veri derleme yöntemleri sık sık değiştiği için, kullanılabilir zaman dizileri bulunmuyor.

Sorunların listesini daha da detaylandırmak ve uzatmak mümkün. Ancak iyileştirme önerilerine geçmeden evvel yazarın şu öznel saptamasına da yer vermek gerekiyor:

Türkiye’de, istatistik kurumlarında tarım, tarım kurumlarında istatistik ihmal edilmelerine ve tüm eksikliklerine rağmen, tarım istatistikleri görece olarak en kaliteli istatistiklerdir.

Özellikle TÜİK’de topluca bulunabilen, oldukça zengin bir veri kaynağı, uluslararası düzeyde kapsam ve kaliteye sahiptir. Bunda 60-70’li yıllarda BM ve FAO, 80-90’lı yıllarda OECD ve sonrası AB katkı ve yönlendirmeleri etkili olmuştur.

Özetle oldukça kaliteli ve bol malzeme var, iyi bir helva yok. Bu dünyada da böyle. Türkiye tarım istatistikleri çok daha iyi ve dünyaya örnek olabilir.

⁵ Örneğin en son tarım sayımı 2001’de, tarımsal işletme yapısı araştırması ise 2016’da yapılmıştır.

6. Bütünleşik Veri Tabanı

Bütünleşik veri tabanı, farklı kaynaklardan, veri tabanlarından, farklı biçimlerdeki verilerin temizlenerek, birbirleri ile uyumlu bir biçime getirilerek tek bir veri tabanında toplanması ve kullanıma sunulmasıdır. Bütünleşik veri tabanını oluşturan veriler, kısmen veya tamamen tek bir yerde depolanabileceği gibi, orijinal yerlerinde de kalabilirler. Önemli olan kullanıcının bu verilere tek bir arayüz ile kolaylıkla ulaşabilmesi ve daha önemlisi farklı tanım ve biçimdeki verileri birlikte kullanabilmesidir.

Bütünleşik veri tabanları, basitten karmaşığa, değişik bütünleştirme modelleri kullanılmaktadır. Bunlardan bazıları ve örnekleri Tablo 6'da özetlenmektedir.

- i. **İçerik Bütünleştirme:** Benzer içerikteki verileri fiziksel olarak bir araya getirir veya bunlara bağlantı sağlar.
- ii. **Veri Depolama:** Verileri orijinal formatlarını ve değerlerini değiştirmeden depolama, bir tür arşiv görevini üstlenir.
- iii. **Yerel Veri Ambarı:** Farklı kaynaktaki verileri tek bir yerel veri tabanına aktarır, tasnif eder ve tek bir arayüzden kullanıma sunar.
- iv. **Sanal Veri Ambarı:** Farklı kaynaktaki verileri yerel ambara aktarmadan, aracı arayüzler kullanarak, kaynaklarından kullanıma sunar.
- v. **Anlamsal Bütünleştirme:** Belli bir amaca yönelik farklı veri setlerini tutarlı bir biçimde bir araya getirip birbirleriyle ilişkilendirmeye olanak sağlar.
- vi. **Tekli Ontolojik Bütünleştirme:** Farklı veriler, genellikle hiyerarşik olan ve ilgili tüm verileri ve ilişkilerini içeren kapsamlı bir düzenleme (üst yapı) ile bir araya getirilir.
- vii. **Çoklu Ontolojik Bütünleştirme:** Verilerin bütünleştirilmesinde tek bir kavramsal üst yapı kullanılabileceği gibi (örneğin toplum refahı), birden fazla üst yapı da (örneğin tüketici refahı, üretici refahı, sürdürülebilirlik) kullanılabilir.

Tablo 6: Bütünleştirme Modelleri ve Örnekler

Bütünleştirme Modeli	Örnek
İçerik	TÜİK(Tarım)
Veri Depolama	UNSD (Nüfus, Dış Ticaret, Enerji)
Veri Ambarı	UN-Data, EUROSTAT, OECD, FAO
Anlamsal Bütünleştirme	COM-TRADE, TÜİK, FAOSTAT
Ontolojik Bütünleştirme	FAOSTAT2 Project-TAR-İST Öneri

Kaynak: Kasnakoğlu (2009).

Bütünleşik bir veri tabanı oluşturmak için 3 konuda karar vermek gerekiyor. Bunlar sırasıyla amaç, kapsam ve bütünleştiricilerdir.

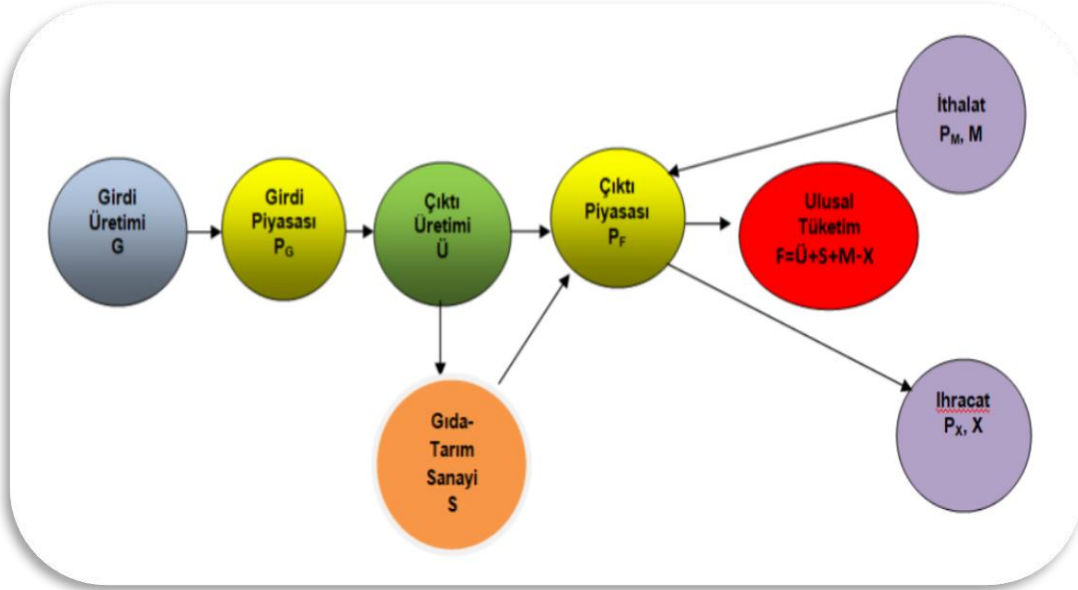
6.1. Amaç

Her veri tabanının, özellikle de bütünleşik veri tabanının bir amacı olması gerekir. Aksi takdirde hangi verilerin, hangi detayda, hangi sıklıkla ve hangi yöntemle derleneceği ve yayınlanacağı konusunda bir yön gösterici olmaz, veri tabanı da kimseye memnun etmeyen bir veriler kalabalığı olur. Amaçların belirlenmesi ve sınırlanması da kolay değil. Burada detaylı amaçlardan çok, çerçeve amaçlardan söz edeceğiz:

- Tarım politikalarının oluşum, izleme ve değerlendirmesine katkı
- Tarım sektörünün geçmiş ve güncel durumunu izlemek
- Tarım üreticileri ve tarım ürünü tüketicilerin refahını değerlendirmek
- Araştırmacılara ve paydaşlara veri sağlamak
- Uluslararası veri tabanları ile uyum ve veri alışverişi

6.2. Kapsam

Tarım sektörü denilince, bitkisel üretim, hayvancılık, ormancılık, su ürünleri ve balıkçılık alt sektörleri ve bunların girdi üretimden başlayıp, tarım ve gıda ürünlerinin tüketilmesine kadar uzanan üretim ve değer zincirlerinden söz etmek mümkün. Doğal olarak kapsamlı bir tarım veri tabanının bu dikey ve yatay öğelerin tümünü kapsamı arzu edilir. Ancak bu pratikte mümkün olmayabilir. Burada önemli olan birbiri ile girdi-çıkı ilişkisi olan öğeleri bütünleşik veri tabanı içine dahil etmek ancak dışarıda bırakılanlarla da bağlantılar kurmak. Bu da genelde girdi-çıkı ilişkisi olan bitkisel ve hayvancılık alt sektörlerinin bütünleşik bir veri tabanında bir arada, ormancılık ve balıkçılık sektörlerinin ayrı ayrı (yine bütünleşik) veri tabanlarında değerlendirilmesi anlamına gelmektedir. Şekil 1'de, bütünleşik bir veri tabanının içeriğini oluşturacak, tarım girdilerinden başlayıp, üretim, işleme ve ilgili piyasa aşamalarından geçerek, dış ticaret ve tüketime giden değer zinciri gösterilmektedir.

Şekil 1: Tarım İstatistikleri Kapsamı

Kaynak: Kasnakoğlu (2022).

6.3. Bütünleştiriciler

Amaç ve kapsam ile, bütünleştirilecek verilerin sınırının çizilmesi amaçlanmaktadır. En zor bölüm ise farklı kaynaklardaki, farklı biçimlerdeki verilerin birbirleri ile uyumlu, tutarlı bir şekilde, temizlenerek ve boşlukları doldurularak, kullanıma hazır bir araya getirilmesidir.

6.3.1. Kavramsal Üst Yapı

Bütünleştirme işleminin olmazsa olmazı kavramsal bir üst yapının olmasıdır. Bu veri tabanının konusuna ve amacına göre farklılık gösterebilir. Genel istatistikler için bu üst yapı milli gelir, gelir dağılımı, sosyal refah gibi kavramlar olarak düşünülebilir. Tarım sektörü için üst yapı, tarımsal katma değer, tarım üreticileri refahı ve tarım ürünleri tüketicileri refahı olarak düşünülebilir. Bu üst yapı aynı zamanda tarım politikalarının amacı olarak da düşünülebilir. Doğal olarak üst yapıyı destekleyen veya onun altında, yanında alt yapılar da olabilir. Bunlardan son yıllarda özellikle vurgulanan bir tanesi, sürdürülebilirlik kavramıdır.

6.3.2. Analitik Araçlar

Kavramsal üst yapıya ek olarak bütünleştirmeye anlam katacak, tutarlılık sağlayacak birçok analitik araçtan söz etmek mümkün:

- **Tarım Modelleri:** Bitki Büyüme, Çiftlik-Hanehalkı, Sektör, Genel Denge Modelleri, vb.
- **Eşitlikler:** Alan x Verim = Üretim, Fiyat x Miktar = Değer, vb.
- **Dengeler:** Ürün, Gıda, Arz-Talep, Dış Ticaret Dengeleri

6.3.3. Sınıflamalar

Farklı veri setlerinin birleştirilebilmesi için özellikle aralarında ilişkilendirme tabloları olan uluslararası sınıflamaların kullanılması çok önemlidir. Üretim istatistiklerinde kullanılan ürün listesi ve tanımları ile fiyat ve dış ticaret istatistiklerindeki ürün liste ve tanımları, girdi fiyatları ile girdi kullanım istatistiklerinde kullanılan listeler uyuşmadığı takdirde veya bu listeler arasında kabul görmüş geçişler olmadığı takdirde birçok veriyi birlikte kullanmak mümkün olmayacaktır.⁶

6.3.4. Dönüşüm Katsayıları

Tarım sektörünü tarladan sofraya izlemeyi amaçladığımızda veri tabanı ile yeni birçok analize olanak sağlamış oluyoruz. Ancak kapsamın bu şekilde genişlemesi bazı sorunları da beraberinde getiriyor. Değer zincirinin değişik aşamalarında ürünle işlenerek şekil değiştiriyor. Üretilen, tüketilen ve dış ticareti yapılan ürünler aynı ürünler değil. O nedenle de örneğin, üretilen ve ithal edilen buğdayın ne kadarı ihraç ediliyor, ne kadarı içeride tüketiliyor sorusuna cevap bulabilmek için buğdaydan üretilen ürünleri buğdaya dönüştürebilmek gerekiyor. Aynı şekilde buğdayın değer zincirinin değişik aşamalarındaki fiyatını kıyaslayabilmek için de dönüşüm katsayıları gerekiyor.⁷

6.3.5. Meta Veri

Bütünleşik bir veri tabanı farklı kaynaklardan, farklı tanım ve biçimlerde gelen verilerin, birlikte kullanılabilmesi için, uyumlu hale getirilmesi, eksikliklerinin tamamlanması, hatalarının düzeltilmesi birçok işlem gerektirecektir. Verilerin kaynaklarının, derleniş yöntemlerinin, yapılan varsayımların, dönüştürme işlemlerinin belgelenmesi, türev değişkenlerin tanımlanması için, sayısal veri tabanının özenle geliştirilmiş bir meta veri tabanı ile zenginleştirilmesi gerekmektedir.

TÜİK yayınladığı istatistikler için bir meta veri şablonu kullanarak, konu bazında meta veri yayınlamaktadır. Bu şablonda, veri setinin tanımlanması, kalite öğelerini de içerecek biçimde şu başlıkları altında yapılmaktadır: Kapsam (veri tanımı, coğrafi kapsam, sınıflama, sektörel kapsam, zaman, referans dönemi, ölçü birimi, dönemsellik, zamanlılık), Kamuoyunun Bilgiye Ulaşımı, Bütünlük, Kalite (TÜİK, 2022f). Tarım istatistikleri için de konu bazında (bitkisel üretim, ürün denge tabloları, dış ticaret,

⁶ Sınıflama konusuna bölüm 8.7'de daha ayrıntılı olarak değineceğiz.

⁷ Dönüşüm katsayıları konusuna daha kapsamlı olarak bölüm 8.6'da değineceğiz.

tarımsal alet makine, tarımsal işletme yapısı, su ürünleri, hayvancılık, tarımsal fiyat ve ulusal hesaplar, tarımsal girdi fiyat endeksi vb.) bu şablon ile meta veri yayınlamaktadır (TÜİK, 2022g). Yayımlanan meta verilerin kapsam, yöntem, sınıflama, referans dönemi gibi veriyi tanımlayan kısımları yeterli ancak kalite tanımlayan kısımları boş veya yetersizdir.

