



Ekonomi-tek

Volume 13 Number 2
Cilt 13 Sayı 2

September 2024
Eylül 2024

İstanbul işgücü piyasasında rezervasyon ücretleri
Ozan Bakış, Seyfettin Gürsel

Adil geçiş planlamak: Yeşil dönüşümü adil kılmak için bir çerçeve önerisi
Can Portakal, İşilsu Tamcı, Sevil Acar

Borders of socio-economic development in Türkiye
Burhan Can Karahasan

Logistics performance and environmental degradation: The case of MENA countries
Seda Ekmen Özçelik, Ünal Töngür

The role of Pearl's causal framework in empirical research
Fırat Bilgel

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

Fatma 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 Kazdağılı

(*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 Akçigit

(*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: Sırri 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, 2024

ISSN 2146-6173
e-ISSN 2791-7991

<https://www.tek.org.tr/>

Ekonomi-tek is a peer-review journal published bi-annually (March 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 iki kez (Mart ve Eylül) yayımlanan hakemli bir dergidir. Dergi ekonomi ile ilgili İngilizce veya Türkçe orijinal makaleleri kabul eder. Dergiye çevirmişi olarak ücretsiz erişilebilir.

Türkiye Ekonomi Kurumu Vakfı adına sahibi: Hasan Kazdağılı

Türkiye Ekonomi Kurumu, Hoşdere Cad. No: 24/4, 06550
Çankaya/ANKARA

Basım Tarihi: Eylül 2024



Contents / İçindekiler

Araştırma Makalesi

İstanbul işgücü piyasasında rezervasyon ücretleri

Reservation wages in Istanbul labour market

Ozan Bakış, Seyfettin Gürsel 140

Araştırma Makalesi

Adil geçiş planlamak: Yeşil dönüşümü adil kılmak için bir çerçeve önerisi

Planning the just transition: A framework proposal for making green transformation fair

Can Portakal, Işılsu Tamçı, Sevil Acar 160

Araştırma Makalesi

Borders of socio-economic development in Türkiye

Türkiye'de sosyoekonomik gelişmişliğin sınırları

Burhan Can Karahasan 183

Araştırma Makalesi

Logistics performance and environmental degradation: The case of MENA countries

Lojistik performans ve çevresel bozulma: MENA ülkeleri örneği

Seda Ekmen Özçelik, Ünal Töngür 198



Inceleme Makalesi

The role of causal models in empirical research

Nedensel modellerin empirik araştırmadaki rolü

Fırat Bilgel 230

İstanbul İşgücü Piyasasında Rezervasyon Ücretleri*

Ozan BAKİŞ**

Seyfettin GÜRSEL***

Öz

İstanbul işgücü piyasasında bir tarafta asgari ücret seviyesinde eleman arayan fakat çalıştıracak insan bulamadığını beyan eden pek çok firma bulunurken diğer tarafta azımsanmayacak bir işsizlik oranı söz konusudur. Nasıl oluyor da açık iş pozisyonları ve işsizlik aynı anda gözleniyor? Sebepleri nelerdir? Betam tarafından İstanbul Büyükşehir Belediyesi için hazırlanan İstanbul İşgücü Piyasası Araştırmaları kapsamında sahadan toplanan son üç yılın anket verileri kullanılarak cinsiyet, eğitim, yaş ve işgücü piyasası tecrübesinin rezervasyon ücretine olan etkileri araştırılmıştır. Regresyon analizi sonuçlarına göre İstanbul'da kadınların rezervasyon ücreti erkeklerle kıyasla daha düşüktür. Hiç çalışmamış olanlarla kıyaslandığında çalışmış olanların rezervasyon ücreti daha yüksektir. İşsizlere kıyasla potansiyel işgücüün rezervasyon ücreti daha yüksektir. Bir iş kabul ederken bir koşul belirtenler koşulum yok diyenlere kıyasla daha yüksek rezervasyon ücretine sahiptirler. Son olarak, regresyon analizi işsiz kalınan sürenin rezervasyon ücretine doğrudan bir etkisi olmadığını göstermektedir.

JEL Kodları: J31, J16, J30

Anahtar Kelimeler: rezervasyon ücreti, İstanbul işgücü piyasası, cinsiyetler arası ücret farkı

* Sagalassos Çalıştayı-5 katılımcılarına (2-5 Kasım 2023) değerli katkı ve önerileri için teşekkür ederiz. Ayrıca yorum ve eleştirileri ile çalışmamıza katkıda bulunan Ekonomi-Tek dergisi editörler kuruluna ve iki hakeme teşekkür ederiz.

** Bahçeşehir Üniversitesi, ozan.bakis@bau.edu.tr, <https://orcid.org/0000-0001-9785-1992>

*** Bahçeşehir Üniversitesi, seyfettin.gursel@bau.edu.tr, <https://orcid.org/0000-0003-4645-1117>

Reservation Wages in Istanbul Labour Market

Abstract

On the one hand, there are many companies in the Istanbul labour market that are looking for minimum-wage workers but say that they cannot find people to hire. On the other hand, unemployment rate is significantly high. How is it possible that both job vacancies and unemployment can be observed at the same time? What are the reasons? We analysed the effects of gender, education, age and labour market experience on reservation wages using survey data from the last three years collected as part of the Istanbul Labour Market Survey that is being prepared by Betam for the Istanbul Metropolitan Municipality. The regression results show that women in Istanbul have lower reservation wages than men. Compared to those who have never worked, those who have worked have higher reservation wages. Compared to the unemployed, the potential workers have higher reservation fees. Those who state a condition when accepting a job have higher reservation wages compared to those who do not state a condition. Finally, we find that the duration of unemployment has no direct effect on the reservation wage.

JEL Codes: J31, J16, J30

Keywords: reservation wage, Istanbul labor market, gender wage gap

1. Giriş

İş arayanların bir iş kabul etmek için talep ettiği en düşük ücrette rezervasyon ücreti denmektedir. Elbette, bu ücret kişinin ücret dışı geliri, eğitim seviyesi, yaşadığı bölgede geçim koşulları, mensup oldukları hanenin maddi durumu, daha önce çalışmış olanların yararlanabildikleri işsizlik ödeneği, kendi vasif ve deneyimlerine benzer çalışanların aldıkları ücretler ve asgari ücret seviyesi gibi pek çok unsur tarafından belirlenmektedir. Bu faktörlere ek olarak makroekonomik koşullar rezervasyon ücretine etki etmektedir. Örneğin, kriz ortamlarında iş bulmak zorlaştığından aynı zamanda kimi hanelerin gelirleri de azaldığından iş arayanların talep ettikleri rezervasyon ücretlerinde düşüş olabilir.

Bir iş kabul etmek için iş arayanların talep ettikleri en düşük ücret ile istihdamını artırmak isteyen firmaların teklif ettikleri ücret arasında her zaman uyum olmayabilir. Bunun iki temel sebebi bulunmaktadır. Bir yandan kira başta olmak üzere hayat pahalılığına etki eden pek çok unsur bölgeden bölgeye farklıdır. Diğer yandan firmalar ulusal düzeyde belirlenen asgari ücreti referans alma eğiliminde olduklarıdan, rezervasyon ücretlerinin hayat pahalılığı sebebiyle yüksek olduğu bölgelerde asgari ücret ile rezervasyon ücretleri arasında ciddi bir fark oluşabilmektedir. Bu koşullarda arz ile talep arasında uyumsuzluk (*mismatch*) ortaya çıkmaktadır. Bunun sonucu olarak hem istihdamını artırmak isteyen işletmeler eleman bulmakta zorluk yaşarken öte yandan işsizlerin iş arama süreleri giderek artar ve sonuçta yapısal işsizlik yükselsir ve giderek katılır.

İstanbul işgücü piyasasında durum tam da böyledir. Bahçeşehir Üniversitesi Ekonomik ve Toplumsal Araştırma Merkezi'nin (Betam) İstanbul Büyükşehir Belediyesi (İBB) için hazırladığı ilk İstanbul İşgücü Piyasası raporu sırasında (2021 yılı verileri ile hazırlayıp 2022 yılında yayınlanan) karşılaştığımız bazı olgular bu durumu teyit eder niteliktedir. Bir tarafta o gün geçerli olan asgari ücret seviyesinde eleman arayan fakat çalıştıracak insan bulmadığını beyan eden pek çok firma bulunurken diğer tarafta azımsanmayacak bir işsizlik oranı (yüzde 14'ün üstü) söz konusuydu. 2023 ve 2024 yıllarında yaptığımız saha çalışmaları da benzer şekilde, son iki yılda işsizlik oranı bir miktar azalmış olmakla birlikte, işgücü arz ve talebi arasındaki uyumsuzluğun varlığını teyit etmektedir. Nasıl oluyor da açık iş pozisyonları ve işsizlik aynı anda gözleniyor?

İşgücü arzı ile talebi arasındaki bu uyumsuzluğun birden fazla sebebi olabilir. İlk akla gelen sebep rezervasyon ücretlerinin çok yüksek olmasıdır. Pek çok işveren vasıfsız işler için asgari ücrete yakın bir ücretten yeni eleman ararken iş arayanlar daha yüksek bir ücret talep ettikleri zaman bu uyumsuzluk kaçınılmaz olacaktır. Bu uyumsuzluğun bir diğer sebebi friksiyonel işsizliktir. İş değiştirmek isteyen kişilerin kendilerine uygun işi bulması ve iş başı yapabilmesi hemen mümkün değildir, belli bir zaman gerektirmektedir. Bu süreçte de açık iş pozisyonları ve işsizlik aynı anda

gözlemlenebilmektedir. Benzer şekilde firmaların talep ettiği işgücünün vasıflarıyla mevcut işgücü arzının sahip olduğu vasıflar arasında uyumsuzluk olduğu durumlarda da işgücü arzı ile talebi arasında uyumsuzluk olabilmektedir.