7. Bütünleşik Bir Tarım Veri Sistemi Önerisi

Bu bölümde Türkiye tarım istatistiklerini daha kullanışlı bir yapıya kavuşturacak, karşılaşılan sorunları azaltacağını umduğumuz bütünleşik bir tarım veri tabanı sistemi önerisi sunulacaktır.⁸ Bu öneride, genelde var olan verilerin yeniden yapılandırılmasının yanı sıra eksik olan yeni bazı verilerin derlenmesi de söz konusudur. Bütünleşik tarım veri tabanının bazı özellikleri ve varsayımları aşağıda özetlenmektedir:

İsim: Bütünleşik Tarım İstatistikleri Sistemi (TAR-İST)

Amaç: Tarım Politikaları, Tarım Analizleri, Tarım İzleme

Kapsam: Bitkisel Üretim ve Hayvancılık, Tarım Değer Zinciri

Veri Sistemi Parçaları: Çekirdek ve Kaynak

Çekirdek Bütünleştirme Modeli: Çoklu Ontolojik

Bütünleştiriciler: Üretici Refahı, Tüketici Refahı, Sürdürülebilirlik

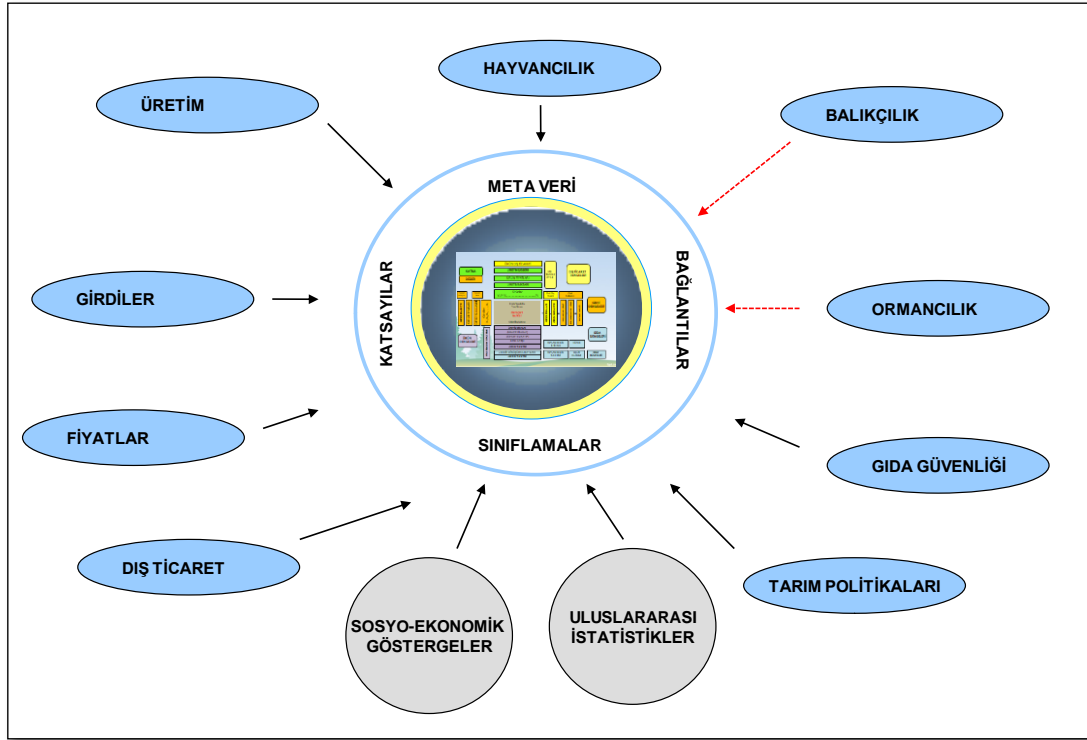
Kaynak Bütünleştirme Modeli: Anlamsal, Tekli Ontolojik

Şekil 2’de gösterildiği gibi TAR-İST her biri belirli konular etrafında bütünleştirilmiş ayrı ayrı (anlamsal) kaynak veri tabanlarından ve ontoloji tabanlı bir çekirdek’ten oluşmaktadır. Kaynak veri tabanları şu anda var olan, çoğunlukla TÜİK, TOB ve FAO’da bulunan veri setlerinin yeniden düzenlenmiş ve genişletilmiş biçimleri olarak düşünülebilir. Bunlar bitkisel üretim, hayvancılık, ormancılık, balıkçılık, girdiler, fiyatlar, dış ticaret, gıda güvenliği, tarım politikaları, sosyo-ekonomik göstergeler, uluslararası istatistikler olarak düşünülebilir. Bu veri tabanlarında tekrarlar, kavram, kapsam ve biçim farklılıkları olabilir. Bu nedenle de farklı veri tabanlarının kendi içlerinde ve veri tabanları arasında bilgi alışverişi ve birleştirme mümkün olamayabilir. İşte bu nedenle bu veri tabanlarından türeyen bir bütünleşik veri tabanına ihtiyaç duyuyoruz. TAR-İST’in ve özellikle çekirdek veri tabanının geliştirilmesi aşamalarında kaynak ve çekirdek veri tabanları arasındaki alışverişin daha çok kaynaktan çekirdeği

⁸ Burada **Bütünleşik** terimi **Integrated** kelimesinin karşılığı olarak kullanılmıştır. Aynı anlama gelebilecek entegre, tümleşik, bütünsel, bütünleşmiş kelimeleri de kullanılabilir.

dođru olması beklenirken. TAR-İST tamamlandığında, çekirdekten kaynađa da geri beslemelerin olması beklenir. Kaynak veri tabanları ile çekirdek veri tabanları arasındaki iki yönlü etkileşime bu çalışmada ayrıntılı olarak değinilmeyecek, bazı ipuçları ile yetinilecektir.

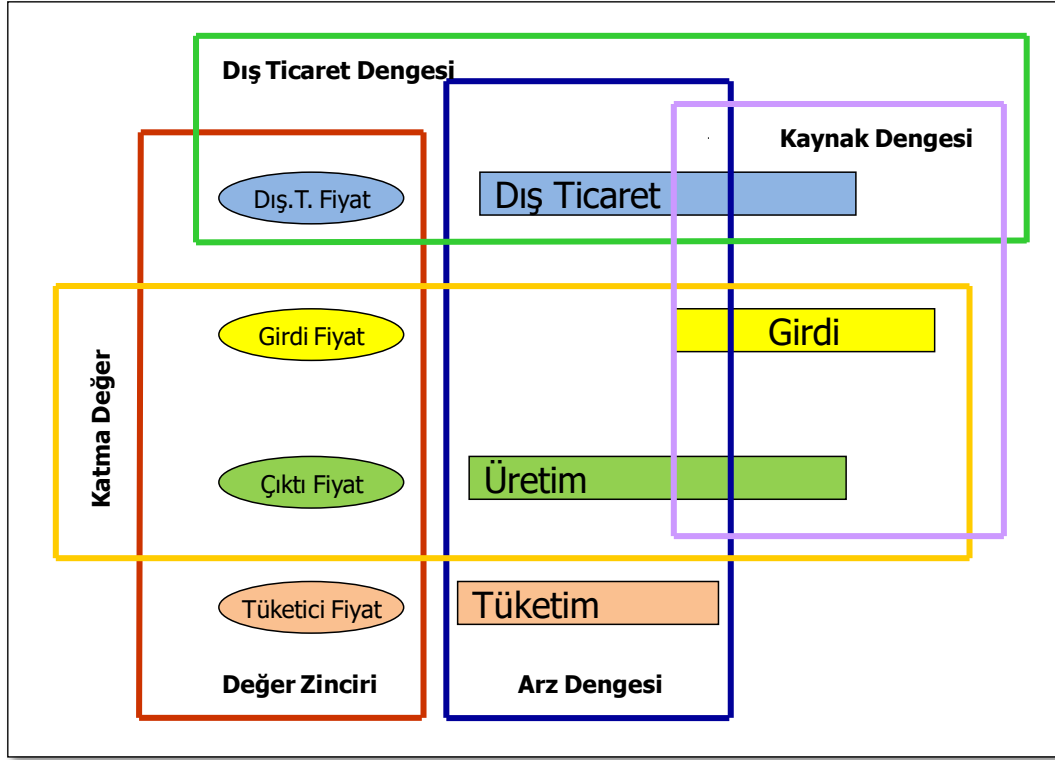
Şekil 2: Bütünleşik Tarım İstatistikleri Sistemi (TAR-İST)



Kaynaklar: Kasnakoglu ve Mayo (2003), Kasnakoglu (2004, 2006).

Şekil 3'te TAR-İST'in kaynak veri tabanlarından beslenen çekirdeğinin farklı veri setlerini birbirleri ile ilişkilendirerek bütünleştirecek olan kavramsal yapı taşları sunulmaktadır.

Şekil 3: TAR-İST Çekirdek Kavramsal Yapı Taşları

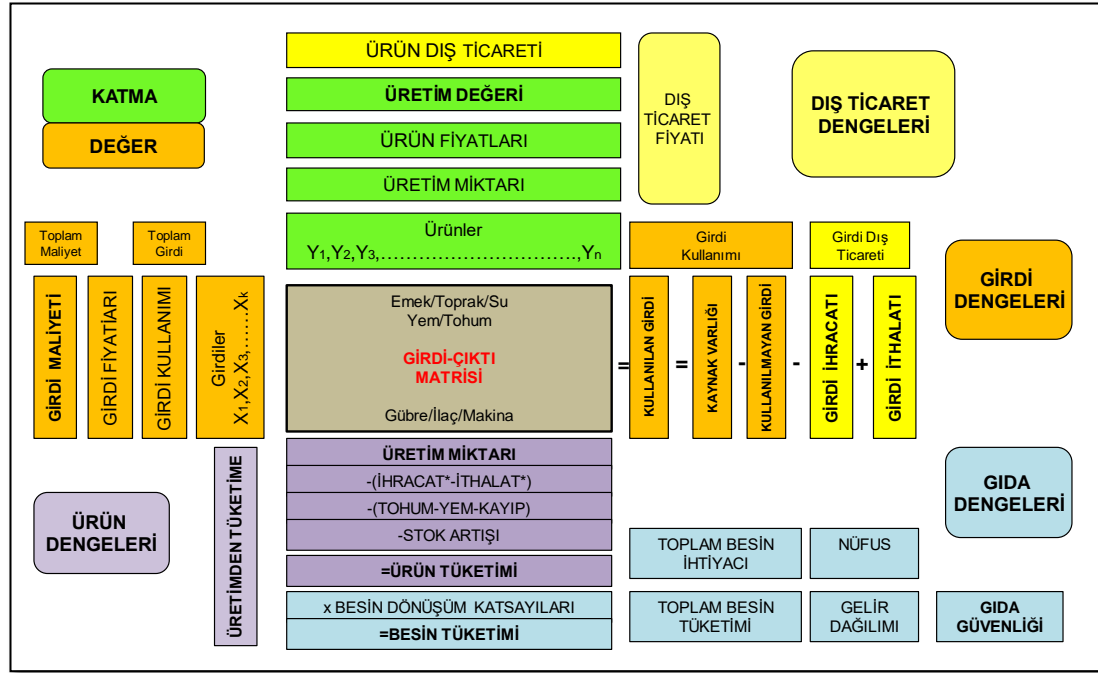


Kaynak: Kasnakoglu (2006).

Bunlardan (sarı çerçeve ile gösterilen) ilki, üretim ve girdi miktarları ile çıktı ve girdi fiyatlarının oluşturduğu ve tarım üreticisinin refahını belirleyecek olan **katma değer**. İkincisi (mavi çerçeve ile gösterilen) ve tüketicilerin refahını gösterecek üretim, ithalat, ihracat, tüketim dışı kullanım ve tüketimden oluşan **arz dengesi**. Üçüncü kavram (yeşil çerçeve ile gösterilen) ihracat ve ithalat miktar ve fiyatlarından çıkacak olan **dış ticaret dengesi**, Dördüncü birleştirici kavram (mor çerçeve ile gösterilen) tarımsal girdilerin varlığı, üretimi, üretimde kullanımı, ithalat ve ihracatını kapsayan **kaynak dengesi**. Son olarak (kırmızı çerçeve ile gösterilen) tarımsal üretime ilişkin girdi, çıktı, tüketici ve dış ticaret fiyatlarından oluşan **değer zinciri**.

Şekil 4'te TAR-İST çekirdek veri tabanının yapısı daha ayrıntılı olarak verilmektedir. Şekli bir Excel tablosu olarak düşünelim. Sütunlarda ürünler, girdi kullanımı, iç ve dış girdi fiyatları, sıralarda ise girdiler, üretim, tüketim, iç ve dış ürün fiyatları var.

Şekil 4: TAR-İST Çekirdek Veri Tabanı Yapısı



Kaynak: Kasnakoglu (2004, 2006).

Merkezde, sütun başlıkları ürünler (Y_1, Y_2, \dots, Y_n), sıra başlıkları girdiler (X_1, X_2, \dots, X_k) olan Tarım Girdi-Çıkıtı Tablosu var. Bu tablo'da üretilen her ürün için kullanılan girdi miktarları (A_{ij}) (haki), elde edilen ürün miktarları (mor) ve her girdinin toplam kullanılan miktarı (sarı) var. Örnek verirsek, girdi çıktı matrisinin birinci sırasında Y_1, Y_2, \dots, Y_n , ürünlerinde kullanılan X_1 girdi miktarları, son sütunda da tüm ürünlerde kullanılan toplam X_1 girdi miktarı var. Üçüncü sütunda ise Y_3 ürünü üretiminde kullanılan her bir girdi (X_1, X_2, \dots, X_k) miktarı ve en altta da Y_3 ürünü üretim miktarı var (Şekil 5).

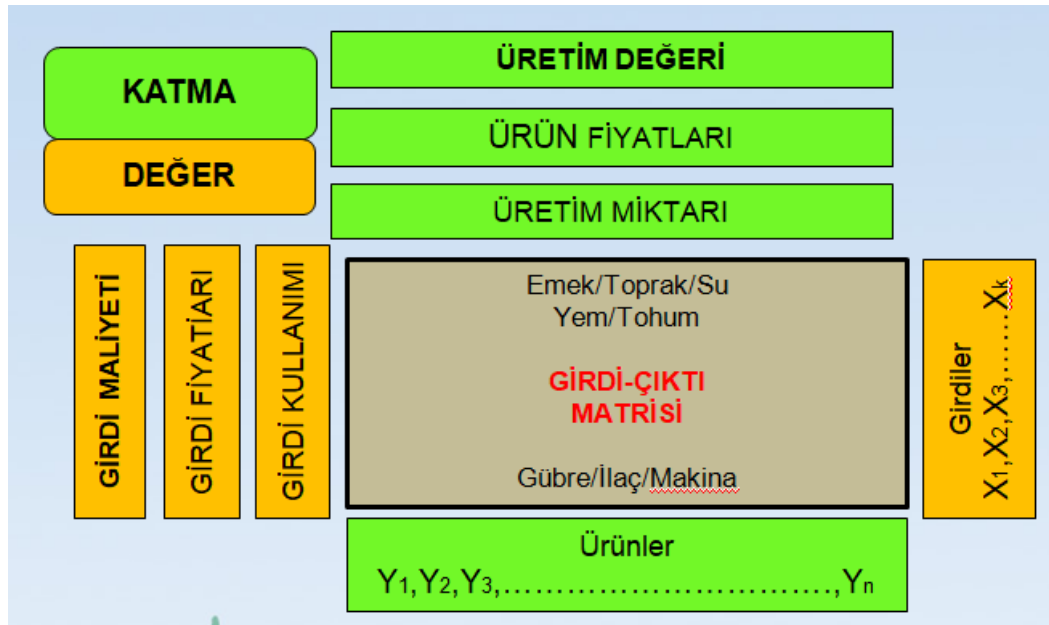
Şekil 5: TAR-İST Çekirdek Girdi-Çıktı Matrisi



Kaynak: Şekil 4.

Şimdi, sunum kolaylığı sağlamak ve Şekil 5 ile uyum sağlamak için, alttaki üretim miktarlarını en üst sıraya, en sağdaki kullanılan girdi miktarlarını da en sola taşıyalım, Ürün ve girdi isimleri için de tersini yapalım (Şekil 6) ve sütunlara girdi fiyatlarını, sıralara da çıktı fiyatlarını ekleyelim.

Şekil 6: TAR-İST Çekirdek Katma Değer

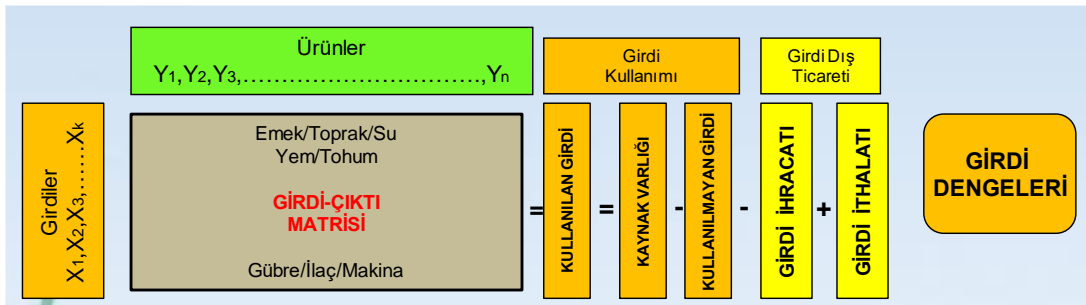


Kaynak: Şekil 4.

Üretim miktarlarını çıktı fiyatları ile çarptığımızda her ürün için üretim değerini ve topladığımızda toplam üretim değerini, girdi kullanım miktarlarını girdi fiyatları ile çarptığımızda her girdinin maliyetini, topladığımızda toplam girdi maliyetini buluruz. Üretim değerlerinden girdi maliyetlerini çıkardığımızda da ürün bazında ve toplam tarımsal katma değeri buluruz.⁹

Şekil 7’de girdi dengeleri gösterilmektedir. Her bir girdi için, bütün ürünlerin üretiminde kullanılan toplam girdi miktarı, girdinin varlığı, artı ithalatı, eksi ihracatı, eksi kullanılmayan miktarına eşittir.

Şekil 7: TAR-İST Çekirdek Girdi Dengeleri

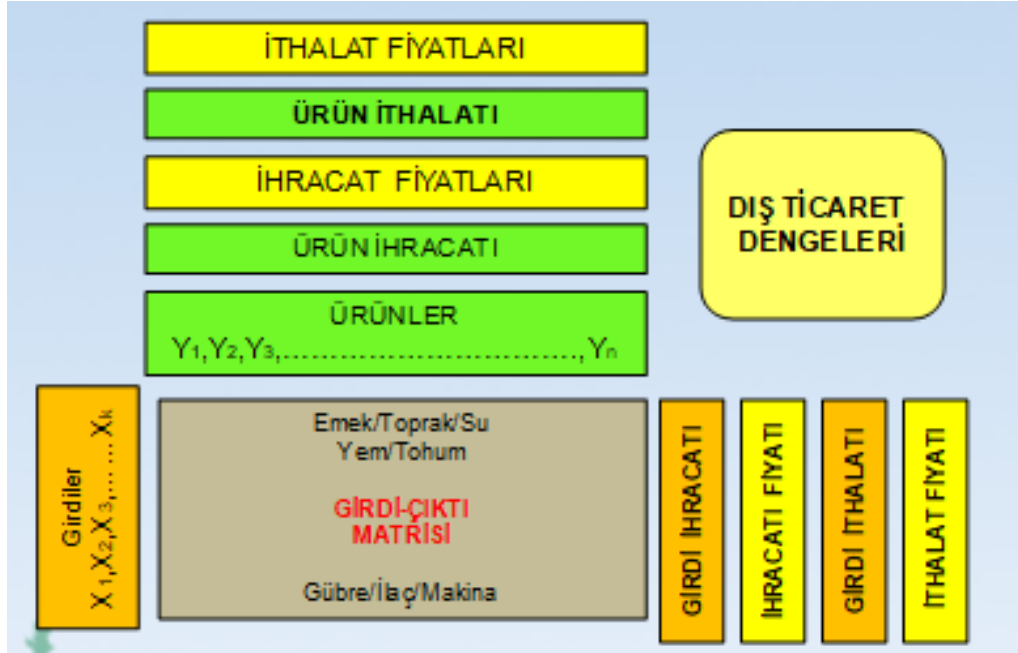


Kaynak: Şekil 4.

Şekil 8’de girdi ve çıktılar için ayrı ayrı ve toplu dış ticaret dengeleri verilmektedir. Burada önemli olan ihracat ve ithalatın birincil tarım ürünü eşdeğeri olarak hesaplanmış olmasıdır. Başka bir deyişle üretim hangi ürünler için hesaplanıyorsa dış ticaretin de aynı ürünler için hesaplanması gerekmektedir. Bu nedenle işlenmiş tarım ürünleri dış ticaretinin, işlenmemiş tarım ürünü ihracatı olarak ifade edilmesi gerekmektedir. Ancak bu şekilde tek tek hangi tarım ürünlerinde net ihracatçı, hangilerinde net ithalatçı olduğumuzu ölçebiliriz. Yine buradaki dış ticaret fiyatları birincil ürün fiyatlarıdır. Aynı şekilde, tarımsal girdi kullanımını hangi düzeyde ölçmüşsek, dış ticaretini de aynı düzeyde ölçmemiz gerekmektedir. Örneğin, gübre kullanımını N,P,K olarak ifade etmişsek, dış ticaretinin de aynı şekilde ifade edilmesi gerekmektedir. Bu şekilde hesaplanacak bir dış ticaret dengesi analitik olarak çok yararlı olmakla birlikte ifadesi çok da kolay olmayabilir. O zaman tek tek ürünler ve girdiler için dış ticaret dengelerini unutup, topluca tarım ürünleri olarak ifade edilen dış ticaret pozisyonları toplamları ile yetinmemiz gerekecektir. Bu durumda da hem tarım dışı ürünler de toplamlara girmiş olacak hem de ihracat ve ithalat için iki farklı ürün kompozisyon dengesi bulmuş olacağız.

⁹ Burada amacımız TAR-İST yapısını anlatmak olduğundan, sabit girdiler, ücretsiz emek, vb gibi ayrıntılara girmiyoruz.

Şekil 8: TAR-İST Çekirdek Dış Ticaret Dengeleri




Kaynak: Şekil 4.

Şekil 9’da üretilen ürünler için ürün dengeleri de denilen arz kullanım muhasebesi ile ürün bazında tüketimin elde edilmesi, daha sonra gıda ürünlerinin besin değerlerine dönüştürülerek gıda dengelerinin ve gıda güvenliğinin ölçülmesi gösterilmektedir. Burada da yurtiçi üretime, ithalatı varsa stoktan kullanımı ekleyip, ihracat, stok artışı, tohum, yem, kayıp gibi gıdaya gitmeyen üretimi çıkarıp tüketim miktarlarını elde ediyoruz. Bir önceki paragrafta vurguladığımız gibi, burada da üretim ve dış ticaretin aynı düzeyde yani birincil ürün olarak ifade edilmesi gerekmektedir. Dolayısıyla tüketim de birincil ürün eşdeğeri olarak hesaplanmaktadır. Daha sonra her ürünün bir kg’ında içerdiği kalori, protein karbonhidrat değerleri kullanılarak besin değerleri bulunabilir. Bu besin değerlerinin toplanıp, toplam besin ihtiyaçları ile karşılaştırılmasıyla gıda dengeleri elde edilmekte ve gıda güvenliği hesaplanabilmektedir.

Şekil 4’e dönersek, Şekil 5-Şekil 9’un birleştirilmiş olduğunu görürüz. Bir diğer önemli gözlem, tarım istatistiklerini bütünleştirmede kullandığımız 4 birleştirici denge aynı zamanda birbirleri ile olan ilişkisidir. Hepsinin ortak paydası olan girdi-çıkıtı tablosu dışında, her dengede, başka dengeleri meydana getiren değişkenler de yer almaktadır.

Şekil 9: TAR-İST Çekirdek Ürün-Gıda Dengeleri



Kaynak: Şekil 4.

Not: Şekil 4 ve Şekil 9'da "Kayıp" hasat sonrası kayıpları ve besin tüketimi hesaplamalarında ürünlerinin gıda dışı endüstriyel kullanımlarını kapsamaktadır.

8. TAR-İST Ayrıntıları

Bölüm 7'de TAR-İST'in temel yapısını vermeyi amaçladığımızdan, ilgiyi dağıtmamak için, birçok ayrıntıyı göz ardı ettik. Bu bölümde bu ayrıntılara yine çok ayrıntıya girmeden soru-cevap şeklinde değineceğiz.

8.1. TAR-İST Verileri Var mı? Yeni Veri Derlemek Gerekliyor mu?

TAR-İST sistemi, Şekil 2'de gösterildiği gibi, merkezde bir çekirdek ve onu besleyen kaynak veri tabanlarından oluşuyor. Temelde kaynak veri tabanları, var olan verilerin konular (üretim, fiyat, dış ticaret, girdi kullanımı vb) etrafında bir araya getirilmesi ile oluşuyor. Veriler çoğunlukla da konular etrafında bir arada bulunuyorlar. Farklı yerlerde olsalar da fiziki veya sanal olarak bir araya getirilmeleri çok zor değil. Çekirdek veri tabanının oluşturulmasındaki en önemli veri eksikliği, girdi-çıktı tablosunun, yani kullanılan girdilerin ürün bazında dağıtılmasında ortaya çıkıyor. Toprak girdisi için var olan bu verilerin, diğer girdiler için elde edilmesi, çiftlik muhasebesi, maliyet anketleri ve uzman görüşü gerektiriyor. İyi tarafı ise bu girdi-çıktı tabloları bir kere oluşturulduktan sonra her yıl küçük değişikliklerle güncellenebiliyor. Yine çekirdek veri tabanının oluşturulması için, var olan ancak derlenmesi gereken, önemli bir girdi bölüm 8.6'da ayrıntılı olarak ele alacağımız (işlenmemiş ürün) --> (işlenmiş ürün) --> (besin) dönüşüm tabloları.

8.2. TAR-İST Hangi Sektörleri Kapsıyor?

TAR-İST kavramsal yapı olarak bitkisel, hayvancılık, ormancılık ve balıkçılık sektörlerini kapsayabilir. Ancak pratikte bitkisel ve hayvancılık ile yoğun girdi çıktı

ilişkisi bulunmayan, ikame ve tamamlayıcılık etkileşimleri zayıf olan balıkçılık ve ormancılık faaliyetlerinin çekirdek veri tabanına dahil edilmemesinde ancak çekirdek yapıya benzer bir yapı ile kendi özel veri tabanlarında bulunmasında fayda var. Bu alt sektörlerin çekirdek dışında bırakılması durumunda, özellikle gıda güvenliği hesaplamalarında, su ve orman ürünleri tüketimlerinin ve bunların besin değerlerinin de hesaplamalara katılması gerekmektedir.

8.3. TAR-İST Tarım Değer Zincirini Tümüyle Kapsıyor mu?

Evet, ancak tüm halkaları aynı ayrıntıda kapsamıyor. Amaçlanan, birincil üretimin girdisi, çıktısı, teknolojisi, fiyatları ile kapsamlı bir şekilde kapsanması, zincirin diğer halkalarının ise birincil üretim ile geriye ve ileriye doğru bağlantıları düzeyinde kapsanmasıdır. Başka bir deyişle, tarımsal üretime katkı sağlayan girdi üretim sektörünün girdi arzı ve fiyatları TAR-İST kapsamında, ancak bu sektörün girdileri, girdi-çıkıtı tablosu, maliyetleri vb. kapsam dışıdır. Aynı şekilde tarım sanayinin birincil ürün talebi, alım-satım fiyatları ve arzı kapsam dahilindeyken, bu sektörün üretim yapısı, maliyet ve karlılığı kapsam dışındadır. Son olarak, tüketiciler tarım ürünlerine talepleri, ödedikleri fiyatlar, tükettikleri tarım ürünleri ve içerdikleri besin değeri ile TAR-İST'te temsil edilmekte, gelirleri, tüketici davranışları, yaşam koşulları vb. göstergeleri kapsamamaktadır.

8.4. TAR-İST Verileri Hangi Ayrıntıda Olmalı?

Veri tabanlarında en zor konulardan birisi de ayrıntı düzeyine karar vermek. TAR-İST sistemi çekirdek ve kaynak veri tabanlarından oluşmaktadır. Kaynak veri tabanlarında ayrıntı veri talebi, arzı ve bu amaçla kullanılacak bütçeye göre belirlenir. Çekirdek veri tabanında ise ayrıntıyı belirleyen ve sınırlayan verilerin bütünleşik olma özelliğidir. Başka bir deyişle çekirdek veri tabanında verilerin birbirleriyle bir bütün oluşturabilecek ayrıntıda, tanımda, zamanda, mekanda olması gerekmektedir. Örnek olarak, ayrıntıda girdi kullanımı verisi olmayan bir ürünün veya ürünlere dağıtılamayan bir girdinin bu veri tabanında yeri yoktur. Nitekim çekirdek veri tabanının güvenilirliği en zayıf halkası ile belirlenir. Doğal olarak bu, Bölüm 8.5'te göstereceğimiz gibi, az sayıda verisi eksik, hatalı veya tutarsız olan her değişkenin de atılması anlamına gelmemektedir.

Yukarıda konu ettiğimiz ürün ve girdi ayrıntısı yanında, verilerin bir de mekansal ve zamansal ayrıntısından söz edebiliriz. Kaynak veri tabanlarında yine veri talebi, arzı ve bütçeye göre zaman ve mekan ayrıntısını belirler. Örneğin, fiyatlar günlük, aylık, yıllık olabilirken, üretim yıllık, dış ticaret aylık, yıllık olabilir. Yine, dış ticaret ülke düzeyinde olurken, fiyatlar ülke ve bölge düzeyinde, üretim ülke, bölge, alt bölge düzeyinde olabilir. Çekirdek veri tabanında ise genelde yıllık ve ülke ayrıntı düzeyleri yeterlidir. Çekirdek veri tabanında girdi kullanımı ve üretimi bölgesel, girdi fiyatları kısmen bölgesel, kısmen ülke, çıktısı fiyatları bölgesel ve ülkesel, dış ticaret ise ülke düzeyinde veriyi sahiptir. Bunların ortak kesişim noktası ülke düzeyinde verilerdir. Daha alt

mekansal veriler kaynak veri tabanlarında bulundurulmalı ve onların bütünleşik veri tabanına katılması araştırmacılara bırakılmalıdır. Çekirdek veri tabanında zaman ayrıntısına gelince, birden fazla yıl, hatta bir zaman dizisi verileri çok iyi olurdu. Ancak bunu yeni kurulacak bir veri tabanından beklemek fazla iyimser olur. Çekirdek veri tabanı zaman içinde yıllık verilerin birikmesiyle zaman boyutunda da zenginleşecektir. Mevsimsel ayrıntı ise çekirdek veri tabanının bazı değişkenlerinde, daha sonra yıllık baza toplulaştırılmak üzere gerekebilir. Arzı mevsimsel farklılık gösteren girdi kullanımı (su, emek gibi), bir yılda birden fazla üretimin (buğday, mısır gibi) olduğu durumlarda, verilerde mevsimsel ayrıntı yararlı olabilir.

8.5. TAR-İST’de Eksik, Hatalı, Tutarsız Veriler Ne Olacak?

İstatistik veri tabanlarında sunucudan kaynaklanmayan eksik, hatalı, tutarsız verilere yaklaşımda iki temel yol vardır. Birincisi, verileri olduğu gibi sunmak ve düzeltmeleri kullanıcıya bırakmak. İkincisi ise eksik verileri, meta veride belirterek, tahmin etmek, hatalı ve tutarsız verileri, yine meta verilerde ayrıntılarını vererek, düzeltmek. Her iki yaklaşımın da artı ve eksileri vardır. Birinci yaklaşımın savunması şöyle olurdu: “İstatistik sunucuları, çok sayıda veri ile uğraşmak zorunda olduklarından, eksik verileri tahmin etmede, hatalı ve tutarsız verileri düzeltmede ancak genel yöntemler kullanabilirler, kullanıcılar ise daha küçük bir veri seti ile uğraştıkları için daha kapsamlı ve gelişmiş yöntemler kullanabilirler”. İkinci yaklaşımın savunması ise şöyle olurdu: “İstatistik sunucuları, konuyu uzmanları olarak kendi sundukları verinin eksiklik, hata ve tutarsızlıklarını, genel kullanıcılara göre çok daha iyi değerlendirebilir ve düzeltebilirler”. Yazarın görüşü Türkiye gibi görece olarak gelişmiş tarım istatistik ofisinin olduğu bir ülkede, uzman görüşlerine de başvurarak ve meta verilerle ayrıntılı açıklanarak, ikinci yöntemin kullanılmalıdır. Kaynak veri tabanlarında bu yaklaşım daha çok eksik ve hatalı verilerde ve aynı veri tabanında tutarlılık sağlamada faydalı olabileceken, farklı kaynak veri tabanları arasında tutarlılık sağlamak kolay olmayacaktır. Çekirdek veri tabanında ise eksiklerin tamamlanması, hata ve tutarsızlıkların düzeltilmesi kaçınılmazdır. Kullanıcılar, isterse çekirdek veri tabanını düzeltilmiş sunulan biçimiyle, isterlerse, nedenini belirterek, kendi düzeltmeleri ile kullanabilirler.¹⁰ Çekirdek veri tabanının bir özelliği de yapısı itibarıyla içerdiği dengelerle (girdi, arz, tüketim, dış ticaret) veri tutarsızlıklarına izin vermemesidir.