Bu çalışma bu olası sebeplerden ilkine, rezervasyon ücretlerine, odaklanmaktadır. Yüksek rezervasyon ücretinin sebepleri nelerdir? Cinsiyet, yaş, eğitim, asgari ücret gibi faktörler rezervasyon ücretini nasıl etkilemektedir? Çalışmamızda tüm bu sorulara cevap aranmakla birlikte kadınlar ile erkekler arasındaki rezervasyon ücreti farklılıklarının analizine ağırlık verilecektir. Bu konuya şu sebeple önemsiyoruz: Bugüne kadar çevremizde yapılan akademik tartışmalarda, kadınların görece yüksek işsizlik oranlarını açıklarken en sık duyduğumuz sebeplerin başında kadınların yüksek rezervasyon ücretlerine sahip oluşu gelmektedir. Kadınların rezervasyon ücretinin erkeklerle kıyasla daha yüksek olmasının dayanağı ise hem hanede çalışan erkeğin gelirinin kadınlar için “ücret dışı gelir” (*nonwage income*) olarak algılanması hem de kadınların hane içi sorumluluklardan dolayı alternatif zamanlarının erkeklerle göre daha değerli olmasıdır. Çalışmamız bu tartışmaya doğrudan katkı sunan ilk çalışmadır.

Regresyon analizi sonuçlarına göre İstanbul'da kadınların rezervasyon ücreti erkeklerle kıyasla daha düşüktür. Hiç çalışmamış olanlarla kıyaslandığında çalışmış olanların rezervasyon ücreti daha yüksektir. İşsizlere kıyasla potansiyel işgücünün rezervasyon ücreti daha yüksektir. Bir iş kabul ederken bir koşul belirtenler koşulum yok diyenlere kıyasla daha yüksek rezervasyon ücretine sahiptirler. Son olarak, regresyon analizi işsiz kalınan sürenin rezervasyon ücretine doğrudan bir etkisi olmadığını göstermektedir.

Eldeki TÜİK verilerinde bu soru sorulmadığı için rezervasyon ücreti Türkiye işgücü piyasasında hemen hemen hiç araştırılmamıştır. Bu eksiği gidermek için Bahçeşehir Üniversitesi Ekonomik ve Toplumsal Araştırma Merkezi (Betam) tarafından İstanbul Büyükşehir Belediyesi için hazırlanan İstanbul İşgücü Piyasası Araştırmaları (İSİPA) kapsamında sahadan toplanan son üç yılın anket verileri kullanılmıştır. İSİPA anketleri 2021, 2022 ve 2023 yıllarının Ekim ayında yapılmış, nihai rapor ise takip eden yılın ocak/şubat aylarında yayınlanmıştır.

Türkiye ile ilgili bizim ulaşabildiğimiz yegâne çalışma İstekli ve Şentürk (2016) tarafından yapılmıştır. Yüksek Lisans tezinden türetilen bu çalışma için 2013 yılı Ekim ayında 15 ilde 2162 kişi ile yapılmış bir İşkur anketi kullanılmıştır. Çalışmanın ana kütlesi işsizler olduğu için belirlenen illerde bulunan İş Kurumu İl Müdürlüklerinde kayıtlı kişilerle Türkiye İş Kurumu ofislerinde anket gerçekleştirilmiştir. Anket yapılan kişilerin yüzde 63,6'sı (yaklaşık üçte ikisi) erkek, kalanı kadındır. Potansiyel işgücü (çalışmayı arzulayan ama iş bulma umidi olmadığından ya da ailesel nedenlerle iş aramayanlar) kapsam dışı bırakılmıştır. Örneklemnin sınırlılığı nedeniyle bölgeler arası kişi başı gelir ve geçim koşulları farkları dikkate alınmamıştır.

Haurin ve Sridhar (2003) ABD panel verilerini, Caliendo vd. (2017) Alman panel verilerini, Brown vd. (2011) İngiliz panel verilerini, Bloemen ve Stancanelli (2001) Hollanda panel verilerini, Le Barbanchon vd. (2020) Fransız idari kayıtlarını kullanarak kadınların rezervasyon ücreti olarak erkeklerin gerisinde kaldıklarını ortaya koymaktadır. Çalışmaların çoğu fakın yüzde 10 civarı olduğunu belirtiyor. Kimi çalışmalar rezervasyon ücretinin belirleyenlerine odaklanırken diğerleri gözlemlenen farkı bileşenlerine ayırtırmaya çalışmaktadır. Çocuk sayısı, eğitim, işsiz geçirilen süre, eski işteki ücret, finansal durum gibi faktörler rezervasyon ücreti tartışmalarında öne çıkmaktadır.

2. Veriler

İSİPA kapsamında 2021 yılında 10083, 2022 ve 2023 yıllarında ise 5.000 bin kişiyle görüşülmüştür. Görüşülen kişilere ait temel bazı bilgiler, üç yılın bilgileri toplulaştırılarak, Tablo 1'de kadın, erkek ve ikisinin toplamı olarak verilmektedir. Önce tüm örneklemde (Toplam sütunları) yer alan başlıca dağılımların TÜİK HİA İstanbul istatistikleri ile karşılaştırılması yararlı olabilir. Örneklemde kadın payı (yüzde 47,4) HİA'ya kıyasla bir miktar düşüktür. Buna karşılık çalışanların (istihdamdakiler) örneklem (çalışabilen nüfus) içindeki payı (yüzde 48,5) diğer ifadeyle istihdam oranı HİA 2021-22 ortalamasına (yüzde 48,9) çok yakındır. Keza eğitim düzeylerinin dağılımı da büyük ölçüde örtüşmektedir. İstanbul HİA'da (2021-22) ve örneklemde üç eğitim düzeyinin payları şöyledir: Lise altı yüzde 45,8-49,2; Lise yüzde 28,0-25,9; Lise üstü Yüzde 26,2-24,9.

Kadın ve erkeklerin eğitim ile yaş dağılımı birbirine çok yakındır. Kadınlar ile erkekler arasındaki en büyük fark işgücü piyasası durumunda görülmektedir. Durum değişkeni dört değer almaktadır: işsizler (aktif olarak iş arayanlar), potansiyel işgücü (çalışmayı arzuladığı halde aktif olarak iş aramayanlar), çalışıyor (istihdamda) ve diğer (işgücü dışında olan diğer kişiler). Erkeklerin yüzde 64,1'i çalışırken kadınlarda bu oran sadece yüzde 31,2'dir. İşgücü dışında (diğer) olan erkek oranı yüzde 21,4 iken aynı oran kadınlarda yüzde neredeyse yüzde 50'dir. Çalışmamızın odak noktası olan işsizlerin payı¹ üç yıllık veri havuzunda yüzde 10,5'tir. Kadınlar için işsizlik oranı yüzde 11,2 olup erkekler için bir miktar daha düşüktür (yüzde 9,8). İstanbul HİA istatistiklerinde (2021-22) toplam işsizlik oranı daha düşüktür (yüzde 6,2). Örneklemde işsiz sayısı yüksek tahmin edilmiştir; bu yüksek tahmin büyük ölçüde kadın işsiz sayısının yüksek tahmin edilmesinden kaynaklanmaktadır.

¹ Örneklem içinde işsizlerin payı (yüzde 10,5) çalışabilen nüfus içinde işsizlerin payının muadilidir; işsizlik oranı ile karıştırılmamalıdır.

Ek Tablo1 ve Ek Tablo 2'te, sırası ile işsiz ve potansiyel işgücü alt örneklemeleri içinde kadın ve erkekler kıyaslanarak eğitim ve yaş dağılımı farkları incelenmiştir. Her iki tabloda da lise üstü eğitme sahip bireylerin payı kadınlarda daha yüksektir. Benzer şekilde her iki tabloda 25-44 yaş aralığındaki kişilerin oranı kadınlarda daha yüksektir. 45 yaş üstü çalışmak isteyen kadın sayısı her iki grupta daha düşüktür. Öztemek gerekirse işsiz ve potansiyel işgücü alt örneklemelerinde yer alan kadınlar erkeklerle kıyasla biraz daha genç ve daha eğitimlidir denebilir.

Tablo 1. İSİPA anketleri

		N			Pay (%)		
Değişken	Kırılım	Kadın	Erkek	Toplam	Kadın	Erkek	Toplam
		9.516	10.567	20.083	47,4	52,6	
Durum	Çalışıyor	2.970	6.778	9.748	31,2	64,1	48,5
Durum	Diğer	4.686	2.258	6.944	49,2	21,4	34,6
Durum	İşsiz	1.066	1.039	2.105	11,2	9,8	10,5
Durum	Potansiyel İşgücü	794	492	1.286	8,3	4,7	6,4
Eğitim	Lise Altı	4.824	5.064	9.888	50,7	47,9	49,2
Eğitim	Lise Üstü	2.457	2.544	5.001	25,8	24,1	24,9
Eğitim	Lise	2.235	2.959	5.194	23,5	28,0	25,9
Yaş grubu	15-24	1.563	1.559	3.122	16,4	14,8	15,5
Yaş grubu	25-44	4.584	4.623	9.207	48,2	43,8	45,8
Yaş grubu	45-69	3.225	4.067	7.292	33,9	38,5	36,3
Yaş grubu	70+	144	318	462	1,5	3,0	2,3

Not: Durum: kişinin istihdam durumunu belirtmektedir. Dört değer almaktadır: **İşsizler** (aktif olarak iş arayanlar), **Potansiyel İşgücü** (çalışmayı arzuladığı halde aktif olarak iş aramayanlar), **Çalışıyor** (istihdamda) ve **Diğer** (işgücü dışında olan diğer kişiler)

Anketlerde rezervasyon ücreti şu şekilde sorulmuştur:

İşsizlere: Bir işte çalışmaya başlamak için kabul edeceğiniz en düşük aylık ücret nedir? [2023'te ek soru: Bu işte günde kaç saat çalışmayı bekliyorsunuz? Bu işte haftanın kaç günü çalışmayı bekliyorsunuz?]

Potansiyel işgücüne: İş aramaya karar verdığınız takdirde teklif edilen bir işi kabul etmek için razı olacağınız en düşük aylık ücret nedir? [2023'te ek soru: Bu işte günde kaç saat çalışmayı bekliyorsunuz? Bu işte haftanın kaç günü çalışmayı bekliyorsunuz?]

Ekim 2022'de asgari ücret 5.500 TL idi (Temmuz 2022'de kararlaştırılan asgari ücret). 2021 ve 2023 yılı rezervasyon ücretlerini TÜFE ile 2022 Eylül fiyatlarına çektiğimizde İstanbul'da işsizlerin ve potansiyel işgücünün toplamı dikkate alındığında, erkekler için ortalama rezervasyon ücretinin 7.955 TL kadınlar için ise 7.108 TL

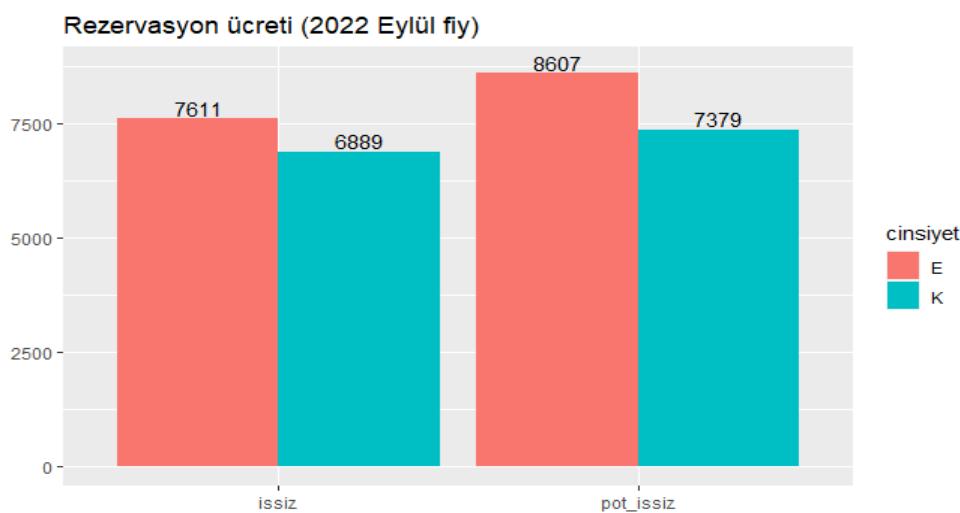
olduğunu gözlemliyoruz. Bu da yaklaşık yüzde 12'lik bir farka denk gelmektedir. Anketten gelen ücretler Hanehalkı İşgücü Anketi'nde (HİA) **gözlemlenen ücretler** ile kıyaslandıklarında oldukça gerçekçi şekilde tahmin edildikleri görülmektedir.² Ama esas vurgulanması gereken olgu, İstanbul'da ortalama rezervasyon ücretinin (7.532TL) asgari ücretten yüzde 37 oranında daha yüksek olmasıdır. Bu önemli farkı eldeki veriler ile olabildiğince aydınlatmak için regresyon analizleri gerçekleştirılmıştır. Bu analizlere hazırlık mahiyetinde önce ortalama rezervasyon ücretinin cinsiyet, işgücü durumu ayrıımında ne ölçüde farklılaşlığına kısaca değinilecek ardından her yıla özgü rezervasyon ücreti dağılımı ele alınacaktır.

3. İssizlerde ve Potansiyel İşgücünde Rezervasyon Ücretleri

İSİPA 2021-22-23 verilerine göre issızlar (aktif olarak iş arayanlar) ile potansiyel işgücüne mensup kişilerin (çalışmayı arzuladığı halde aktif olarak iş aramayanlar) ortalama rezervasyon ücretleri cinsiyet ayrıımında Şekil 1'de gösterilmiştir.

² İSİPA'daki rezervasyon ücretleri HİA 2021 ve 2022 yılı verilerinde **gözlemlenen ücretler** ile kıyaslanabilir. Her iki yılda da 500 bine yakın kişi ile görüşülmüştür. 2021 yılı rakamlarını TÜFE endeksi ile 2022 yılına çektiğinden sonra özel sektörde çalışanlarda ortalama ücretin Türkiye genelinde erkekler için 6.382 TL, kadınlar için ise 5.488 TL olduğunu hesaplıyoruz. Aradaki fark yüzde 16'dır. İstanbul'daki rezervasyon ücretleri biraz daha yüksek olup aradaki fark daha düşüktür: erkekler için 7.511 TL, kadınlar için ise 6.761 TL olup aradaki fark yüzde 1,11'dir.

Şekil 1. İşgücü durumuna göre rezervasyon ücretleri



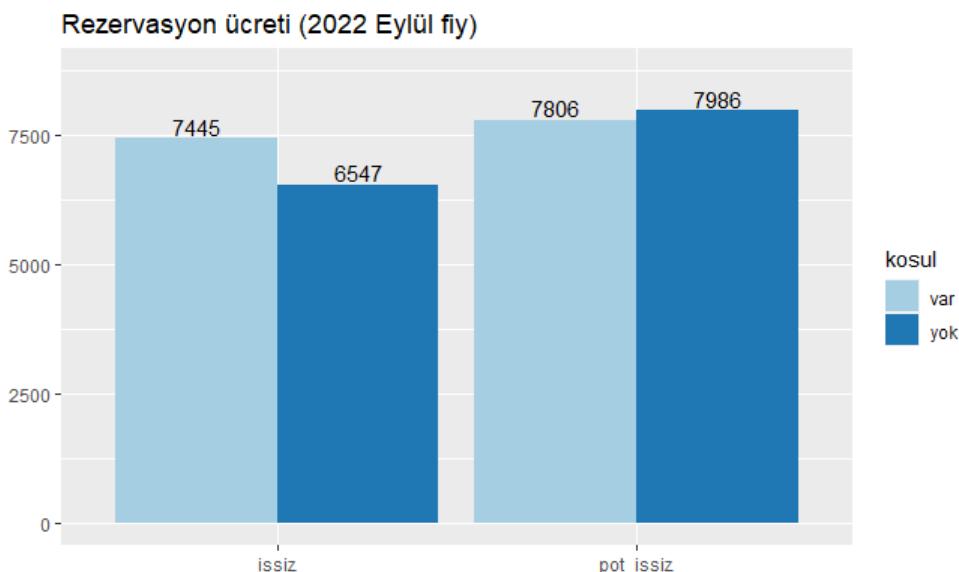
Not: işsiz: işsiz, potansiyel işsiz: potansiyel işgücü, E: erkek, K: kadın

İlk gözlem, işsizlerde olduğu gibi potansiyel işgücünde de rezervasyon ücretinin kadınlarda erkeklerle kıyasla düşük olmasıdır. Bu fark işsizlerde yüzde 10,5, potansiyel işgücünde yüzde 16,6'dır. İkinci gözlem, potansiyel işgücünde olanların rezervasyon ücretlerinin işsizlerin rezervasyon ücretlerine kıyasla yüksek olmasıdır; fark erkeklerde yüzde 13,1, kadınlarda yüzde 7,1'dir. Bu gözlemlerin muhtemel nedenlerine regresyon analizleri bölümünde degeinilecektir.

Anketlerde iş arayanlara ve potansiyel işgücü mensuplarına rezervasyon ücretlerinin yanı sıra bir iş kabul etmek için talep ettikleri koşullar olup olmadığı da sorulmuştur. Katılımcıların bir kısmı “koşulum yok” yanıtı verirken³ diğer kısmı bir ya da daha fazla koşulu olduğunu beyan etmiştir.⁴ Koşulları olanlar ve olmayanların ortalama rezervasyon ücretleri her iki grup için Şekil 2'de izlenebilir.

³ Örneklemde koşulu olmadığı söyleyenlerin payı işsizlerde yüzde 20,6; potansiyel işgücünde yüzde 18,8'dir.

⁴ Bu koşullar şunlardır: 1) En az asgari ücretten bir iş olmalı 2) Eğitimini aldığım mesleğe uygun bir iş olmalı 3) Tam zamanlı bir iş olmalı 4) Evime yakın olmalı, 5) Sigortası olmalı 6) Yol, yemek gibi nitelikli hakları olmalı 7) İş güvenliği sağlanmış olmalı/tehlikeli iş olmamalı.

Şekil 2. Koşul durumuna göre rezervasyon ücretleri

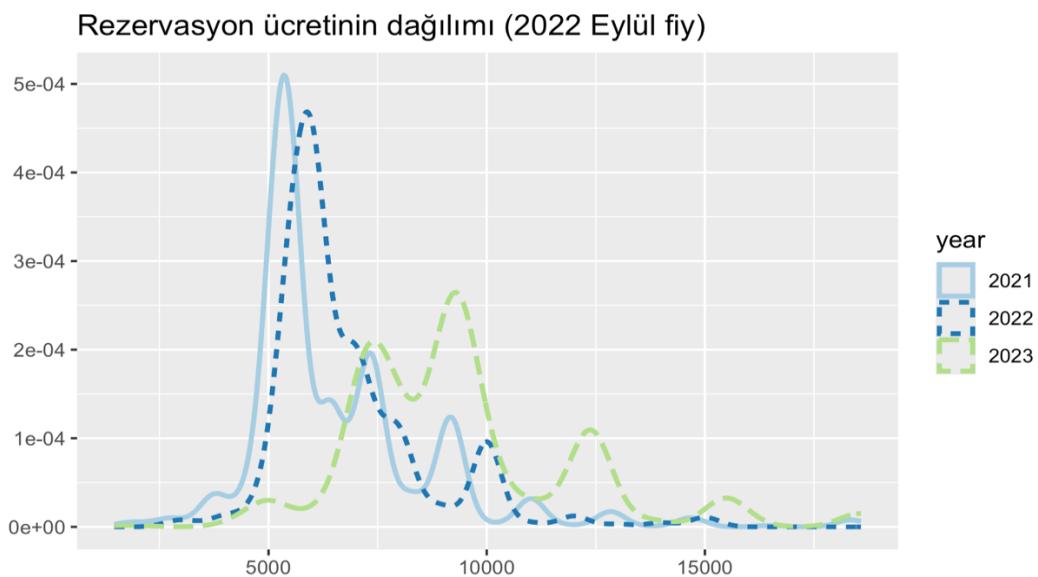
Not: işsiz: işsiz, potansiyel işsiz: potansiyel işgücü, E: erkek, K: kadın, koşul: bir iş kabul etmek için talep ettikleri koşullar olup olmadığı.

Beklenebileceği gibi aktif olarak iş arayanlar (ıssızlar) arasında koşulu olmayanların ortalama rezervasyon ücreti (6547 TL) koşulu olanlarından (7445 TL) yüzde 13,7 daha düşüktür. Buna karşılık potansiyel işgücünde koşulu olmayanların rezervasyon ücreti (7806 TL) olanlara kıyasla (7986 TL) az da olsa düşük çıkmıştır; ancak fark yüzde 2,3'ten ibarettir.