8.6. TAR-İST Dönüşüm Tablo ve Katsayıları Nereden Gelecek?

TAR-İST sisteminde, özellikle çekirdek veri tabanının olmazsa olmazı, daha önce de sözünü ettiğimiz üç dönüşüm tablosu. Bunlar, girdileri çıktıya dönüştüren **Girdi-Çıktı Tablosu**, birincil çıktıları işlenmiş ürünlere dönüştüren **Teknik Dönüşüm Katsayıları**

¹⁰ Veri tabanlarında eksiklerin doldurulması, tutarlılığın sağlanması için bkz. Verhoog, Heiden, Salomon, Dol ve Godeschalk (2008, s. 32-50), Kasnakoğlu (2009 ve 2022).

ve tüketilen gıda ürünlerini besin değerlerine dönüştüren **Besin İçerik Tablosu**. Aşağıda bunların yapısına ve kaynaklarına kısaca değineceğiz (Kasnakoğlu, 2022).

8.6.1. Girdi-Çıktı Tablosu

Tarım sektörü için geliştirilecek olan Girdi-Çıktı tablosunun genel yapısını Şekil 5’te göstermiştik. Tablo 7’de 1 hektar toprak kullanımı için standartlaştırılmış örnek bir Girdi-Çıktı tablosu gösterilmektedir. Burada ülke ortalaması olarak bir hektar alanda kullanılan girdi miktarları ile elde edilen ürün ve yan ürünlerin miktarı verilmektedir. Doğal olarak bu tablo veriler olduğu takdirde bölgesel, iklimsel, teknolojik koşullar ve ürün çeşitleri ile zenginleştirilebilir. Yine, bu tablo, 1 hektar toprak yerine, 1 Kg ürün için, veya güncel yıl için gerçekleşen girdi ve verim miktarları için de verilebilir. Önemli olan ürün maliyet çalışmalarının da özünü oluşturan bu tabloların, değer olarak değil, fiziksel olarak veri tabanında bulunmasıdır. Böylece, orta dönemde, yıllar itibariyle çok fazla değişmesi beklenmeyen fiziksel tablo, değişen fiyatlarla değerlendirilip gelir ve maliyet analizleri yapılabilecektir.

Tablo 7: Tarım Girdi-Çıktı Tablosu Genel Yapısı

	Buğday Kuru	Buğday Sulu	Nohut	Mısır	Domates Sofralık	Domates Salçalık	Elma
Kuru Toprak (ha)	1		1				
Sulu Toprak (ha)		1		1	1	1	
Ağaçlık Alan (ha)							1
İşgücü (hr/ha)	60	110	30	40	120	200	50
Gübre (Kg/ha)	10	30	10	20	40	60	2
Traktör (hr/ha)	12	16	5	10	12	24	0
Tohum (Kg/ha)	5	5	15		20	20	20
Verim (Kg/ha)	1000	2000	400	1200	600	1200	400
Saman (Kg/ha)	1000	1500	0	1000	0	0	0
Yem (Kg/ha)	200	150	10	1000	0	0	0

Kaynak: Kasnakoğlu (2022).

Türkiye’de tarım istatistikleri sisteminde bulunmayan, ancak tarım politikası oluşum ve değerlendirmesinde çok önemli olan bu tablonun ilk kurulumu ve doldurulması için çaba gerekecektir. Ürün uzmanı ziraatçıların, istatistikçilerin, tarım ekonomistlerinin, daha önce maliyet analizi yapmış meslek kuruluşlarının, çiftlik muhasebesi uzmanlarının, bu tabloları akademik çalışmalarını için geliştirmiş araştırmacıların bir

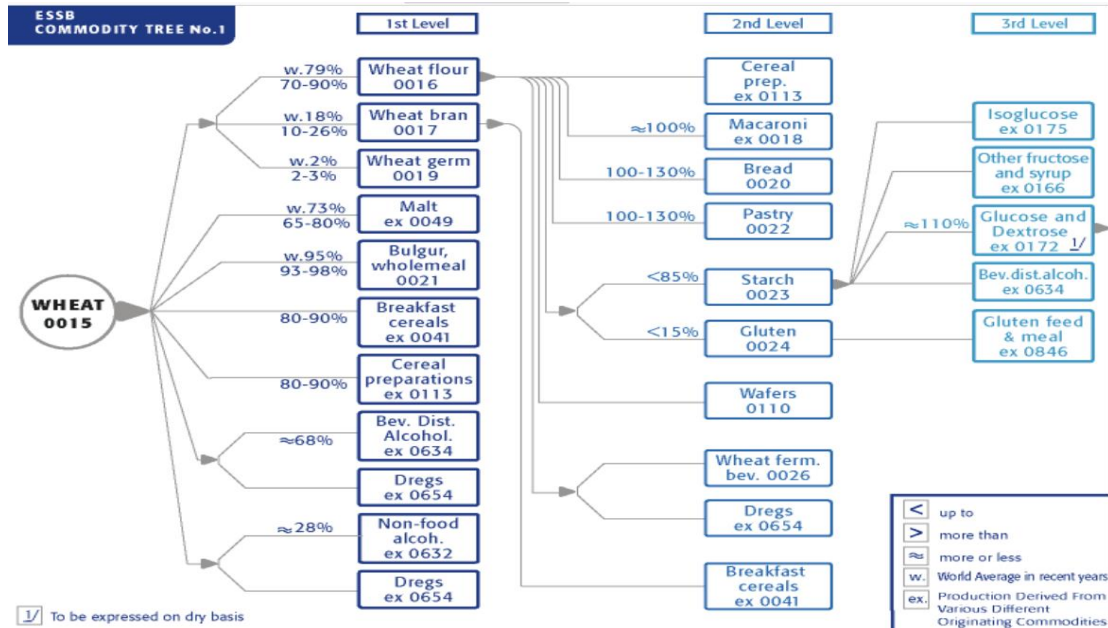
araya getirilerek ilk tablonun geliştirilmesi ve bunun güncellenmesi için yöntemlerin belirlenmesi gerekecektir.

8.6.2. Teknik Dönüşüm Katsayıları

Tarım değer zincirinde ürünler dönüşüm geçirir. Üretilen ürün ile işlenmiş ve tüketilen ürün aynı değildir. O nedenle ürünlerin arz zinciri içindeki hareketlerini ve değer artışlarını izleyebilmek için teknik dönüşüm katsayılarına ihtiyaç vardır. Bir üründen ne kadar üretildiği, ithal ve ihraç edildiği, ne kadarının yem ve tohum olarak kullanıldığı, ne kadarının israf ve kayıp edildiği ve sonuçta tüketildiğini gösteren ürün denge tabloları bu teknik dönüşüm katsayıları olmadan hesaplanamaz.

Teknik dönüşüm katsayıları için en önemli kaynak FAO tarafından geliştirilen Ana Ürün Ağacı (Commodity Tree) tablolarıdır (FAO, 1999). Şekil 10'da buğday için bir örneğini verdiğimiz ürün ağacı, her ürün için birincil üründen tüketilen ürüne kadar teknik dönüşüm dünya ortalamalarını ve aralıklarını vermektedir.

Şekil 10: Buğday için Teknik Dönüşüm Katsayıları



Kaynak: FAO (1999).

Teknik dönüşüm katsayıları, ürün cinslerine, yerel koşullara ve işleme teknolojisine göre ülkeler için farklılık gösterebilir. O nedenle FAOSTAT ürün denge tablosu

hesaplamalarında ülkeler için farklı katsayılar kullanılabilir. Ülkeler için kullanılan teknik katsayılar, Türkiye için Şekil 11 gösterildiği gibi, verilmektedir.¹¹

Şekil 11: Türkiye İçin FAOSTAT Tahıl Dönüşüm Katsayıları

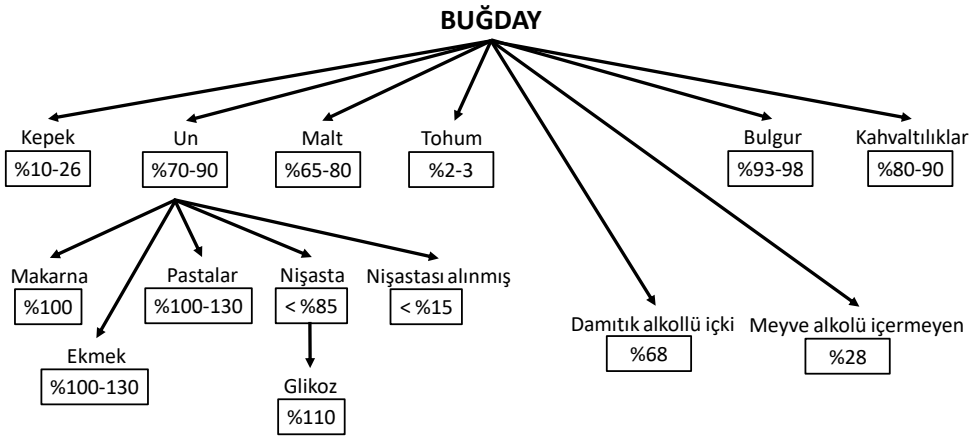
TURKEY			
CROPS AND DERIVED PRODUCTS			
	Seeding rates KG/HA	Extraction rates %	Waste of supply %
CEREALS			
Wheat	184		14
Flour of Wheat		78	
Bran of Wheat		10	
Germ of Wheat		2	
Rice, Paddy	166		3,8
Milled Paddy Rice		60	
Rice, Starch		85	
Bran of Rice		8	
Rice Flour		78	
Barley	200		14
Malt of Barley		80	
Maize	35		3,4
Germ of Maize		6	
Flour of Maize		80	
Bran of Maize		10	
Oil of Maize		46	
Cake of Maize		54	
Maize Gluten		13	
Starch of Maize		85	
Rye	185		14
Flour of Rye		86	
Bran of Rye		10	

Kaynak: FAO (1999).

TÜİK, 2003 yılında yaptığı çok değerli bir çalışma ile ürün denge tablolarında kullanılmak üzere, FAO'nun ana ürün ağaçlarını referans olarak Türkiye'de tarımsal ürünlerde teknik dönüşüm katsayılarını hesaplamış ve yayınlamıştır (DİE, 2003). Şekil 12'de örnek olarak buğday için Şekil 10'da verilen dünya ortalamaları ve Şekil 13'de Türkiye için hesaplanan dönüşüm katsayıları verilmektedir.

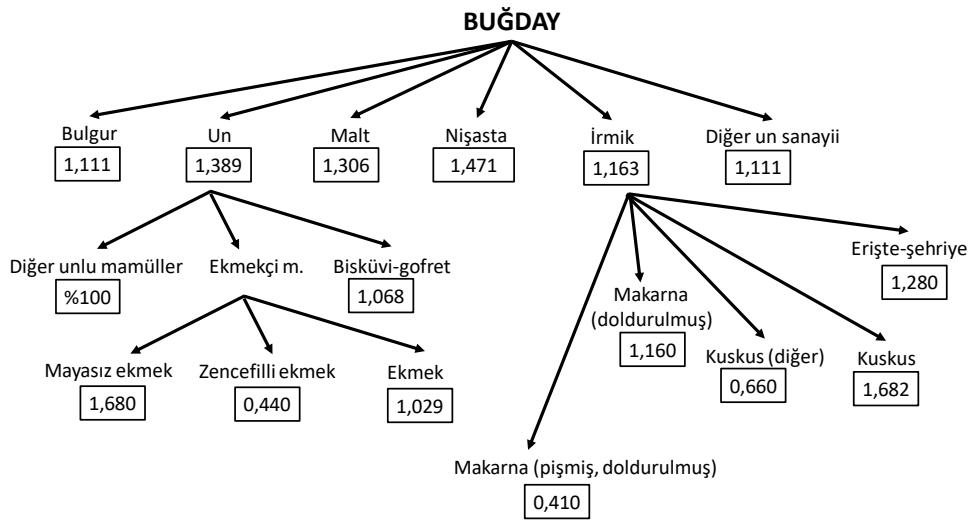
¹¹ Teknik dönüşüm tabloları, orijinal kaynaktaki görüntülerini göstermek için İngilizce bırakılmıştır. Şekil 12 ve 13'te bu tablolar Türkçe olarak verilmektedir.

Şekil 12. FAO Buğday Dönüşüm Aralıkları Ağacı



Kaynak: DİE (2003, s. XXXI)

Şekil 13: DİE Türkiye Buğday Dönüşüm Ağacı



Kaynak: DİE (2003, s.55)

Not: Bu şekilde dönüşüm katsayıları, işlenmişten işlenmemişe doğru verilmektedir. Başka bir deyişle bir birim işlenmiş ürün elde etmek için gerekli işlenmemiş ürün miktarı verilmektedir. Şekil 12 ile kıyaslamak için kutu içindeki verileri 1'e bölmek gerekiyor.

8.6.3. Besin İçerik Tablosu

Teknik dönüşüm katsayılarını kullanarak ürün denge tabloları¹² hazırlandıktan sonra beslenme ve gıda güvenliği hesaplamaları için gıda ürünleri için hesaplanan iç tüketim miktarlarının, içerdikleri besin maddeleri ile çarpılarak ve toplanarak, toplumun toplam besin tüketiminin bulunması, bunun da toplam besin gereksinimi ile kıyaslanması gerekmektedir. FAO kendi gıda güvenliği hesaplamalarında genelde tüm ülkeler için standart bir besin içeriği tablosu kullanmaktadır FAO (2022). Ancak, gıda ürünlerinin besin içerikleri, ürün, üretim, işleme, çevre, depolama ve beslenme farklılıkları nedenleriyle, ülkeden ülkeye ciddi farklılıklar gösterebilmektedir. Bu nedenle, gıda denge ve gıda güvenliği hesaplamalarında ülkelerin kendi besin içerik tablosunu kullanmalarında yarar vardır. Bu nedenle, FAO aynı zamanda INFOODS (International Network of Food Data Systems – Uluslararası Gıda Veri Sistemleri Ağı), isimli, ülkelerin kendi besin içerik tablolarını geliştirdikleri ve paylaştıkları bir ağı yönetmektedir. Türkiye de bu ağın bir parçasıdır ve TürKomp-Ulusal Gıda Kompozisyon Veri Tabanında 14 gıda grubunda, 645 gıda için, kalori, protein ve yağ da dahil, 100 gıda bileşeni değerlerini sunmaktadır (TürKomp, 2022). Tablo 8’de FAOSTAT’ta kullanılan ve TürKomp veri tabanında Türkiye için hesaplanmış değerlere örnek olarak seçilmiş buğday ürünleri için yan yana verilmektedir. Görüldüğü gibi Türkiye için FAO’nun kullandığı besin içerikleri ile TürKomp’un verileri arasında ciddi farklılıklar olabilmektedir.

Tablo 8: FAO ve TürKomp Örnek Besin İçerik Tablosu

BUĞDAY	Kalori <i>Kalori (100 gr)</i>	Protein <i>(mg/gr)</i>	Yağ <i>(mg/gr)</i>
KEPEK	213/315	121/143	31/6
EKMEK	249/276	82/94	12/32
KAHVALTILIK	389/381	74/81	7/39
BULGUR	345/349	123/88	20/21
UN	364/350	109/107	11/14
MAKARNA	367/356	120/84	11/19
PASTA	369/410	74/55	170/181
BUĞDAY	334/335	122/113	23/16
NİŞASTA	362/353	5/2	3/0

Not: Ürünler için verilen ilk sayılar FAO, ikincileri TürKomp verileridir.

Kaynak: FAO (2022), TürKomp (2022).

¹² Herhangi bir ürün için ürün dengesi: Tüketim=Üretim+İthalat-İhracat-Yem-Tohum-Kayıp-Gıda Dışı Endüstriyel Kullanım-Stok Artışı. TÜİK her yıl 63 bitkisel ürün için denge tablolarını hazırlamaktadır. Gıda Denge tabloları hazırlama metodolojisi için bkz FAO (2001, 2017).