4. Rezervasyon Ücretlerinin Yıllık Dağılımlarında Farklılaşma

Şekil 3'te rezervasyon ücretlerinin her yıl için dağılımları gösterilmiştir. Karşılaştırmanın yapılabilmesi için 2021 ve 2023 ücretlerinin TÜFE ile 2022 yılına uyarlandıklarını tekrar hatırlatalım. Dikkat edilirse 2021 ve 2022 yıllarının dağılım eğrileri çok büyük ölçüde örtüşmektedir; 2022 eğrisi 2021 eğrisini biraz daha sağda konumlanmıştır. İstanbul'da 2022 yılından itibaren hayat pahalılığının özellikle kiralardan hızla yükselişe geçmesiyle artmaya başladığı düşünüldüğünde bu 2022 rezervasyon ücreti dağılımının sınırlı ölçüde sağa kaymış olması normaldir. Buna karşılık 2023 eğrisi belirgin şekilde sağa kaymış durumdadır. Eğer rezervasyon ücreti her yıl TÜFE oranında artış gösterse dağılım eğrisinin 2023 yılında bu ölçüde sağa kayması beklenmezdi.

Şekil 3. Rezervasyon ücretlerinin yıllara göre dağılımı



Bu kayma iş arayanların ve potansiyel işgucünün 2023 yılında, daha önceki yıllara kıyasla, çok daha yüksek bir rezervasyon ücreti talep ettiğini ortaya koymaktadır. Bunun bir nedeni 2023 yılında İstanbul'da geçim koşullarının giderek ağırlaşması, bir diğer nedeni de rezervasyon ücretinin esas olarak asgari ücreti referans alması ve bu ücretin 2023 yılında milletvekili ve cumhurbaşkanlığı seçimlerinin etkisiyle TÜFE üzerinde artış gösternesidir. Asgari ücretin TÜFE üzerinde arttığını Tablo 2'yi inceleyerek anlayabiliriz. Tablo 2'de asgari ücretin ve TÜFE'nin 6 aylık birikimli artışları verilmektedir. 2023 Ocak ayında 6 aylık TÜFE artışı yüzde 15 iken asgari ücret artışı yüzde 55 olmuştur. Benzer şekilde 2023 Temmuz ayında 6 aylık TÜFE artışı yüzde 25 iken asgari ücret artışı yüzde 34 olmuştur.

Tablo 2. Rezervasyon ücretleri – Asgari ücret

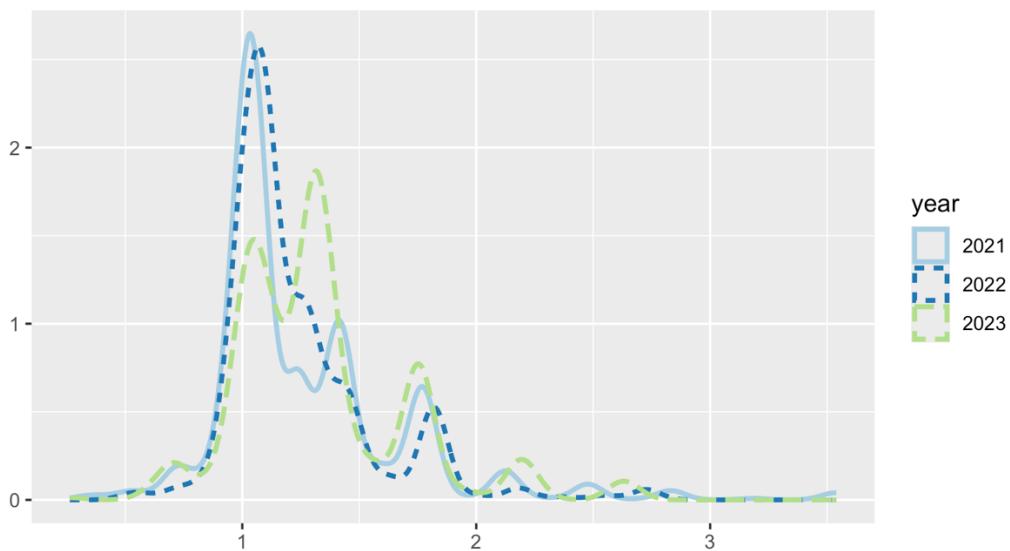
Ay	Yıl	TÜFE	AÜ	TÜFE artışı	AÜ artışı
Ocak	2021	504,8	2.826		
Temmuz	2021	547,5	2.826	1,08	1,00
Ocak	2022	687,0	4.253	1,25	1,51
Temmuz	2022	977,9	5.500	1,42	1,29
Ocak	2023	1.128,0	8.507	1,15	1,55
Temmuz	2023	1.352,0	11.402	1,20	1,34

Not: TÜFE artışı ve AÜ artışı sırası ile TÜFE ve asgari ücretin 6 aylık birikimli artışlarını temsil etmektedir.

Rezervasyon ücretinin asgari ücrete endeksli olduğunu Şekil 4 net olarak göstermektedir. Rezervasyon ücretinin asgari ücrete oranı olarak tanımladığımız *göreli ücret* dağılımını üç yıl için yaptığımızda 2023 yılının 2021 ve 2022 yıllarına büyük ölçüde benzediğini görmekteyiz.

Şekil 4. Rezervasyon ücretlerinin yıllara göre dağılımı

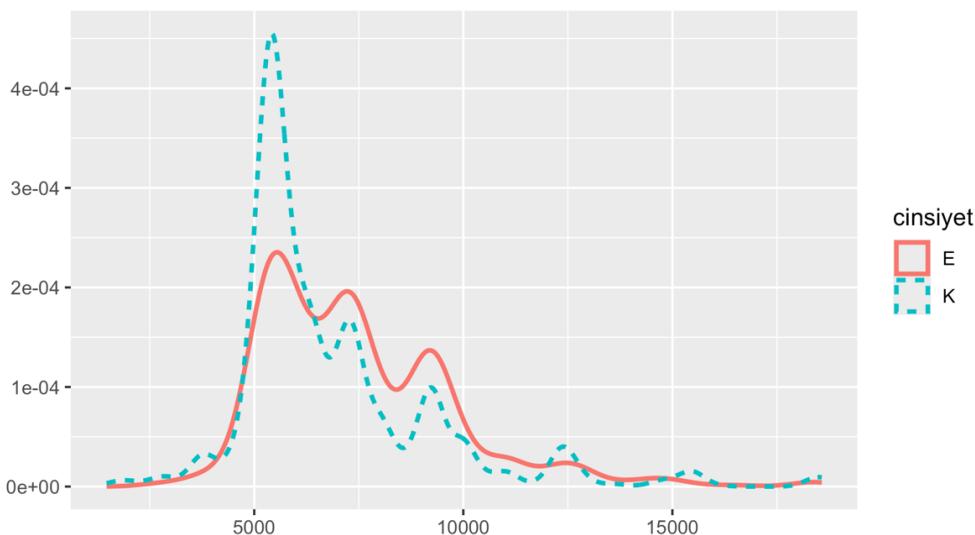
Rezervasyon ücreti/AÜ dağılımı (cari fiyat)



Regresyon analizine geçmeden önce son olarak rezervasyon ücretlerinin toplu dağılımına (üç yıl bir arada) kadın-erkek ayırmı itibarıyle bir göz atmakta fayda var (Şekil 5). İki dağılımı eğrisi arasındaki en dikkat çeken fark, kadınların rezervasyon ücretleri asgari ücretin (5.500TL) biraz üzerinde bir seviyede yoğunlaşıırken, erkeklerin rezervasyon ücretlerinin asgari ücretin belirgin şekilde üzerinde ve çok daha geniş bir aralıkta yoğunlaşmış olmalarıdır. Ortalamada kadınların erkeklerle kıyasla daha düşük rezervasyon ücretine sahip olmaları da bu dağılım özelliğinden kaynaklanmaktadır.

Şekil 5. Rezervasyon ücretlerinin cinsiyet bazında dağılımı

Cinsiyete göre rezervasyon ücretinin dağılımı (2022 Eylül fiy)



Not: E: erkek, K: kadın.

5. İSİPA: Regresyon Analizi

Rezervasyon ücretinin belirleyenlerini tahmin etmek için aşağıdaki modeli kullanıyoruz

$$\log(ucret)_i = \beta_0 + \lambda_t + \beta_1 kadin_i + X_i^T \Gamma + u_i$$

Burada X vektörü eğitim, yaş grubu, işgücü piyasası durumu gibi bireysel özellikleri temsil etmektedir. Esas ilgilendigimiz parametre β_1 olup bu parametre bize rezervasyon ücretlerinin cinsiyete ne kadar bağlı olduğunu göstermektedir. $\beta_1 < 0$ ise bunu cinsiyet temelinde nedensel bir ilişkiden ziyade doğrudan gözlemlenemeyen tercihleri yansımıası olarak yorumlamak daha doğru olacaktır. Dışlanmış değişken yanılılığı (*omitted variable bias*) olarak bilinen bu durumun pek çok sebebi olabilir. Önemli olan, kadınlar ile erkeklerin sistematik olarak bu faktörler bakımından farklılık göstermesidir.

Literatürde kadın-erkek arasındaki rezervasyon ücreti farkları için muhtemel etkenler olarak şu faktörler öne çıkmaktadır:

- sahip olunan eğitim seviyesi,
- meslek ile iş tecrübesi dikkate alınarak başvurulan işin ortalama ücreti,
- esnek çalışma imkânları gözetilerek başvurulan işin ortalama ücreti,

- çalışılmayan zamanın görelî değeri,
- arama-eşleşme sürecindeki zorluklar,
- verimlilik,
- firmaların cinsiyet temelli ücret politikaları,
- psikolojik farklılıklar (risk ve rekabete karşısındaki tutum, öz güven vb.),
- işin toplum nezdindeki algısı/prestiji.

Tablo 3'te yer alan regresyon sonuçları literatürde yer alan etkenlerin geçerliliğini teyit eder niteliktedir. Üzerinde önemle durulması gereken olgu kuşkusuz kadınların rezervasyon ücretlerinin erkeklerinkinden istatistiksel olarak anlamlı bir şekilde daha düşük olmasıdır; katsayı eksİ 0,14 tahmin edilmiştir. Yukarıda giriş kısmında bu katsayıının benzer çalışmalarında yüzde 10 civarında tahmin edildiğini belirtmiştik.