Tablo 9: Tarımı İlgilendiren Başlıca Sınıflamalar

Konu	Kısaltma	İngilizce Adı	Türkçe Adı	Ev Sahibi
Ürün	CPC	<i>Central Product Classification</i>	Merkezi Ürün Sınıflaması	BM
Ürün	CPA	<i>Statistical Classification of Products by Activity</i>	Avrupa Birliğinde Faaliyete Göre Ürünlerin İstatistiki Sınıflaması	EUROSTAT
Tarım Ürünleri	CPCA	<i>CPC expanded for agricultural statistics:</i>	Tarım İstatistikleri İçin Genişletilmiş CPC	FAO
Tarım, Hay. Balıkçılık, Ürünleri	TAORBA	<i>National Classification of Agricultural, Livestock and Fishery Products</i>	Ulusal Tarım Hayvancılık ve Ormancılık Ürün Sınıflaması	TÜİK
İşgücü	ISCO	<i>International Standard Classification of Occupations</i>	Uluslararası Standart Meslek Sınıflaması	ILO
Toprak Kullanımı	ICLU	<i>Classification of land use (LU) for the agricultural census</i>	Tarım Sayımı için Arazi Kullanımı Sınıflaması	FAO
Arazi Örtüsü	CORINE	<i>Coordinated Information on the European Environment Classification</i>	Arazi Örtüsü Sınıflaması	EUROSTAT
Makine	ICAM	<i>Classification of machinery and equipment for the agricultural census</i>	Tarım Sayımı İçin Makine ve Teçhizat Sınıflaması	FAO
Hayvancılık	ICL	<i>Classification of livestock for the agricultural census</i>	Tarım sayımı İçin Hayvancılık Sınıflaması	FAO
Ekonomik Faaliyet	ISIC	<i>International Standard Industrial Classification of All Economic Activities</i>	Tüm Ekonomik Faaliyetlerin Standart Sanayi Sınıflaması	BM
Ekonomik Faaliyet	NACE	<i>Standard Classification of Economic Activities in the European Union</i>	Avrupa Topluluğunda Ekonomik Faaliyetlerin İstatistik Sınıflaması	EUROSTAT
Tüketim	COICOP	<i>Classification of Individual Consumption According to Purpose</i>	Amaca Göre Bireysel Tüketim Sınıflaması	BM
Ulusal Hesaplar	SNA	<i>System of National Accounts</i>	Ulusal Hesaplar Sistemi	BM
Dış Ticaret	HS	<i>Harmonized Commodity Description and Coding System</i>	Uyumlaştırılmış Mal Tanım ve Kod Sistemi	BM
Dış Ticaret	SITC	<i>Standard International Trade Classification</i>	Uluslararası Standart Ticaret Sınıflaması	BM
Dış Ticaret	GTIP	<i>Customs Tariff Statistical Positions</i>	Gümrük Tarife İstatistik Pozisyonu	Ticaret Bakanlığı
Dış Ticaret	CN	<i>Combined Nomenclature</i>	Birleştirilmiş Mal Sınıflaması	EUROSTAT
Bölge	IBBS	<i>Statistical Regional Units Classification</i>	İstatistiki Bölge Birimleri Sınıflaması	TC

Kaynak: UNSD (2022b), TÜİK (2022b)

8.7. TAR-İST’de Sınıflamalar Neden Önemli?

Ulusal istatistiklerde, uluslararası sınıflamaların kullanılması son derece önemlidir. Uzmanların uzun çalışmaları sonunda ortaya çıkan ve genelde UNSD (BM İstatistik Direktörlüğü) İstatistik Sınıflamalar Veri Tabanında bulunan bu sınıflamalar, bir taraftan farklı konudaki ulusal istatistikleri birbirine bağlarken, öte yandan ulusal istatistikleri, uluslararası istatistiklerle ilişkilendirir. Bazı durumlarda uluslararası sınıflamalar gerek kapsam gerekse ayrıntıda, ülke ihtiyaçlarına cevap vermeyebilir. Bu durumda ülkeler uluslararası sınıflamaların yapısını koruyarak, ulusal eklemeler yapabilirler. UNSD sınıflama veri tabanında 142 uluslararası ve 125 ülke için 474 ulusal sınıflama bulunmaktadır.

Tarım sektörü ve istatistikleri için ilgili birçok uluslararası ve ulusal sınıflama vardır. Bunlardan en yaygın kullanılanları Tablo 9’da gösterilmektedir (Gong, Kasnakoglu ve Som, 2007).

Uluslararası sınıflamalar değişen koşullar ve gelişmeler ışığında belirli aralıklarla güncellenirler. En önemlisi de güncellemeler ve değişik sınıflamalar arasındaki ilişkilendirme veya dönüşüm tablolarıdır. Özellikle ürün (CPC, CPA), dış ticaret (HS, SITC, CN) ve ekonomik faaliyet sınıflamalarındaki (ISIC, NACE) geçişler bütünleşik veri tabanları için çok önemlidir (UNSD, 2022c). TÜİK’in de gayet başarılı ve güncel bir Sınıflama Sunucusu bulunmaktadır (TÜİK, 2022b). Burada kullanılan ulusal ve uluslararası sınıflamalar, ev sahipleri, dönüşüm tabloları yanı sıra ilgili sözlükler ve tanımlar yer almaktadır (TÜİK 2022c ve 2022d).

8.8 TAR-İST’de Zaman Farklılıkları Nasıl Çözülüyor?

Tarım istatistiklerinin kullanımında özen gösterilmesi gereken konulardan birisi pek çok üründe girdi ve çıktılarının aynı zaman dilimi hatta yıl içerisinde olmamasıdır. Fiyat artışlarının yüksek olduğu durumlarda gerçekleşen üretim değeri, üretim maliyetinden sonra gerçekleştiğinden karlılık, katma değer hesaplarında yukarı doğru bir yanlılık oluşmaktadır.

TAR-İST’in en önemli özelliklerinden birisi fiyat ve miktar değerlerini ayırıştırmasıdır. Bu nedenle farklı zamanlarda gerçekleşen işlemlerin geçerli fiyatlarla değerlendirilmesi mümkün olmaktadır. Örneğin t zamanındaki üretim t zamanındaki fiyatlarla değerlendirilirken, t zamanında kullanılan girdiler t fiyatları ile, t-1 zamanında kullanılan girdiler ise t-1 fiyatları ile değerlendirilebilir veya tüm girdiler t fiyatları ile değerlendirilebilir. Bu esneklik TAR-İST’de tüm değerlendirmelerde kullanılabilir.

Bazı örnekler:

- Dünya fiyatları ile üretim ve maliyet değerlendirmesi
- Sabit/Politika fiyatlarla üretim, maliyet, kar, katma değer.

- Miktar ve değer olarak ürün dengeleri
- Miktar ve değer olarak girdi dengeleri

9. TAR-İST Kullanıcı Arayüzü

TAR-İST'in başarısı, içerdiği bilgilerin niteliği ve kalitesi kadar kullanım kolaylığına bağlı olacaktır. TAR-İST'in kullanıcı arayüzünün ayrıntıları bu çalışmanın boyutlarını çok aşmaktadır. O nedenle arayüzün ana hatlarını vermekle yetineceğiz.

TAR-İST sistemi iki temel bileşenden oluşmaktadır. Bunlardan birincisi alışageldiğimiz kaynak veri tabanları, ikincisi ise bu çalışmada önerdiğimiz çekirdek veri tabanı. Her iki veri tabanının da 4 temel boyutu var. Ürün, Gösterge, Mekan ve Zaman. Bu konuda, pivot tablo ve (açılır) kutular/menüler olmak üzere iki farklı arayüz kullanılabilir. İlk arayüz daha deneyimli çok sayıda veri kullanmak isteyen kullanıcı ve araştırmacılar, ikincisi ise daha genel, belirli bir veriye erişmek isteyen kullanıcılar için daha uygun olabilir. Kullanıcılara her iki arayüzü kullanma seçeneği de verilebilir.¹³

Tablo 10: Pivot Tablo Arayüz Yapısı

	Yıl→	2022	2022	2021	2021
Bölge ↓	Ürün→ Gösterge↓	+Buğday*	+Arpa		Buğday	Arpa
Türkiye	Üretim					
Türkiye	+Fiyat					
:	İhracat					
+IBBS1**	Üretim					
+IBBS1	+Fiyat					
:	İhracat					
+Diğer	Üretim					

* Değişkenle önündeki + İlgili değişkenin alt kırılımları olduğunu ve bu kırılımlardan da seçim yapılabileceği anlamına gelmektedir.

**İstatistik Bölge Birimleri Sınıflaması (İBBS) –Nomenclature of Territorial Units for Statistics (NUTS)

¹³ Pivot Tablo arayüzüne güzel örneklerden birisi OECD.Stat(2022) (<https://stats.oecd.org/>), açılır menü'lere iyi bir örnek FAOSTAT(2022) (<https://www.fao.org/faostat/en/#data/QCL>) veri tabanlarıdır. TÜİK de MEDAS veri tabanında (<https://biruni.tuik.gov.tr/medas/?locale=tr>) menü yöntemini kullanmaktadır, ancak çok da başarılı olduğu söylenemez (TÜİK, 2022h).

9.1. Pivot Tablosu

Pivot tablosu yapısına bir örnek Tablo 10’da verilmektedir. Burada sıralarda bölge ve göstergeler, sütunlarda ise ürün ve yıllar vardır. Kullanıcı Bölge/Gösterge/Ürün ve Yıl oklarına tıklayarak, bu boyutlarda istediği detayları seçebilecektir. Verinin yoğunluğuna ve arzu edilen tablo yapısına göre Bölge/Gösterge/Ürün/Yıl kolaylıkla yer değiştirebilir. Bu yapı, kaynak ve çekirdek veri tabanlarında değişmeyecektir. Tek farklılık gösterge vektörü değişkenleridir.

Kaynak ve çekirdek veri tabanları gösterge kırılımı farklılığı Tablo 11’de gösterilmektedir. Kaynak veri tabanlarında birinci düzey kırılımlar gösterge, ikinci düzey kırılımlar ürün/girdi, üçüncü düzey kırılımlar ise değişken düzeyindedir.

Çekirdek veri tabanında ise birinci düzey kırılımlar bütünleştirici dengeler, ikinci düzey kırılımlar denge değişkenleri, üçüncü düzey kırılımlar ürün ve dördüncü düzey kırılımlar değişken düzeyindedir.

Tablo 11: Kaynak ve Çekirdek Veri Tabanları Gösterge Kırılımları

Kaynak Veri Tabanları	Çekirdek Veri Tabanı
+Üretim	Katma Değer
Fiyatlar	Üretim Değeri
Ürün Fiyatları	Üretim
Üretici Fiyatı	Üretici Fiyatı
Toptan Fiyatı	Maliyet
Tüketici Fiyatı	İşgücü Maliyeti
İhraç Fiyatı	İşgücü Kullanımı
İthal Fiyatı	İşgücü Ücreti
Girdi Fiyatları	Toprak Maliyeti
Gübre Fiyatı	Toprak Kullanımı
Toprak Kirası	Toprak Rantı
Ücret	;
Traktör Kirası	;
Su Ücreti	Ürün Dengesi
Girdi Kullanımı	Üretim
+Toprak	Eş Değer İhracat
+İşgücü	Eş Değer İthalat
+Gübre	;
:	;
+İhracat	Tüketim
+İthalat	Dış Ticaret Dengesi
+Çevre	+İhracat
+Politika Göstergeler	+İthalat
;	;
;	;
;	;

*Not: Değişkenle önündeki + İlgili değişkenin alt kırılımları olduğunu ve bu kırılımlardan da seçim yapılabileceği anlamına gelmektedir.

Tablo 12’de kullanıcının çekirdek veri tabanı ile çalışmak istediği varsayımıyla olası menü yapısı gösterilmektedir. İkinci ve üçüncü kutular mekansal ve zamansal ayrıntı menülerini göstermektedir. Büyük olasılıkla TAR-İST’in kuruluş aşamalarında bu kutulardaki kullanılabilir seçenekler çok sınırlı olacak, zaman içinde artacaktır. Dördüncü kutu, ürün seçimi menüsüdür. Kullanıcı tüm ürünleri seçebileceği gibi, belirli grup ürünleri veya belli bir ürünü seçebilecektir. Beşinci kutu, seçilen ürün, bölge ve yıl için hangi göstergelerin görülmek istediği menüdür. Buradaki seçenekler, girdi kullanımı, üretim, tüketim, dış ticaret ve fiyatlar gibi ana başlıklar ve bunların alt başlıkları ve ayrıntılı kalemleridir. Altıncı kutu kullanıcılara, çekirdek veri tabanına özel bütünleştirici denge denklemlerini/tablolarnı istenilen mekan, yıl ve ürün/girdi veya grupları için elde etme olanağı vermektedir.

Menülü arayüzlerde kullanıcıları en çok kızdıran durum, farklı menülerden seçim yaptıktan sonra, seçilen kriterlerde veri olmadığı mesajıdır. Bu durumlara meydan vermemek için menülerin herhangi birisinde yapılan bir seçime göre diğer menülerin seçim seçeneklerinin gerekiyorsa kapatılması, sınırlandırılması veya belirlenmesinin önceden programlanmış olması gerekmektedir. Örneğin, çekirdek veri tabanı yalnız 2021 yılı ve Türkiye için yapılmışsa, bölge ayrıntısı ve 2021 dışında yıl seçilmesine arayüz izin vermemelidir. Aynı şekilde ürün olarak pamuk seçilmiş ise denge seçenekleri arasında gıda dengesi olmamalı veya gıda dengesi seçilmiş ise ürün seçenekleri arasında pamuk olmamalıdır.

Tablo12. Açılır Kutular/Menü Arayüz Yapısı


TAR-İST Sistemi	Mekan	Yıl
<ul style="list-style-type: none"> ○ Kaynak Veri Tabanları ○ Çekirdek Veri Tabanı ○ Tüm Veri Tabanları 	<ul style="list-style-type: none"> ○ Türkiye <ul style="list-style-type: none"> ○ +IBBS1 ○ +IBBS2 : 	<ul style="list-style-type: none"> ○ 2022 ○ 2021 ○ : ○ :
Ürün	Gösterge	Denge
<ul style="list-style-type: none"> ○ +Tahıllar ○ +Buğday ○ Durum ○ Ekmeklik ○ +Arpa ○ : ○ +Sebzeler 	<ul style="list-style-type: none"> ○ Üretim ○ +Girdi <ul style="list-style-type: none"> +Toprak +Gübre <ul style="list-style-type: none"> ○ N ○ P ○ K : + Dış Ticaret + Fiyat ○ Tüketim <ul style="list-style-type: none"> + Besin 	<ul style="list-style-type: none"> ○ Ürün Denge ○ Katma Değer ○ Girdi Denge ○ Dış Ticaret ○ Gıda Denge ○ Girdi-Çıktı

9.2. Toplulaştırma, Görsellik, Tablo Formatı, vb.

Bir veri tabanının kalitesi, içerdiği bilgilerin doğruluğu, güvenilirliği, tutarlılığı ve güncelliği yanı sıra kolay ve hızlı erişim sağlanması ile ölçüldüğünü vurgulamıştık. Bu çalışmada, daha çok veri tabanının içeriğini geliştirme üzerine öneriler getirmeye çalıştık. İçerdiği bilgilere erişim konusuna ise, yukarıda yine yapısal olarak değindik. Oysa veri tabanlarının içerdiği bilgiler ve erişim yanı sıra kullanıcıya sağladığı kolaylıklar da önemlidir. Bunlar, içerilen bilgilerden elde edilecek istatistikler (ortalama, varyans, vb.), göstergeler (oran, reel, vb.) ve toplulaştırmalar (bölge, ürün grubu, sektör vb.) ile görsel sunumlardır (tablo, şekil, grafik vb.). Büyük çoğunlukla da veri tabanlarının kalitesini artırma çabaları içeriğini geliştirmekten çok, görsel sunumun çekiciliğini artırmak ile sınırlı kalmaktadır.

Bir örnek vermek gerekirse TÜİK sitesinde, ana sayfada, Şekil 14’de görülen, son yıllarda çok moda olan Tematik Haritalar/Coğrafi Bilgi Sistemleri (CBS) diye bir Türkiye haritası bulunmaktadır. Bu haritada belirli göstergelere göre iller renklendirilmektedir. Son birkaç yıldır değişmeyen bu haritada, Tarım ve Hayvancılık seçilince illeri renklendirmek üzere 5 adet gösterge bulunmaktadır. Bunlar 2019 yılı için tarım alanı, örtülü tarım alanı, yumurta tavuğu sayısı, süzme bal fiyatı ve canlı hayvan değeridir. Süzme bal fiyatı seçildiğinde de Şekil 14’de olduğu gibi tüm sayfayı kaplayan bir harita çıkmaktadır.¹⁴

Şekil 14. TÜİK Tematik Haritalar/Coğrafi Bilgi Sistemi Örnek Harita.



Kaynak: TÜİK (2022a).

¹⁴ Muhtemelen bu haritalar CBS’nin neler yapabileceğini göstermek ve yöneticileri etkilemek için bir zamanlar TÜİK sayfasına konulmuş ancak daha sonra güncellenmeden orada unutulmuştur.

Veri Tabanlarında sunumun önemini bir kez daha vurgulayıp ancak bu çalışmanın ana konusu olmadığını vurguladıktan sonra toplulaştırma konusuna tekrar dönelim. Kullanıcılar istatistik veri tabanlarından bazen ayrıntılı bilgi talep ederken, bazen de toplulaştırılmış bilgi talep ederler. Verinin mikro düzeyde, elde edilmiş biçimiyle verilmesi, istatistikte kişisel verilerin gizliliği ilkesine aykırı düşmenin yanı sıra kullanıcıların büyük çoğunluğu için gereksiz detay oluşturur.¹⁵ O nedenle veriler sunulurken, bazı verilerin toplulaştırılmış olarak(da) verilmesine, bazılarının gerçek zamanlı toplulaştırılmasına olanak sağlanmasına, bazılarının toplulaştırılmasını ise kullanıcının kendi imkanları ile yapmasına bırakmak seçenekleri söz konusudur. Toplulaştırma veri tabanlarını en zor konularından birisidir. Bunun iki temel nedeni vardır. İlki toplulaştırılacak verilerdeki eksik, boşluk ve hatalar, ikincisi ise benzemezlerin toplanması ve bu amaçla kullanılacak ağırlıkların belirlenmesidir. TAR-İST çekirdek veri tabanı verilerinde boşluk olmaması, verilerin tutarlıklarının test edilmiş olması ve miktarları ağırlandıracak değişik fiyat, besin değeri vb. ağırlık unsurlarını barındırması ile toplulaştırmayı görece olarak kolaylaştırmaktadır. O nedenle çok kullanılan ürün, girdi bölge ve zaman grupları gibi toplulaştırmalar önceden yapıp menü seçenekleri arasına konulabilir.¹⁶ Çok özel gruplamalar ise kullanıcıya bırakılabilir. Gerçek zamanlı toplulaştırmalardan mümkün olduğu kadar kaçınmakta yarar olduğunu düşünüyorum.

10. TAR-İST Yönetimi

TAR-İST'in geliştirilmesi, içinin doldurulması, kullanıma sunulması, güncellenmesi ve sürekliliğinin sağlanması ancak bu konuya kaynak ayırabilecek, kurumsal bir yapının içinde gerçekleşebilir. TAR-İST'i destekleyecek, ve derlenmeleri maliyetli olan verilerin büyük bir kısmı TÜİK ve TOB tarafından zaten derleniyor olacağından gerekecek ek maliyet daha çok var olan verileri bir çatı altında toplama, kavramsal yapının kurulması, veri tabanının kullanıma sunulması gibi gerekli yazılımlar, eksik verileri tamamlanması, boşlukların doldurulması, verilerin tutarlılığının sağlanması gibi konularda uzman girdisi ve TAR-İST'in geliştirilmesi için AR-GE faaliyetleri biçiminde olacaktır. TAR-İST'e ev sahipliği yapabilecek kurumlar, yazarın tercih sırasına göre, şunlar olabilir:

1. TOB (Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü, Strateji Geliştirme Başkanlığı-Yönetim Bilgi Sistemleri ve İstatistik Dairesi)
2. TÜİK (Tarım İstatistikleri Dairesi)

¹⁵ Burada doğal olarak araştırma amaçlı mikro veriye erişmenin öneminden bahsetmiyoruz. Genel olarak kamuya açık verilerden söz ediyoruz.

¹⁶ Burada sorun yaratabilecek bir konu çekirdek veri tabanında boşlukların doldurulmuş, tutarsızlıkların giderilmiş verileri ile yapılacak toplulaştırmaların, daha az işlenmiş veri içeren kaynak veri tabanlarındaki toplamlarla farklılık göstermesidir. Bu iki veri tabanını eşlemek önemli ancak ayrı bir çalışma konusudur.

3. Tarımla İlgili Sivil Toplum Kuruluşları (Oda, Birlik, Dernek)
4. Üniversite Araştırma Merkezleri
5. Diğer (Vakıf, Araştırma, Danışmanlık) Kurumlar

TAR-İST'in tarım ile ilgili kurum olan TOB'un ev sahipliğinde ve verilerin büyük çođunu veri tabanlarında bulunduran TÜİK ile işbirliđi içinde geliştirilmesi ve kullanıma sunulması en dođalıdır. Öncelikler, finansal ve işgücü kaynakları, verilere yakınlık, kullanıcılara yakınlık gibi faktörler nedeniyle ev sahipliđi bu iki kurum arasında yer deđiştirebilir.

Ancak, geçmişte olduđu gibi, bu kurumların bu konuya sahip çıkmaması durumunda, tarımla ilgili sivil toplum kuruluşlarından, kâr amacı gütmeyen üniversite, vakıf, merkezlere ve hatta TAR-İST ile yaratılacak katma deđeri ticari amaçla kullanacak özel teşebbüslere varan bir yönetim seçeneđi söz konusu olabilecektir.

Özellikle uluslararası verilerin, yeniden paketlenerek, göstergeler oluşturarak, türev veriler türeterek ve kullanıcı faydası sağlayarak ücret karşılıđı sunumların birçok örneđi vardır. Bazı örnekler verelim:

OECD: Tüm OECD istatistiklerine, istenilen formatlarda, dinamik etkileşimli erişim, pdf formatında istatistik yıllıklara, yayınlara ve onların tablolarına XLS, PDF ve WEB/HTML formatlarında erişim için paket satmaktadır (OECD, 2022).

GTAP (Global Trade Analysis Project): Purdue Üniversitesi bulunan bu konsorsiyum Genel Denge Modelleri ve Uluslararası Ticaret modelleri ülke verilerinden oluşan veri tabanına ücretli erişim üyeliđi satmaktadır (GTAP, 2022).

COMTRADE: BM ülkelerden derlediđi dış ticaret veri tabanına erişim ve yoğun veri taleplerinde yardım için yıllık kişi ve kurumlara göre farklılaştırılmış üyelik satmaktadır (SHOP.UN.ORG, 2022).

ITC (International Trade Center), dış ticaret veri tabanı ve analiz araçlarına tam erişimi ücretli olarak sağlamaktadır (ITC, 2022).

IFASTAT: Uluslararası Gübre Derneđi, ayrıntılı gübre üretim, arz, ticaret ve piyasaları istatistiklerine erişimi üyeler için kısıtlamaktadır (IFASTAT, 2022).

Bu örnekleri vermemizin nedeni, TAR-İST'in ticari bir ürün olmasını tercih ettiđimizden deđil, ikinci el bile olsa düzgün derlenmiş, düzgün sunulmuş verilerin uluslararası piyasalarda kullanıcılarının çok da düşük olmayan ücret ödemeye hazır olduđu bir piyasası olduđunu vurgulamaktır.

11. Sonuç

Bu çalışma ilk 5 bölümünde, Türkiye’de tarım istatistiklerinin yapısı, durumu ve sunucuları üzerine kısa bir değerlendirme yapılmış, daha sonra yazar ve kullanıcı akademisyenler gözünden kalite değerlendirmesi yapılmıştır. Kalite değerlendirmesi ilgililik, kapsayıcılık, tutarlık, güncellik, güvenilirlik, erişilebilirlik olmak üzere 6 kalite göstergesi, ve girdi, üretim, fiyat, dış ticaret, üretici refahı, tüketici refahı, tarım politikaları, tarımsal yapı olmak üzere 8 tarım istatistiği alt grubu bazında yapılmıştır. Akademisyenler arasında konulara ve kalite göstergelerine göre hem benzerlikler hem de farklılıklar vardır. Hem yazar hem de akademisyenler en kaliteli istatistiklerin dış ticaret istatistikleri, en düşük kalitenin ise, akademisyenler üretici ve tüketici refah göstergelerinde, yazar ise tarımsal yapı ve tüketici refahı istatistiklerinde olduğunu düşünmekte. Ortalama notlar genelde 10 üzerinden 4-6 arasında, iyi-kötü sınırında ve iyileştirmelere yer olduğu yönündedir. Bu grubun son bölümü, Türkiye’de tarım istatistiklerinin sorunlarına ayrılmıştır. Bu genel değerlendirme şu gözlemlerle sonuçlanmıştır:

Türkiye’de, istatistik kurumlarında tarım, tarım kurumlarında istatistik ihmal edilmelerine ve de tüm eksikliklerine rağmen, tarım istatistikleri görece olarak en kaliteli istatistiklerdir. Özellikle TÜİK’de topluca bulunabilen, oldukça zengin bir veri kaynağı, uluslararası düzeyde kapsam ve kaliteye sahiptir. Özetle oldukça kaliteli ve bol malzeme var, iyi bir helva yok. Bu dünyada da böyle. Türkiye tarım istatistikleri çok daha iyi ve dünya için bir örnek olabilir.

6. ve 7. bölümlerde, **TAR-İST** adı verilen bütünleşik bir tarım istatistikleri sistemi önerilmektedir. Bu sistem, üretim, girdiler, fiyatlar, dış ticaret gibi ayrıntılı istatistiklerin yer aldığı, kendi içlerinde oldukça bütünleşik ancak birbiri ile bağlantısı zayıf halkalardan oluşan kaynak veri tabanları ve ürün arzı, girdi kullanımı, katma değer, değer zinciri, girdi-çıkıtı tablosu gibi bütünleştirici kavramsal yapılarla hem veri grupları içlerinde hem de grup aralarında bütünleşmiş bir **çekirdek** veri tabanından oluşmaktadır. 8. bölümde TAR-İST’e dair akla gelebilecek sorularla, daha önceki iki bölümde ilgiyi dağıtmamak için girilmeyen ayrıntılara yine özet olarak girilmektedir. Bunlar arasında, sınıflamalar, dönüşüm tabloları, eksik/hatalı veriler, ayrıntı düzeyi, veri zamanlaması ve kapsam gibi kavramlar sayılabilir.

9. bölümde TAR-İST kullanıcı arayüz yapılarına ilişkin öneriler sunulmaktadır. Bu amaçla kaynak ve çekirdek veri tabanı arayüzlerinin pivot-tablo ve menü seçenekleri ile sunulmaları durumundaki olası yapıları özetlenmektedir. Bu bölümde son olarak veri tabanlarında çok önemli olan ancak bu çalışmada ele alınmayan, görsellik ve toplulaştırılmış verilerin sunumu ile ilgili düşüncelerimiz paylaşılmıştır.

TAR-İST’in geliştirilmesi, içinin doldurulması, kullanıma sunulması, güncellenmesi ve sürekliliğinin sağlanması ancak bu konuya kaynak ayırabilecek, kurumsal bir yapının

içinde gerçekleştirilebilir. 10. ve son bölümde, TAR-İST yönetimi gündeme getirilmektedir. TAR-İST'in tarım ile ilgili kurum olan Tarım ve Orman Bakanlığı'nın ev sahipliğinde ve verilerin büyük çoğunluğu veri tabanlarında bulunduran TÜİK ile işbirliği içinde geliştirilmesi ve kullanıma sunulması en doğaldır. Öncelikler, finansal ve işgücü kaynakları, verilere yakınlık, kullanıcılara yakınlık gibi faktörler nedeniyle ev sahipliği bu iki kurum arasında yer değiştirebilir. Ancak, geçmişte olduğu gibi, bu kurumların bu konuya sahip çıkmaması durumunda, tarımla ilgili sivil toplum kuruluşlarından, kâr amacı gütmeyen üniversite, vakıf, merkezlere ve hatta TAR-İST ile yaratılacak katma değeri ticari amaçla kullanacak özel teşebbüslere varan bir yönetim seçeneği söz konusu olabilecektir.

Kaynakça

- D'Orazio, H. ve Gennari, P. (2020). A proposal for a national quality assurance framework. 28th Session of Asia and Pacific Commission on Agricultural Statistics, Bali, Indonesia, 10-14 February. <https://www.fao.org/3/cb3339en/cb3339en.pdf>
- DİE (2003). *Tarımsal Ürünlerde Teknik Dönüşüm Katsayıları ve Ürün Denge Tabloları 1989, 1995*, Ankara.
- EUROSTAT (2022) *Quality Assurance Framework of the European Statistical System, V2.0*. <https://ec.europa.eu/eurostat/documents/64157/4392716/ESS-QAF-V2.0-final.pdf>
- FAO (1999). *Technical Conversion Factors for Agricultural Commodities*. Rome. <http://www.fao.org/fileadmin/templates/ess/documents/methodology/tcf.pdf>
- FAO (2001). *Food Balance Sheets: A Handbook*. Rome. <https://www.fao.org/3/X9892E/X9892E00.htm>
- FAO (2014). *FAO Statistical Data Quality Framework: A Multi Layered Approach to Monitoring and Assessment*. <http://www.bubbavision.com/intersect/Sector%20material/Agriculture/1-FAO.pdf>
- FAO (2017). *Guidelines for Compilation of Food Balance Sheets*. Rome. <https://www.fao.org/3/ca6404en/ca6404en.pdf>
- FAO (2018). *Statistics Quality Assurance Framework (FAO-SQAF): The Quality Assurance Mechanism*. Rome, December. https://unstats.un.org/unsd/methodology/dataquality/references/FAO_Quality_Assurance_Mechanism.pdf

- FAO (2022). *Nutritive Factors*, ESS. <https://www.fao.org/economic/the-statistics-division-ess/publications-studies/publications/nutritive-factors/en/>
- FAOSTAT (2022). (<https://www.fao.org/faostat/en/#data/QCL>).
- Gong, X., Kasnakoglu, H. ve Som, H. (2007). Contribution to International Classification of Agricultural Statistics, *ICAS-4*, Beijing China, 22 October <http://slideplayer.com/slide/7230097/>
- GTAP (2022). <https://www.gtap.agecon.purdue.edu/products/packages.asp>
- IFSTAT (2022). <https://www.ifastat.org/market-outlooks>
- IMF (2003), *Data Quality Assessment Framework and Data Quality Program (SQAQF)* <https://www.imf.org/external/np/sta/dsbb/2003/eng/dqaf.htm>
- ITC (2022). *Market Analysis Tools Account*. <https://mas-admin.tools.intracen.org/accounts/OptionsFees.aspx>
- Kasnakoglu, H. ve Mayo, R. (2003). FAOSTAT2 Project and CountryStat, *Statistics in Transition*, 6(2), 207-218.
- Kasnakoglu, H. ve Mayo, R. (2004). FAO statistical data quality framework: a multi-layered approach to monitoring and assessment. *Conference on Data Quality for International Organizations*, Weisbaden, Germany, 27-28 May.
- Kasnakoglu, H. (2004). New challenges in agricultural statistics. Keynote Speech, *MEXAI, Third International Conference on Agricultural Statistics*, 2-4 November, Cancun Mexico. <https://www.nass.usda.gov/mexsai/presentations/newchallenges.ppt>
- Kasnakoglu, H. (2006). FAOSTAT and CountrySTAT: Integrated global and national food and agriculture statistical databases. *Proceedings of the XLIII Scientific Meeting, Societa Italiana di Statistica*, Universita di Torino, 14-16 June, 183-194.
- Kasnakoglu, H. (2009). Usefulness, feasibility, limitations and sustainability of an international database on agricultural statistics. Presentation at the *Integrated Assessment of Agriculture and Sustainable Development (AGSAP) Conference*, Edmond aan Zee, The Netherland, 10-12 March. https://www.academia.edu/30104103/Usefulness_Feasibility_Limitations_and_Sustainability_of_an_Integrated_International_Database_on_Agricultural_Statistics
- Kasnakoglu, H. (2021). Dünya tarımına yön verenler: Uluslararası örgütler, *TEK 21. Ulusal İktisat Kongresi*, Eskişehir, 5-7 Kasım.