Cök benzer karakteristiklere sahip kadın ve erkeklerin farklı rezervasyon ücretine sahip olmaları ilk bakışta şaşırtıcı gelebilir. İlk akla gelen, kullandığımız veride doğrudan gözlemlenemeyen bazı nedenlerle kadınların daha düşük ücretli işlere başvurmayı tercih etmeleridir. Örneğin, iş arayan kadınların önceliği mesai saatlerinde esneklik, işyerinin eve yakın olması ya da ağır olmayan işler ise kadınlar bu şartları sunan işlerde çalışmayı daha düşük ücretle rağmen tercih edebilir.⁵ Kadınların bu tercihi, pekâlâ, kendilerinin özgün tercihinden ziyade toplumsal değerlerin dayattığı iş bölümünün bir sonucu olabilir. Ayrıca Türkiye'de genç kadınların üniversite eğitiminde ağırlıklı olarak sosyal bilim bölümlerini tercih ettikleri görülmektedir (Bkz. Filiztekin, 2018). Bu bölümlerin kazandırdığı mesleklerin ortalamada mühendislik bölümlerine kıyasla daha düşük ücretlere sahip olduğu bilinmektedir.

Bir diğer sonuç lise üstü eğitimlilerin lise altı eğitimlilere kıyasla daha yüksek rezervasyon ücretine sahip olmasıdır; kat sayı 0,16'dır. Buna karşılık lise mezunlarının rezervasyon ücreti ile daha düşük eğitim seviyesine sahip olanlarındaki arasında anlamlı bir fark yoktur. Bu sonucun bir bakıma lise diplomasının piyasa açısından degersizliğinin göstergesi olduğu ileri sürülebilir. Orta ve ileri yaş grubunda yer alanların rezervasyon ücretleri de genç yaş grubu mensuplarından yüksektir. Keza potansiyel işgücünün işsizlere kıyasla az da olsa (0,04) yüksek, teklif edilen işi koşulsuz

⁵ Kadın erkek eşitsizlikleri üzerine yaptığı çalışmalar sayesinde 2023 Nobel Ekonomi ödülüne layık görülen Claudia Goldin bu açıklamayı ilk getiren iktisatçıdır. Bu konuda bkz. Goldin (2019). Danimarka İŞKUR'unun tüm iş arayanların son derece zengin verilerini kullanan ve 2023'te yayınlanan bir çalışma (Fluttmann vd. 2023) Goldin'in bulgularını teyit etmiştir. Danimarka'da iş arayanlar 2016'dan itibaren aradıkları işin niteliği, özellikleri ve bekledikleri ücretleri de kapsayan çok geniş bir formu doldurmaları zorunlu tutulmuştur. Söz konusu çalışma, bu tam sayı veri sayesinde kadınların özgün tercihleri nedeniyle ağırlıklı olarak nispeten düşük ücretli ama nispeten esnek işlere başvurduklarını göstermektedir.

kabul etmeye hazır olanların ise koşulu olanlara kıyasla sınırlı ölçüde düşük (-0,05) rezervasyon ücretlerine sahiptirler.

Bunlar beklenen sonuçlardır. Buna karşılık rezervasyon ücretlerinin 2021 yılına kıyasla anlamlı bir şekilde 2022'de sınırlı ölçüde (0,04) 2023'te ise büyük ölçüde (0,41) yüksek olması yukarıda rezervasyon ücretlerinin yıllara özgü dağılımlarına dair yapılan analizi ve yorumları tamamen teyit eder nitelikte olduğunu belirtmek isteriz. 2023'te İstanbul'da geçim koşullarının ağırlaştığını ve asgari ücrete yüksek reel zamlar yapıldığını hatırlatalım.

Tablo 3. Regresyon analizi (ıssız + potansiyel işgücü)

	İssız + Pot. İşgücü		İssız		Pot. İşgücü	
(Intercept)	8,69 ***	(0,02)	8,69 ***	(0,02)	8,71 ***	(0,03)
25-44 yaş grubu	0,14 ***	(0,01)	0,15 ***	(0,02)	0,11 ***	(0,03)
45-69 yaş grubu	0,12 ***	(0,02)	0,13 ***	(0,02)	0,10 ***	(0,03)
Kadın	-0,14	(0,01)	-0,15	(0,01)	-0,11	(0,02)
Lise	0,01	(0,01)	0,02	(0,02)	0,00	(0,02)
Lise Üstü	0,16 ***	(0,01)	0,14 ***	(0,02)	0,19 ***	(0,03)
yıl_2022	0,04 ***	(0,01)	0,04 ***	(0,02)	0,06 **	(0,02)
yıl_2023	0,41 ***	(0,02)	0,39 ***	(0,02)	0,44 ***	(0,03)
Koşulu yok	-0,05	(0,01)	-0,07	(0,02)	-0,02	(0,03)
Potansiyel işgücü	0,04 ***	(0,01)				
N	2.839		1.702		1.137	
R squared	0,26		0,27		0,25	
*** p < 0,01; ** p < 0,05; * p < 0,1.						

Regresyon analizinin bir diğer ilginç bulgusu, ıssızlar ile potansiyel işgücü katsayılarında gözlemlenen farklılıklarlardır. Potansiyel işgücüne mensup kadınların katsayısı (-0,11) iş arayan kadınların kat sayısından (-0,15) daha düşüktür. Diğer ifadeyle potansiyel işgücündeki kadınların rezervasyon ücreti iş arayan kadınlarından daha yüksektir. Öte yandan potansiyel işgücünde katsayı lise üstü düzeyde belirgin olarak yüksektir: 0,14'e 0,19. Bu durum, daha sınırlı ölçüde, 2022 ve 2023 yılları için de geçerlidir. Potansiyel işgücünde olanlar aktif olarak iş aramadıkları için ücret ve işin niteliği konusunda daha talepkâr davranışları olabilirler.

İssızlar ve potansiyel işgücü mensuplarını toplu olarak ve ayrı ayrı dikkate alarak yapılan regresyona ilaveten ıssızlere (aktif olarak iş arayanlara) özgü etkenleri irdelemek

icin işsizlere odaklanan bir regresyon da yapılmıştır. Yeni değişkenler, iş arama ve iş tecrübesi ile işsizlik süresinden oluşmaktadır. Sonuçlar Tablo 4'te gösterilmiştir. İlk sütun daha önce çalışmamış olan işsizlere odaklanmaktadır. İlk kez iş arayan bu kişiler 3 gruba ayrılmıştır: öğrenciler, yeni mezunlar ve diğerleri (eski mezunlar). Eski mezunlar ile öğrencilerin (*ilk_is_ogrenci*) rezervasyon ücreti arasında istatistiksel açıdan anlamlı bir fark yoktur. Fakat, eski mezunlar ile kıyaslandığında yeni mezunların (*ilk_is_yeni_mezun*) rezervasyon ücreti daha yüksektir. İkinci ve üçüncü sütunlar ise iş tecrübesi ve koşul sahibi olmanın etkisine odaklanmaktadır. Daha önce hiç çalışmış olanlarla kıyaslandığında çalışmamış olanların (*is_tec_yok*) rezervasyon ücreti daha düşüktür. Deneyim sahibi olmak ücretleri artırdığı için bu sonuç da beklenen bir sonuctur. Son olarak bir yıldan daha uzun bir süredir iş arayanlar ile bir yıldan daha az bir süredir iş arayanlar arasında bir fark gözükmedigini belirtelim. Beklentimiz işsizlik süresi uzadıkça rezervasyon ücretlerinin düşmesi idi. Her ne kadar tahmin ettiğimiz katsayı anlamsız olsa da işsizlik süresinin rezervasyon ücretlerine etkisi aslında negatif olabilir. Rezervasyon ücreti daha yüksek olan kişilerin bir takım doğrudan gözlemlenmeyen özellikleri diğerlerinden farklı olabilir ve bu farklılıklar sebebiyle bazı kişiler hem daha yüksek rezervasyon ücretine hem de daha yüksek işsizlik süresine sahip olabilir. Bu da yanlışlık yaratarak işsizlik süresi ile rezervasyon ücreti arasındaki ilişkinin doğru şekilde tahmin edilmesine müsaade etmemektedir.⁶

⁶ Bu uyarı için hakeme teşekkür ediyoruz.

Tablo 4. Regresyon analizi (sadece işsizler)

	(1)		(2)		(3)	
(Intercept)	8,64 ***	(0,04)	8,69 ***	(0,02)	8,71 ***	(0,02)
25-44 yaş grubu	0,07 **	(0,03)	0,14 ***	(0,02)	0,14 ***	(0,02)
45-69 yaş grubu	0,07 *	(0,04)	0,11 ***	(0,02)	0,11 ***	(0,02)
Kadın	-0,09 ***	(0,02)	-0,14 ***	(0,01)	-0,15 ***	(0,01)
Lise	-0,02	(0,03)	0,02	(0,02)	0,02	(0,02)
Lise Üstü	0,12 ***	(0,03)	0,15 ***	(0,02)	0,14 ***	(0,02)
yıl_2022	0,08 ***	(0,03)	0,05 ***	(0,02)	0,05 ***	(0,02)
yıl_2023	0,40 ***	(0,03)	0,41 ***	(0,02)	0,40 ***	(0,02)
ilk_is_ogrenci	-0,02	(0,03)				
ilk_is_yeni_mezun	0,07 **	(0,03)				
1+ yıldır işsiz	0,03	(0,03)	-0,01	(0,01)	-0,00	(0,01)
is_tec_yok			-0,05 ***	(0,02)	-0,05 ***	(0,02)
kosulu_yok					-0,06 ***	(0,02)
N	570		1702		1702	
R squared	0,30		0,27		0,27	

*** p < 0,01; ** p < 0,05; * p < 0,1.

Regresyon analizlerini yorumlarken benzer karakteristiklere sahip kadın ve erkeklerin neden farklı rezervasyon ücretine sahip olduklarını açıklarken bir olasılığın “doğrudan gözlemlenemeyen bazı nedenlerle kadınların daha düşük ücretli işlere başvurmayı tercih etmeleri” olabileceğini belirtmiştik. Örnek olarak ise toplumsal değerlerin dayattığı iş bölümünün sonucu kadınların mesai saatlerinde esneklik, işin ağır olmayacağı ve işyerinin eve yakın olması gibi kriterler gözetebileceğini ifade etmiştir. Biraz da bu hipotezleri test etmek amacıyla 2023 yılı anketinde rezervasyon ücreti için haftada çalışılması planlanan gün ve günlük çalışma süresini sorduk. Veriler erkek ile kadın arasında çalışılmak istenen gün bakımından fark olmadığını, fakat günlük çalışma saatı açısından bir fark olduğunu gösteriyor (bkz. Tablo 5). Kadınların, erkeklerle kıyasla ortalamada 1,43 saat (yüzde 16) kadar daha az çalışmayı istedikleri anlaşılmaktadır. Kadınlar talep ettikleri rezervasyon ücreti de yaklaşık olarak yüzde 14 kadar daha düşük olduğu için kadın-erkek arasında gözlemlenen rezervasyon ücreti farkının büyük oranda çalışılmak istenen saatlerin farklılığından kaynaklandığı söylenebilir.