Kasnakoğlu, H. (2022). Evidence based policy making in agriculture: data and tool requirements. APART Project Working Paper, World Bank, 6 March.

OECD (2011). *Quality Framework and Guidelines for OECD Statistical Activities (OECD-QFGSA)*.

<http://www.oecd.org/std/qualityframeworkforoecdstatisticalactivities.htm>

OECD (2022). *iLibrary, Subscription Products*, <https://www.oecd-ilibrary.org/oecd/purchasing/subscriptionproducts>

OECD.Stat(2022). <https://stats.oecd.org/>

SHOP.UN.ORG (2022). *UN Comtrade*. <https://shop.un.org/comtrade>

TÜİK (2022a). *Coğrafi İstatistik Portalı*. <https://cip.tuik.gov.tr/?il=6#>

TÜİK (2022b). *Sınıflama Sunucusu*.

<https://biruni.tuik.gov.tr/DIESS/ChangeLocaleAction.do?dil=tr>

TÜİK (2022c) *Sınıflama Sunucusu/Sınıflamalar*

<https://biruni.tuik.gov.tr/DIESS/SiniflamaTurListeAction.do>

TÜİK (2022d). *Sınıflama Sunucusu, Dönüşüm Tabloları*.

<https://biruni.tuik.gov.tr/DIESS/DonusumTablosuListeleAction.do?guncel=Y>

TÜİK (2022e). *Resmi İstatistik Portalı/Kalite*.

<https://www.resmiistatistik.gov.tr/detail/kalite/>

TÜİK (2022f). *Resmi İstatistik/Metaveri Şablonu*.

(<https://www.resmiistatistik.gov.tr/detail/kalite/>)

TÜİK (2022g). *İstatistik Veri Portalı, Tarım İstatistikleri/Metaveri*.

<https://data.tuik.gov.tr/Kategori/GetKategori?p=Tarim-111>

TÜİK (2022h). *MEDAS Veri tabanı*. <https://biruni.tuik.gov.tr/medas/?locale=tr>

TürKomp (2022). *Ulusal Gıda Kompozisyon Veri Tabanı*, Gıda ve Yem Kontrol Merkez Araştırma Enstitüsü Müdürlüğü. <http://www.turkomp.gov.tr/database>

UNSD (2015). *Generic Statistical Quality Assurance Framework for a UN*

Agency(GSQAF). <https://unstats.un.org/unsd/unsystem/Documents-Sept2015/GSQAF-GenericData-Sept2015.pdf>

UNSD (2019), *National Quality Assurance Frameworks Manual for Official Statistics (UN-NQAF)*.

<https://unstats.un.org/unsd/methodology/dataquality/references/1902216-UNNQAFManual-WEB.pdf>

UNSD (2022a). *Principles Governing International Statistical Activities*. CCSA.
https://unstats.un.org/unsd/ccsa/principles_stat_activities/

UNSD (2022b). *Statistical Classifications Portal*.
<https://unstats.un.org/unsd/classifications/>

UNSD (2022c) *Statistical Classification/Correspondence Tables*
<https://unstats.un.org/unsd/classifications/Econ#Correspondences>,

Verhoog, D., Heiden, M., Salamon, P. Dol, W. ve Godeschalk, F. (2008). *Potentials of a Harmonised Database for Agricultural Market Modelling*. European Commission Joint Research Centre Institute for Prospective Technological Studies, Seville.

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.

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.² Genel olarak

² “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.³ 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

³ 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 İstatistikin 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.⁴ 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

⁴ 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.⁵ 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).

⁵ 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. Bayesçi bir yaklaşım öneren Leamer istatistiksel çıkarımların öznel olduğunun altını çizmektedir.⁶ 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,

⁶ 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.⁷ 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.⁸ 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

⁷ Böylece hile (“con”) ekonometriden “çıkartılmıştır”.

⁸ 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 kümeler ayrılması veya boyut küçültme sayılabilir. Temel bileşenler analizi (PCA, *principal components analysis*), K-ortalamalar kümelemesi ve hiyerarşik kümeleme bu alanda kullanılan başlıca yöntemler arasındadır.⁹

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

⁹ Bu bölümde ağırlıklı olarak gözetimli öğrenme problemleri gözden geçirilecektir.

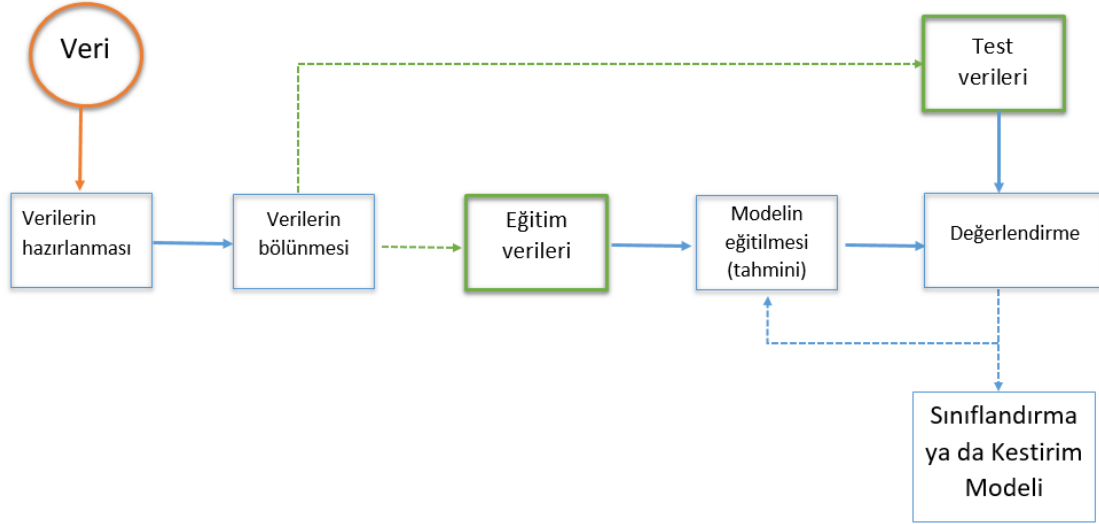
ve etkin tahmini mümkündür. Ancak OLS yöntemi değişken sayısı p 'nin çok büyük olduğu durumlarda işe yaramayabilir. Öyle ki kestirim değişkenlerinin gözlem sayısından fazla olduğu çok boyutlu problemlerde kullanılamaz. Makine öğrenmesinin üstün olduğu yanlardan biri kestirim değişkenlerinin seçimindeki 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 özneteliğini¹⁰ 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.

¹⁰ Bu öznetelikler 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

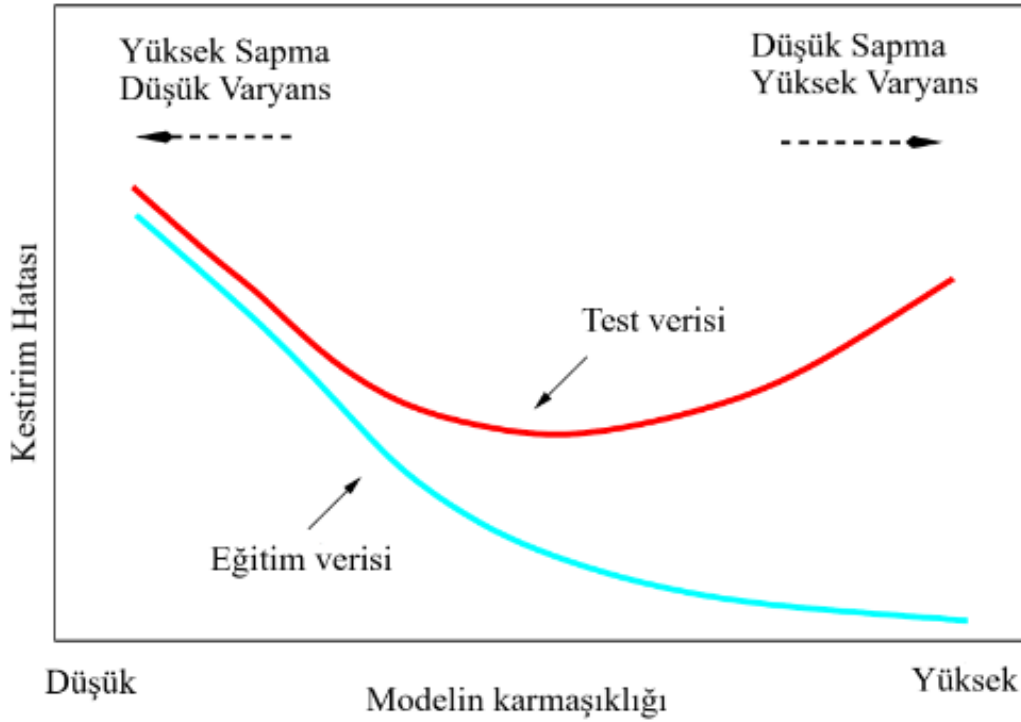
3.1 Kestirim Başarısının Ölçümü

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 seçilmiş¹¹ %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.

¹¹ 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):

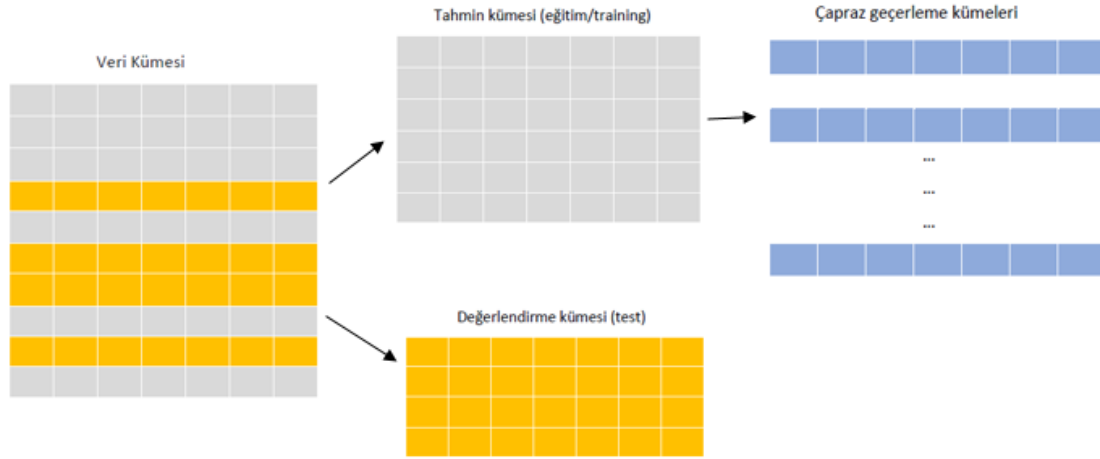
$$\text{MSE} = \text{Kestirim Varyansı} + \text{Sapma Kare} + \text{İndirgenemez Hata Varyansı}$$

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

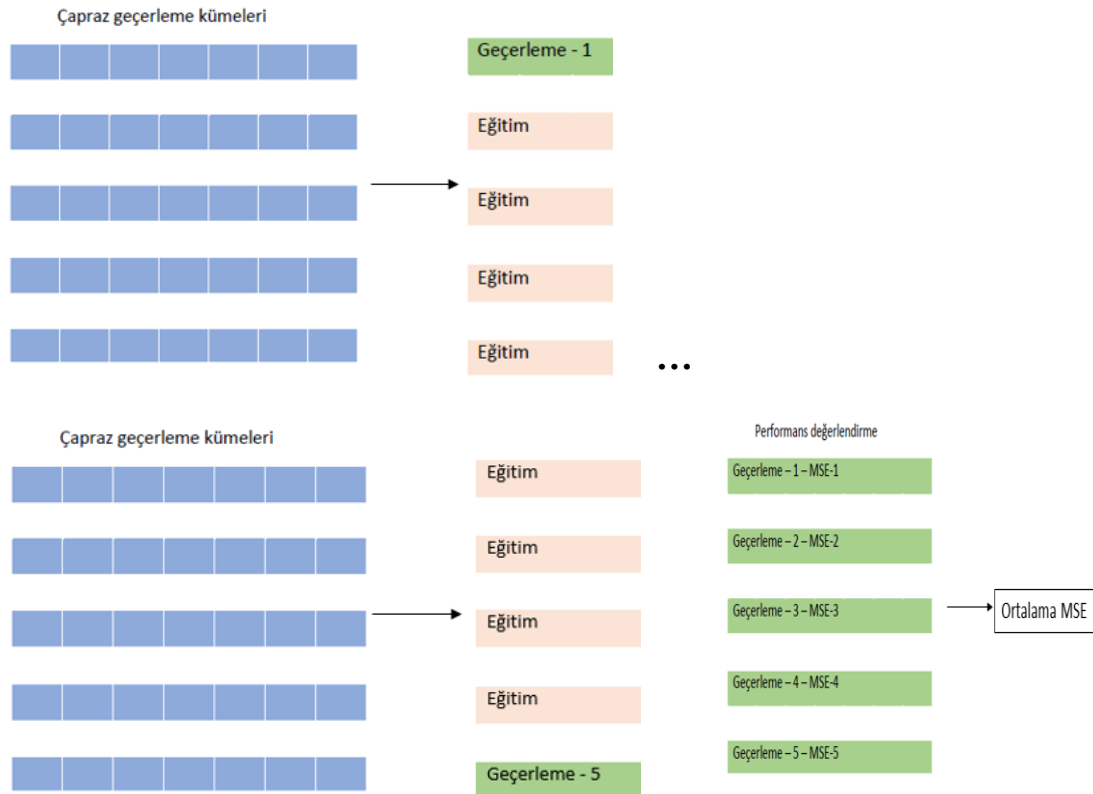
(*random forest*) deęişken sayısı, takviye (*boosting*) yönteminde öğrenme hızı ve iterasyon sayısı verilebilir.

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-geçleme” (*cross-validation*) yöntemidir.¹² Çapraz-geçleme yönteminde eğitim kümesi rassal olarak alt örneklemelere (ya da gruplara/katlara) ayrılarak eğitim ve geçleme hesaplamaları ayrı ayrı yapılır (Şekil 1). Biri hariç çapraz geçlemede, eğitim kümesindeki gözlemlerden biri geçleme 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-geçleme uygulanabilir. Bu yaklaşımda eğitim örnekleme rassal olarak k gruba ayrılır (verilerin türdeş ve bağımsız dağıldığını varsayıyoruz) ve sırasıyla her grup geçleme kümesi olarak kullanılarak kestirim performansı ölçülür. Sonunda k geçleme hata ölçütünün ortalaması alınarak test performansı tahmin edilir. Her bir ayarlanma parametresi için bu hesaplamalar tekrarlanarak en düşük çapraz geçleme 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 düzenleştirme (*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).

¹² 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 λ 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 β parametreleri ayarlanma parametresine bağlı olarak sifıra 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 α sıfır ile bir arasında bir sabittir. $\alpha = 0$ olduğunda ridge regresyonu, $\alpha = 1$ durumunda ise LASSO elde edilir. Pratikte α çapraz-geçerleme yaklaşımı ile tahmin edilebilir.

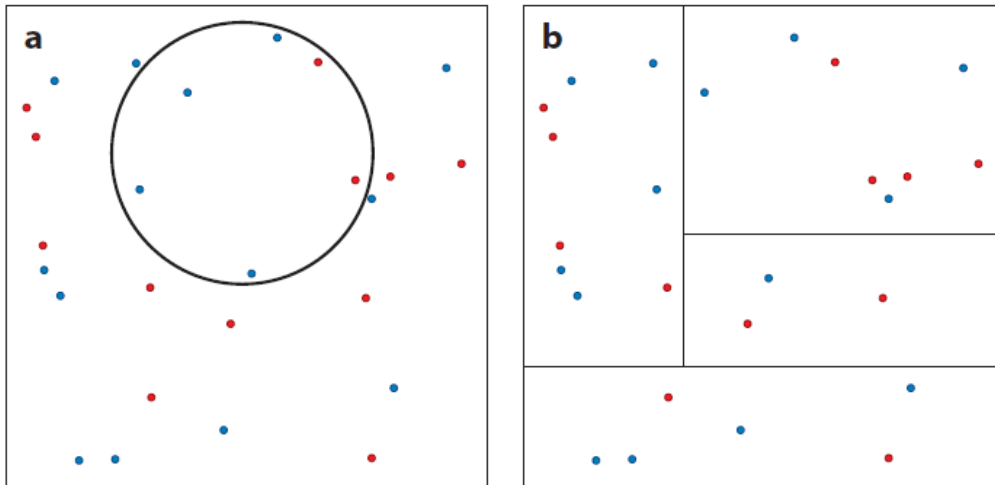
Makine öğrenmesi algoritmaları ile eğittiğimiz modelden hareketle istatistiksel çıkarsama yapabilir miyiz? Daha genel olarak tahmin edilen model yapısal veri üretim süreci olarak yorumlanabilir mi? Her iki soruya da hayır cevabı verilebilir. İstatistiksel çıkarsama yapmak için gerekli olan standart hataların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

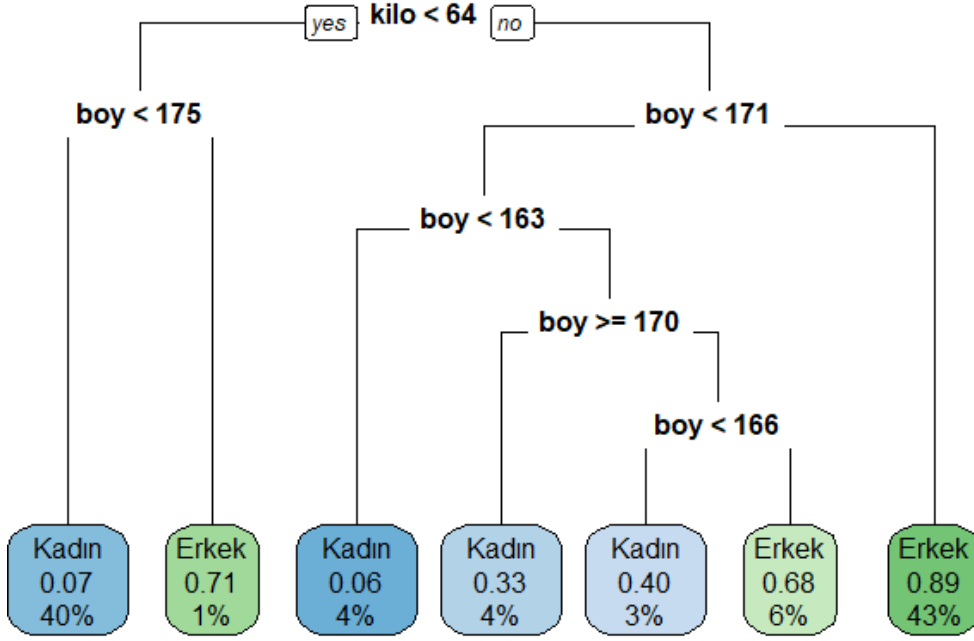
Ağaç bazlı yaklaşım ile (kernel) regresyonu komşuluk tanımları üzerinden karşılaştırılabilir (bkz. Şekil 2, Athey ve Imbens, 2019). Kernel regresyonunda (a) bir hedef gözlemin çevresindeki Euclid uzaklığı temel alınırken ağaç yöntemlerinde (b) komşuluklar dikdörtgenlerle tanımlanır. Yeni bir gözlem için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

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

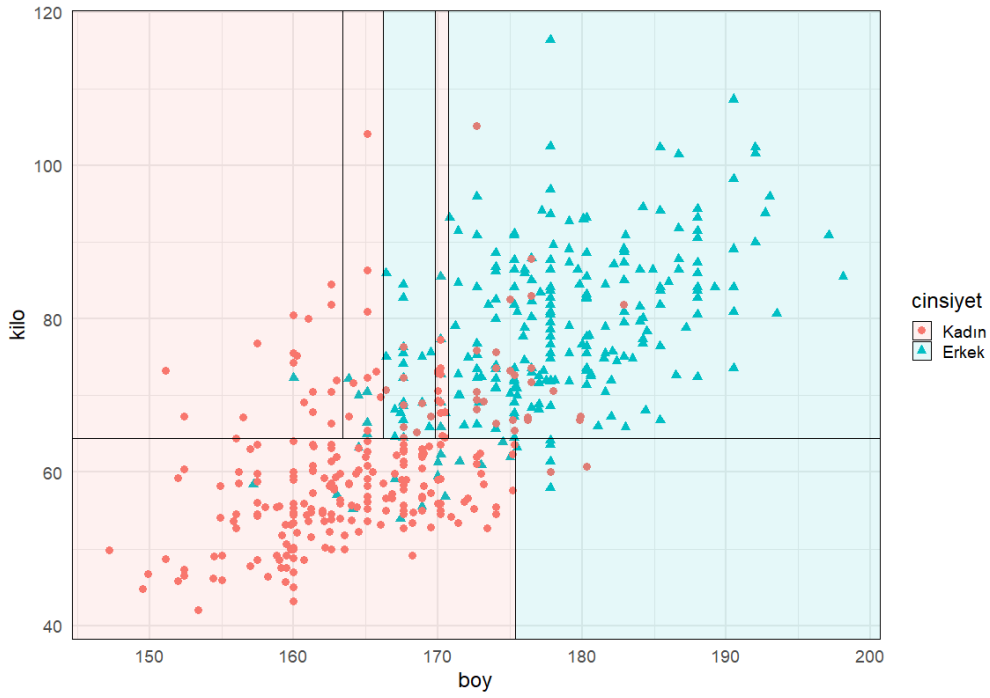


Sınıflandırma ağaçlarında da benzer bir yol takip edilir. Örnek olarak Şekil 5’de gösterilen vücut ölçüleri ve cinsiyet verisini düşünelim. Burada amaç sadece kilo ve boy özniteliklerinden hareketle yeni bir gözlemin kadın ya da erkek sınıflarına atanmasıdır. Kilo ve boy arttıkça erkeklerin sıklığının 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*¹³ yaklaşımının temelinde elimizdeki veri setinden hareketle yeniden yerine koyma usulüyle rassal örneklemeler oluşturulması

¹³ “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 yöntemde “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

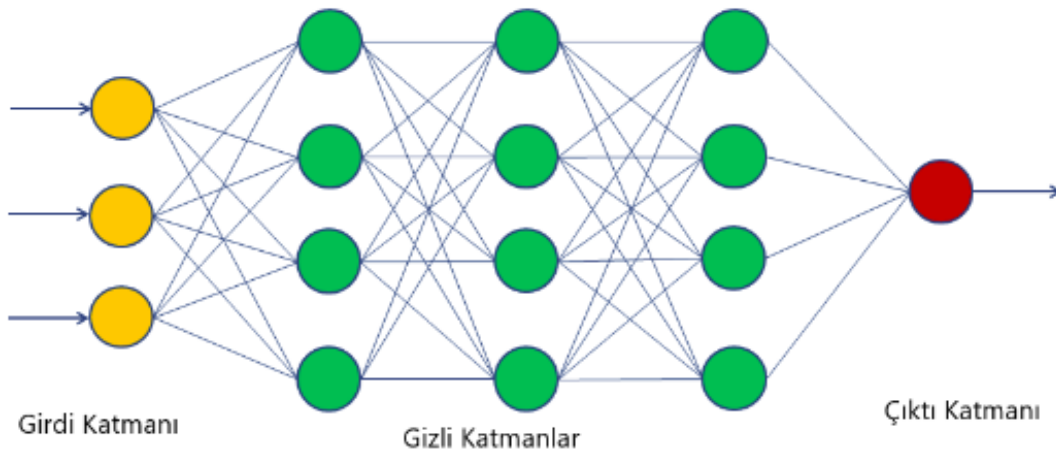
Ağaç bazlı yöntemler ile *boosting* yaygın olarak birlikte kullanılır. Bu durumda *boosting* algoritmasının üç ayarlanma parametresi vardır: ağaç sayısı (iterasyon), öğrenme oranı (*shrinkage*), ve ağaçlardaki düğüm sayısı. Tipik olarak pratikte çapraz geçiş yöntemiyle en başarılı kestirimleri veren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

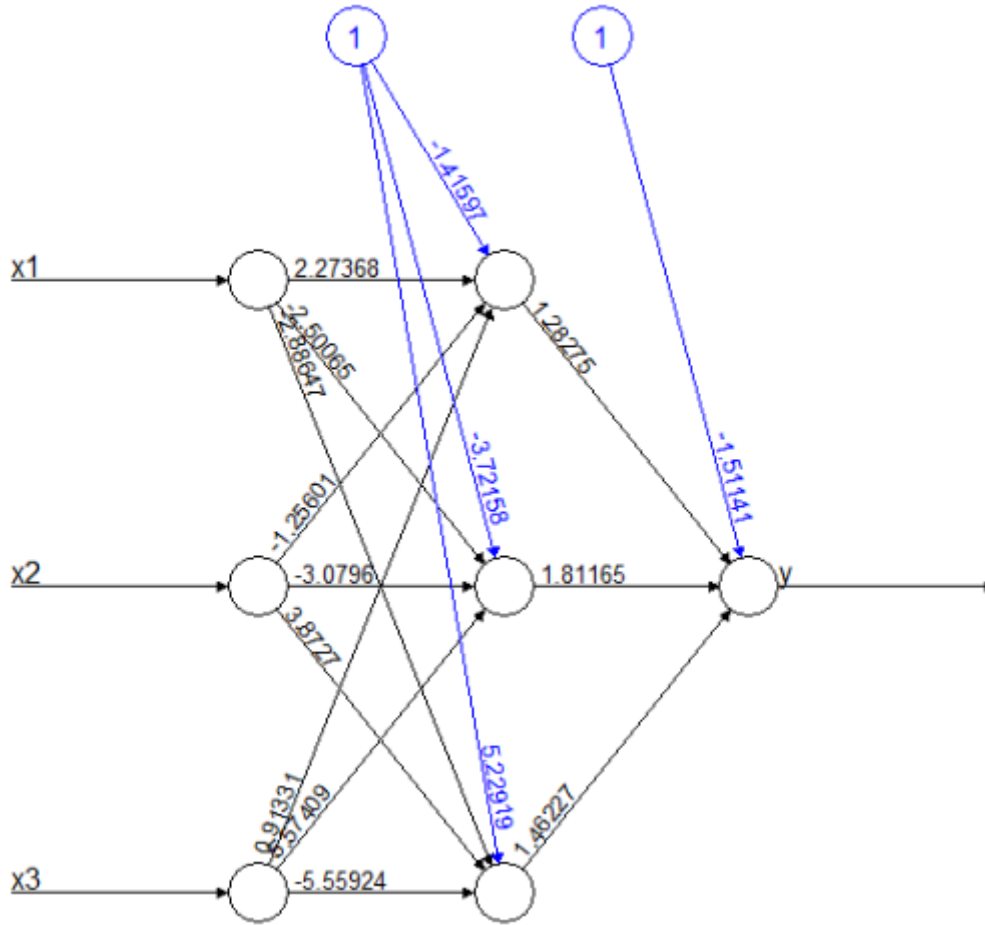
$$\hat{y} \approx 9.593 + 2.308x_1 - 4.52x_2 + 3.90x_3 \quad [8]$$

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



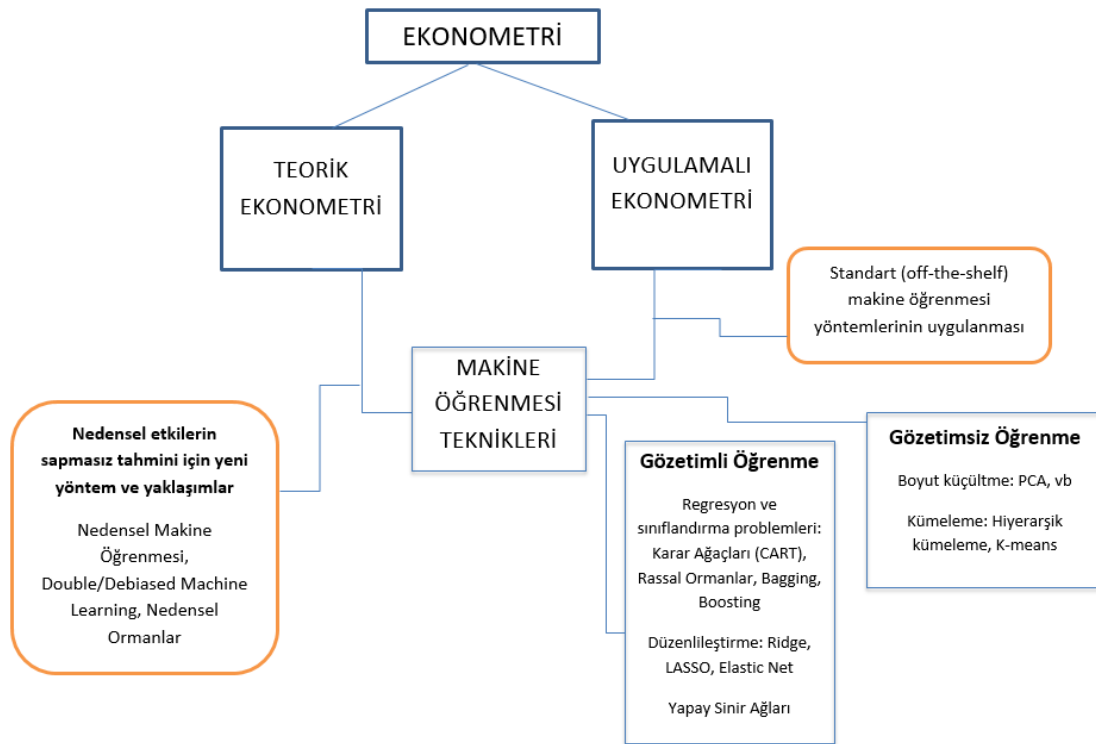
3.6 Diğer yöntemler

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.¹⁴

Şekil 11: Ekonometri ve Makine Öğrenmesi Etkileşimi



¹⁴ 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 sapsız/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.¹⁵ 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 θ_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* parametrelerini¹⁶ içermektedir.

¹⁵ Detaylar için bkz. Chernozhukov, Hansen ve Spindler (2016).

¹⁶ 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 θ_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 θ_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 öngörülerin¹⁷ 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.¹⁸ 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

¹⁷ Zaman serisi analizinde geleceğe dönük kestirimler “öngörü” olarak isimlendirilmiştir.

¹⁸ 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.¹⁹

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

¹⁹ 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 çıkarılmanın 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 kullanılabilceğini 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-validatory 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.



ISSN 2146-6173
e-ISSN 2791-7991