Tablo 5. Çalışılmak istenen gün ve saat

	(saat)		(gün)	
(Intercept)	8,95 ***	(0,32)	5,28 ***	(0,07)
Kadın	-1,43 ***	(0,41)	0,03	(0,09)
N	275		275	
R squared	0,04		0,00	

*** p < 0,01; ** p < 0,05; * p < 0,1.

Daha önce dejindiğimiz gibi, veri eksikliğinden dolayı Türkiye için kadın-erkek ayrimında rezervasyon ücreti iktisat yazısında pek çalışılmış bir konu değildir. Bu sebeple de kadınların daha yüksek işsizlik oranlarını açıklarken, en azından bugüne kadar, başvurulan muhtemel açıklamalardan biri kadınların rezervasyon ücretlerinin daha yüksek olduğu idi. Çalışmamız bunun tam tersini gösteriyor. Peki yüksek işsizlik oranları ile düşük rezervasyon ücreti nasıl bir arada gözlemlenebilir? Öncelikle rezervasyon ücretleri ile işsizlik arasında kesin, tekyönlü bir nedensellikten bahsetmek mümkün değildir. Kadınların rezervasyon ücretleri yüksek olduğu için işsizlik oranları yüksek olabileceği gibi işsizlik oralarının erkeklerle göre daha yüksek olduğunu gören kadınlar rezervasyon ücretlerini düşük tutmayı da tercih edebilir. Nedenselliğin yönü ile ilgili bu eşzamanlılık (*simultaneity*) probleminden dolayı nedenselliğin yönüne dair kesin bir yorum yapmak mümkün değilse de yüksek işsizlik oranları ile düşük rezervasyon ücretlerinin bir arada gözlemlenmesi mümkün değildir. Ayrıca, doğrudan gözlemlenmeyen birtakım nedenlerle (başvurulan işin zorluğu, işyerinin eve yakınlığı, mesai saatlerinin esnekliği vb.) kadınlar hem daha düşük bir ücrette çalışmayı kabul ederken hem de daha yüksek işsizlik oranlarına sahip olabilir. Nitekim, bunu ima eden bulgular yukarıda Tablo 5'te okuyucunun dikkatine sunulmuştur. Son olarak, Danimarka verilerini kullanan Flutchmann vd. (2023) kadınların çoğunlukla düşük ücretli ama nispeten esnek işlere başvurduklarını göstermektedir. Tüm bu sebeplerle kadınlardaki yüksek işsizliğin sebeplerini rezervasyon ücreti dışında kalan sosyokültürel faktörlerde aramak daha doğru olacaktır.

6. Sonuç

İstanbul İşgücü Piyasasında gün geçtikçe işgücü arzı ile talebi arasında bir uyumsuzluk sorununun büyüğünü gözlemliyoruz. Bir tarafta mevcut asgari ücret seviyesinde eleman arayan fakat çalıştıracak insan bulamamaktan şikayet eden firmalar bulunurken diğer tarafta azımsanmayacak bir işsizlik oranı söz konusu. Bu çalışmada bu sorunun farklı boyutlarına ışık tutmaya çalıştık. Regresyon analizi sonuçlarına göre

İstanbul'da kadınların rezervasyon ücreti erkeklerle kıyasla daha düşüktür. Hiç çalışmamış olanlarla kıyaslandığında çalışmış olanların rezervasyon ücreti daha yüksektir. İşsizlere kıyasla potansiyel işsizlerin rezervasyon ücreti daha yüksektir. Bir iş kabul ederken bir koşul belirtenler koşulum yok diyenlere kıyasla daha yüksek rezervasyon ücretine sahiptirler. Son olarak, regresyon analizi işsiz kalınan sürenin rezervasyon ücretine doğrudan bir etkisi olmadığını göstermektedir.

Yaptığımız analizler rezervasyon ücretinin geçmiş enflasyonu değil asgari ücreti referans aldığı ortaya koymaktadır. Bu iddiamızı destekleyen olgu TÜFE endeksi ile reelleştirdiğimiz *reel rezervasyon ücret* dağılımı ile rezervasyon ücretlerinin asgari ücrete oranı olarak tanımladığımız *göreli ücret* dağılımının kıyaslamasına dayanmaktadır. 2021 ve 2022 yılları ile kıyaslandığında reel rezervasyon ücreti seviyesi 2023 yılında daha yüksektir. Bunun nedeni ise 2023 yılında asgari ücretin cumhurbaşkanlığı seçimleri etkisiyle TÜFE üzerinde artış göstermesidir. Nitekim, göreli ücrette baktığımızda üç yılın da çok büyük bir benzerlik gösterdiği anlaşılmaktadır.

Yukarıda sıralanan bulgulara rağmen rezervasyon ücreti ile ilgili eksik kalan pek çok boyut vardır. İlk akla gelenlerden bir tanesi cinsiyet temelinde gözlemlenen farkın ne oranda başvurulan işin türünden kaynaklandığıdır. Eğer kadınlar daha düşük ücretli işlere başvuruyor ise beyan ettikleri ücretlerin de daha düşük olması şaşırtıcı olmayacağındır. Eğer böyle bir durum söz konusu ise bu durum gözlemlenen farkın ne kadarını açıklamaktadır? Bir diğer önemli boyut rezervasyon ücreti dinamiklerinin bölgesel olarak ne oranda farklılık gösterdiğidir. Dönem dönem tartışılan bölgesel asgari ücret tartışmalarını daha verimli ve sağlıklı şekilde yürütebilmek için rezervasyon ücretlerinin bölgesel düzeyde ne kadar ayırttığını bilmek gereklidir.

Kaynakça

- Bloemen, H. G. ve Stancanelli, E. G. (2001). Individual wealth, reservation wages, and transitions into employment. *Journal of Labor Economics*, 19(2), 400-439.
- Brown, S., Roberts, J. ve Taylor, K. (2011). The gender reservation wage gap: evidence from British panel data. *Economics Letters*, 113(1), 88-91.
- Caliendo, M., Fedorets, A., Preuss, M., Schröder, C. ve Wittbrodt, L. (2017). The Short-Term Distributional Effects of the German Minimum Wage Reform.
- Filiztekin, Alpay. (2018). Üniversite Mezunlarının Diploma Alanlarına Göre İşgücündeki Yerleri. E. Aslanoglu, N. Engin, O. Erdogan ve C. Karahasan (Der.). *Türkiye Ekonomisinde Kalkınma ve Dönüşüm, Taner Berksoy'a Armağan*. İçinde (s. 315-340). İstanbul: Imge Yayıncıları.
- Flutchnmann, J., Glenny A., Harmon N. ve Mailbom J., (2003). The Gender Application Gap: Do men and women apply for the same jobs?, IZA DP No. 14906.
- Goldin, C. (2019). Human Capital. C. Diebolt ve M. Haupert (Der.), *Handbook of Cliometrics*. İçinde (s. 147-177) Springer.
- Haurin, D. R. ve Sridhar, K. S. (2003). The impact of local unemployment rates on reservation wages and the duration of search for a job. *Applied economics*, 35(13), 1469-1476.
- Istekli, M., ve Senturk, İ. (2016). Determinants Of Reservation Wages In Turkey. *Journal of Business Economics and Finance*, 5(2), 258-266.
- Le Barbanchon, T., Rathelot, R. ve Roulet, A. (2021). Gender Differences in Job Search: Trading off Commute Against Wage. *The Quarterly Journal of Economics*, 136(1), 381–426.

BEYANLAR:

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

Yazarların Makaleye Katkı Oranları: Birinci yazarın makaleye katkısı %50, İkinci yazarın makaleye katkısı %50'dir.

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

Araştırma Desteği ve Teşekkür: Bu araştırma herhangi bir kurum tarafından desteklenmemiştir.

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

Ekler

Ek Tablo 1. İşsiz alt örneklemi içinde kadın ve erkek eğitim ve yaş dağılımı farkları

İşsiz		N		Pay (%)	
Değişken	Kırılım	Kadın	Erkek	Kadın	Erkek
Eğitim	Lise Altı	444	581	41,7	55,9
Eğitim	Lise Üstü	366	227	34,3	21,8
Eğitim	Lise	256	231	24,0	22,2
Yaş grubu	15-24	295	195	27,7	18,8
Yaş grubu	25-44	517	399	48,5	38,4
Yaş grubu	45-69	249	433	23,4	41,7
Yaş grubu	70+	5	12	0,5	1,2

Ek Tablo 2. Potansiyel işgücü alt örneklemi içinde kadın ve erkek eğitim ve yaş dağılımı farkları

Potansiyel İşgücü		N		Pay (%)	
Değişken	Kırılım	Kadın	Erkek	Kadın	Erkek
Eğitim	Lise Altı	386	246	48,6	50,0
Eğitim	Lise Üstü	202	91	25,4	18,5
Eğitim	Lise	206	155	25,9	31,5
Yaş grubu	15-24	161	128	20,3	26,0
Yaş grubu	25-44	395	133	49,7	27,0
Yaş grubu	45-69	235	217	29,6	44,1
Yaş grubu	70+	3	14	0,4	2,8

**Adil Geçişi Planlamak:
Yeşil Dönüşümü Adil Kılmak İçin Bir Çerçeve Önerisi**

Can PORTAKAL*

Işılsu TAMCI**

Sevil ACAR***

Öz

“Adil Geçiş”, küresel iklim felaketine karşı yeşil ve sürdürülebilir bir ekonomik dönüşümü sağlama planlaması içerisinde toplumların refahını, hakkaniyetli ve kapsayıcı bir şekilde sağlamayı amaçlayan kamucu bir politika çerçevesi olarak karşımıza çıkmaktadır. Bu çalışma, Adil Geçiş politika çerçevesinin detaylı bir dökümünü içerirken aynı zamanda başta Avrupa Birliği'nin Adil Geçiş Mekanizması olmak üzere hayata geçirilmeye başlanmış Adil Geçiş süreçlerine ışık tutmaktadır. Deneyimlenen süreçlerden de anlaşıldığı üzere adil bir geçiş sürecinin yeşil dönüşüm kapsamında gerçekleştirilebilmesi ve kamusal yararı gözeterek eyleme geçirilmesi için toplumun, sivil toplum örgütlerinin, sendikaların ve devletin işbirliği, planlama, finansman yeterliliği gibi pek çok faktörün hassas ve dengeli bir uyumla bir araya gelmesi gerekmektedir. Adil Geçiş sürecinin başarılı olabilmesi için her bölgeye uygun tek bir yol ya da formül bulunmamaktadır. Ülkeler, kendi politika araçlarını ve düzenlemelerini yine kendi iktisadi ve sosyo-kültürel koşullarına dayanarak üretmeli ve hayata geçirmelidir.

JEL Kodları: Q52, Q56, Q58, R11

Anahtar Kelimeler: adil geçiş, adil geçiş fonu, adil geçiş mekanizması, Avrupa yeşil mutabakatı, iklim krizi, yeşil dönüşüm

* Boğaziçi Üniversitesi, Ekonomi Bölümü, İstanbul, can.portakal@std.bogazici.edu.tr,
<https://orcid.org/0009-0007-2542-911X>

** Özyegin Üniversitesi, Endüstri Mühendisliği Bölümü, İstanbul, isilsu.tamci@ozu.edu.tr,
<https://orcid.org/0009-0002-2042-7899>

*** (İletişim Yazarı) Boğaziçi Üniversitesi, Turizm İşletmeciliği Bölümü, İstanbul,
sevil.acar@bogazici.edu.tr, <https://orcid.org/0000-0001-5535-8673>

Planning the Just Transition: A Framework Proposal for Making Green Transformation Fair

Abstract

“Just Transition” emerges as a public policy framework that aims to ensure the welfare of societies in an equitable and inclusive manner within the planning of a green and sustainable economic transformation against the global climate disaster. This study includes a breakdown of the “Just Transition” policy framework, while also shedding light on the Just Transition processes of the European Union. As can be understood from the experience, in order for a just transition process to be realized within the scope of green transformation and to take action in the public interest, many factors such as cooperation, planning and financing adequacy of the society, civil society organizations, unions and the state must come together in harmony. There is no single path suitable for every region for the Just Transition process to be successful. Countries must implement their own policy instruments and regulations based on their own economic and socio-cultural conditions.

JEL Codes: Q52, Q56, Q58, R11

Keywords: just transition, just transition fund, just transition mechanism, European green deal, climate crisis, green transformation

1. Giriş

Dünya tarihinin en büyük ve en kapsamlı krizlerinden biri haline gelen, milyarlarca insanı etkileyebilecek olan iklim krizi, sanayileşme ve buna bağlı modernleşmenin bir sonucu olarak medeniyetimizin istenmeyen ancak göz ardı edilemeyecek bir “yan ürünü” olarak algılandı. İklim krizi ve beraberinde getireceği felaketler zinciri politika yapıcılar ve çeşitli kamuoyu çevreleri tarafından 20. yüzyılın ortalarına kadar kamusal tartışma alanına taşınmadı. Kapsayıcı, adil ve çözüm odaklı bir politika çerçevelendirmesine ancak İkinci Dünya Savaşı sonrasında gerçekleşen küresel kalkınma yıllarının ardından, 20. yüzyılın sonlarına doğru kavuşmaya başladı. Bu bağlamda, iklim krizine karşı alınacak küresel çapta bir dizi önlem hayata geçmeye başladı. 1997 yılında imzalanan Kyoto Protokolü ve 2015 Paris İklim Anlaşması gibi bazı önemli aşamalar iklim krizi ile mücadelenin çerçevesini çizmek için önemli olsa da, iklim krizine karşı alınacak önlemlerin kısa ve orta vadelerde yaratacağı olumsuz sosyal, kültürel ve ekonomik etkilerin hafifletilmesi meselesi ile ilintili kamu politikaları, ancak “Adil Geçiş” (Just Transition) kavramının varlığı ile birlikte gündeme gelmiştir. Adil Geçiş, sürdürülebilir kalkınma odaklı ekonomik ve sektörel dönüşümden sosyal, kültürel ve ekonomik olarak etkilenen bireyleri koruma altına almaya, maddi ve manevi desteklemeye, “insan onuruna yakışır işler” kapsamında yeni istihdam alanlarında istihdam etmeye odaklanmaktadır. Uluslararası Çalışma Örgütü’nün (ILO) tanımına göre Adil Geçiş, *“ekonomiyi yeşil ve sürdürülebilir hedefler doğrultusunda dönüştürürken aynı zamanda dönüşümden etkilenen herkes için ‘insan onuruna yakışır işler’ yaratarak hiçbir bireyi geride bırakmamayı önceler”* (ILO, 2015). Uluslararası Sendikalar Konfederasyonu (ITUC) tanımına göre ise Adil Geçiş, *“düşük karbonlu bir ekonomiye geçişte işçilerin ve toplulukların geleceğini ve değişim kaynaklarını güvence altına alır. İşçiler ve sendikaları, işverenler ve hükümet arasındaki sosyal diyalog'a ve topluluklar ve sivil toplumla istişareye dayanır. Adil Geçiş planı, küresel ısınma ve iklim değişikliği politikalarından etkilenen tüm çalışanlar için daha iyi ve insan onuruna yakışır işler, sosyal koruma, daha fazla eğitim fırsatı ve daha fazla iş güvenliği sağlar ve garanti eder.”* (ITUC, 2016). Hem iklim krizine karşı alınan aksiyonlar sonucu ekonomik ve sosyal dönüşümden etkilenen tarafları (bireyleri, haneleri, toplulukları) korumak hem de dönüşümü adil ve sürdürülebilir kılmak açısından adil geçişin ulusal, bölgesel ve yerel ölçeklerde tutarlı bir biçimde planlanması ve hayata geçirilmesi gerekmektedir.

İklim krizi ile mücadele en başta sera gazı emisyonlarına en fazla katkı sağlayan enerji sektöründe dönüşümü gerektirdiği için adil geçişin öncelikli olarak hedeflemesi gereken alanlar da fosil yakıt yoğunluklu iktisadi aktiviteye dayalı olarak şekillenen bölgelerdir. Kömür, petrol, doğal gaz faaliyetlerinin yaygın olduğu bölgelerde adil geçişten en çok etkilenenecek kesim, bu sektörlerde istihdam edilenlerdir. Avrupa Birliği (AB) ülkelerinden örnekle, güncel verilere göre üye ülkelerde yaklaşık 238 bin insan, kömür sektöründe istihdam edilmektedir (Widuto, 2019). Yine aynı

çalışmaya göre, 2030 yılına kadar AB'nin sera gazı salımını azaltmak üzere hayatı geçireceği eylem planları sebebiyle yaklaşık 160 000 iş kaybının yaşanacağı öngörlülmektedir. Uluslararası Enerji Ajansı'nın hazırladığı rapora göre (IEA, 2022), dünya genelinde doğrudan veya destekleyici olarak 65 milyon kişi enerji sektöründe istihdam edilmektedir. Bu sayı, iklim krizinden etkilenmesi beklenen diğer sektörleri de ele aldığımızda 1,4 milyar kişiye çıkmaktadır. Ek olarak, 2030 yılına kadar düşük karbonlu ekonomilere geçiş sebebiyle dünya genelinde yaklaşık 6 milyon insanın işini kaybetmesi beklenmektedir. Sayıların büyülüğu göz önüne alındığında; kapsayıcı, adil, hakkaniyetli ve çözüm odaklı bir anlayışla kamucu politikaları iklim değişikliği bağlamında hayata geçirmenin önemi daha iyi anlaşılabilir. ILO (2015)'e göre Adil Geçiş sürecinin özelliklerini şunlar olmalıdır:

- İnsan onuruna yakışır işler yaratılması
- Kapsayıcılık ve sosyal içерme
- Toplumsal eşitsizliğin ve yoksulluğun azaltılması

Başka bir deyişle, iklim değişikliği ve diğer sorunlarla mücadele ederken yeni iş yaratma, sosyal adaleti sağlama, çalışanlar, iş dünyası ve farklı toplum kesimleri için adil bir geçiş sağlama Adil Geçiş süreçlerinin genel özellikleri olmalıdır (ILO, 2015).

Bu çalışmada ikinci bölümde yukarıda tanıtılmış ve çerçevesi çizilen “Adil Geçiş” sürecinin sivil toplum ve politika yapıcılardan nezdinde tarihsel şekillenmiş süreci incelemekte, üçüncü bölümde Adil Geçiş tasarımda politika ve düzenlemelerin rolü ile sosyal diyalog ve paydaş katılımının önemi vurgulanmaktadır. Dördüncü bölümde planlı bir örnek olarak Avrupa Komisyonu'nun Adil Geçiş politika çerçevesi olan “Adil Geçiş Mekanizması”, fonlama ve politika çerçevesi bakımından detaylıca ele alınmaktadır. Beşinci bölümde Adil Geçiş süreç tasarımları için genel bir çerçeve önerisi sunulmakta, altıncı bölümde ise sonuç ve önerilere yer verilmektedir.

2. Adil Geçiş'in Tarihsel Arka Planı

Kanadalı işçi sendikası liderleri tarafından 1990'lı yılların sonunda ilk kez çerçevesi ortaya konan “Adil Geçiş” kavramının tarihsel gelişimine baktığımızda, pek çok kavram ve politika setinde olduğu gibi, burada da pek çok mücadelenin ve birbirine girift olan aşamaların izlerine rastlanmaktadır. İlk olarak Amerikalı işçi hakları ve çevre aktivisti Tony Mazocchi tarafından dillendirildiği düşünülen “Adil Geçiş”, başlangıçta sendikal hareketlerin, işçilerin “insana yakışır işler” çabaları ile çevreyi koruma ihtiyaçlarını uzlaştırma girişiminin organik bir sonucu olarak ortaya çıkmıştır (The Scottish Government, 2020). Burada Adil Geçiş'in şekillenisinin tarihine odaklanmaktan önce, “insana yakışır işler” kavramsallaştırmasının tanımını ve çerçevesini vermek gereklidir. Zira Adil Geçiş kavramının alt başlıklarını ve bu kavramı

oluşturan çerçeveyi detaylıca anlamadan, Adil Geçiş mekanizmasının içsel dinamiklerini ve bu konuda yürütülen tartışmaları anlamak da mümkün olmayacağından. ILO'nun yaptığı tanıma göre (ILO, n.d.) İngilizce'de bilinen adıyla "decent work", Türkçe çevirisi ile "insan onuruna yakışır işler", işgücüne katılan her kesimden insanın eşit, özgür, güvenli ve insan onurunu zedelemeyecek şekilde tasarlanmış çalışma koşullarına sahip işlerde çalışmalarını güvence altına alır. Bu bağlamda insan onuruna yakışır işler, ITUC ve ILO tarafından işçi ve iklim hareketleri arasında bir köprü kurmayı amaçlayan tartışmalarda ele alınmaya başlanır ve Adil Geçiş mekanizmasını oluşturan önemli kavamlardan biri haline gelir.

Toplumsal çerçevesi 70'li yıllarda şekillenmeye başlayan ve 90'lı yıllarda tekrar büyük bir kuvvetle gündeme gelen çevre hareketlerini, 80'li yılların başında küresel boyutta değişiklik göstermiş bulunan ekonomi politikalarına bağlayan bir literatürün varlığı da değerlendirdiğinde, 90'lı yılların işçi ve çevre hareketlerinin ortak bağlamından, "Adil Geçiş" kavramının doğması sürpriz görünmemektedir. 90'lı yılların politik atmosferinden doğan bu kavram, kendini günümüze taşımayı başaracak ve günümüzün çevresel ve politik sorunlarına uyum sağlayacaktır. 2019 yılının sonunda dünya çapında patlak veren Covid-19 pandemisinin yarattığı sosyal eşitsizliğin etkileri, Adil Geçiş kavramının politika setleri içerisinde daha fazla yer almasıyla sonuçlanmıştır. Özellikle 14 Ocak 2020 tarihi, Adil Geçiş kavramının tarihçesi açısından önemli bir milat olarak görülebilir. Zira bu tarihte, Avrupa Komisyonu ilk kez Adil Geçiş Fonu'nu (Just Transition Fund (JTF)), uygulanması hedeflenen politika setlerine resmen dahil etmiştir. Koronavirüs pandemisinin küresel çapta ses getirmeye başladığı bu tarihlerde AB, görece hızlı aksiyon alarak karbon salımının yüksek olduğu sanayi üretimine sahip bölgelerin "karbonsuzlaştırılması" sürecinden ekonomik olarak en fazla etkilenenek bölgeleri "Adil Geçiş Mekanizması" kapsamına dahil etti ve ilgili yasa teklifini Avrupa Parlamentosu'na sundu. 28 Mayıs 2020 tarihinde, pandeminin seyrinin kıta Avrupası ve dünya genelinde kötü seyretmesi üzerine ilgili yasa teklifinde Adil Geçiş Fonu için başlangıçta öngörülmüş olan 7,5 milyar Avro miktarındaki bütçe 40 milyar Avroya (2018 sabit fiyatları ile) çıkarıldı. 17-21 Temmuz 2020 Avrupa Konseyi liderler zirvesinde, belirlenen mikarda ve 2021-2027 bütçelerinde anlaşma sağlandı, fakat daha sonra belirlenen miktar toplamda 17,5 milyar Avroya düşürüldü (Avrupa Komisyonu, 2020a). Bu miktarın daha sonraları yükseltileceği konuşulsa da nihai miktar 17.5 milyar Avro olarak kabul edildi (Widuto, 2019).

3. Adil Geçiş Nasıl Tasarlanabilir? Politika ve Düzenlemelerle Adil Geçişi Planlamak

Küresel ısınmaya ilişkin en fazla 1,5°C sıcaklık artış hedefini tutturmayı amaçlayan bir iklim politikası, dünya genelinde hükümetlerin kömür, petrol ve doğalgaz gibi fosil yakıtlardan tamamen uzaklaşmalarını gerektirmektedir. 2022 itibariyle enerjiden kaynaklı CO₂ emisyonlarının %40'ından fazlası, elektrik üretimi için fosil yakıtların yakılmasından kaynaklanmaktadır, fosil yakıt emisyonları içinde en büyük payı da kömür oluşturmaktadır (IEA, 2023a). Eğer bu sektörlerde verilen teşvikler kaldırılırsa fosil yakıt yoğunluklu enerji projelerinin birçoğundan vazgeçilmesi, yatırımların yenilenebilir enerjiye kayması beklenmektedir, zira özellikle kömür gibi kirli kaynaklardan elde edilen elektrik yenilenebilir enerjiye kıyasla gitgide daha pahalı hale gelmekte, kömür sektörü teşviklerle ayakta durabilmektedir. Carbon Tracker Initiative'in (CTI, 2022) yaptığı analize göre 1 trilyon doları aşan petrol, kömür ve gaz varlığı, iklime yönelik politika eylemleri ve alternatif enerji kaynaklarındaki artışın bir sonucu olarak atıl kalma (*stranded assets*) riski taşımaktadır.

Bu kaynaklardan özellikle kömür, bulunduğu bölgelerde sektörel çeşitlilik de yoksa önemli düzeyde istihdam yarattığı için, kömürden çıkışın bizzat kömür sektörlerinde çalışanlar için yadsınamaz iktisadi ve sosyal etkileri olacaktır. Girişte de bahsedildiği gibi, kömürden çıkışın kitlelerin hakkını gözeten, adil ve kapsayıcı bir şekilde gerçekleştirilebilmesi için belli eylem planları takip edilmelidir. ILO (2015)'e göre bu eylem planları dört aşamadan oluşmaktadır: işgücü piyasası politikaları, eğitim ve beceri geliştirme, sosyal koruma ve güvenlik, damışma ve sosyal diyalog. Yapılandırılmış bir eylem planı takip edilmediği sürece kömürden çıkış gerek bu çıkışın yapıldığı bölge ekonomisine gerekse büyük ölçüde ülke ekonomisine ciddi zararlar verebilir. Bu bağlamda, öncelikle kömürden çıkışta dikkat edilmesi gereken adımları kapsamlı bir şekilde ele alacağız.

3.1. İstihdam Politikaları

ILO (2015)'e göre iklim politikaları ve bunlara bağlı olarak kömürden çıkış, işgücü piyasasını aşağıda anlatıldığı şekilde, birkaç farklı yönden etkileyebilir: Doğaya daha az zarar veren ürünlerin, hizmetlerin ve altyapının geliştirilmesi sayesinde belli sektörlerde işgücü ihtiyacı doğacaktır. Bu sektörde yenilenme ve çeşitlilik sayesinde yeni iş kolları ortaya çıkabilir. Ya da halihazırda mevcut karbon salımı yapmakta olan sektörlerin yerlerini verimlilik bakımından daha avantajlı, karbon salımı daha düşük ve sektörler alabilir. Kirletici sektörler aşamalı olarak küçültülebilir veya ortadan kaldırılabilir. Bu sayede mevcut istihdam alanlarının çoğu yeşil dönüşümün etkisiyle yeniden değerlendirilmek zorunda kalınabilir. Yapılan araştırmalar işgücü piyasasında, sektör bazda dönüşümde en çok etkilenecek alanların başında enerji sektörü ve bu sektördeki işlerin geleceğini göstermektedir (örneğin Pollitt vd., 2014; Blazejczak vd.

2014; REN21, 2015; Borbonus, 2017; Garrett-Peltier, 2017; Garcia-Casals vd., 2019; REN21, 2020; O'Sullivan ve Edler, 2020). Özellikle rüzgâr ve güneş enerjisinde artan yatırım ve azalan maliyetler yenilenebilir enerji genişlemesinin arkasında itici güç olmuştur. Enerji sektörünün yanında, iklim politikaları ve yeşil dönüşüm, tarım ve hizmet sektöründe de yeni iş imkanları yaratabilir. Fakat ortaya çıkan yeni iş imkanlarının daha adil bir şekilde dağılabilmesi için işgücü politikalarının yeniden düzenlenmesi gerekmektedir (ILO, 2015). Örneğin iş arama yardımı ve danışmanlık, istihdam kalitesinin artırılması ve beceri uyumsuzluğunu azaltmak için eğitimlerin düzenlenmesi gibi destekler işgücü talebini artırmayı amaçlar. Yeşil sektörlerde iş yapacaklara girişimcilik teşvikleri ve yoksullara gelir ve iş imkânı sağlamayı amaçlayan kamu istihdam programları, istihdam olanaklarının daha adil ve hakkaniyetli dağılabilmesi için geliştirilebilecek politikalara örnek olabilir. Bu politika araçlarının bir kısmı kısa ve orta vadede uygulanabilirken, bazıları ise uzun vadede etkili olacaktır.

3.2. Eğitim ve Yeni Beceri Kazandırma

Yeşil dönüşüme bağlı olarak yeni sektörlerde iş edinebilmek ve rekabet edebilmek için işgücünün beceri donanımlarında da değişim ve buna yönelik eğitim gerekmektedir. ILO (2015)'e göre beceri geliştirme sürecinin önünde iki temel zorluk bulunmaktadır: doğru teknik ve mesleki eğitimin sağlanması ve yeşil dönüşümden dolayı işsiz kalanların yeniden eğitilerek istihdama katılımlarının sağlanması. Doğru teknik ve mesleki eğitimin verilebilmesinin önündeki bazı engeller bulunabilir. Örneğin, görece yaşlı ve göçmen nüfusun eğitilmesi ve farklı beceri donanımının kazandırılması genç ve dinamik nüfusu eğitmeye kıyasla daha zor olabilir. Ayrıca, yeşil dönüşümle ortaya çıkacak yeni işler, coğrafi ve sosyolojik farklılıklar sebebiyle yeşil dönüşümden olumsuz etkilenen bölgelerde ortaya çıkmayabilir. Bu noktada, adil geçiş politikalarının etkilerinin bölgeden bölgeye farklılık gösterebileceği anlaşılmaktadır. Bu sebeple, dönüşümden etkilenen bölgelerde adil bir geçişin sağlanabilmesi, bölgenin sosyolojik, ekonomik ve kültürel yapısının ayrıntılı analiz edilmesini gerektirmektedir (ILO, 2015).

3.3. Sosyal Güvenlik

İklim krizinden en çok etkilenenecek tarım, balıkçılık, turizm, ormancılık gibi sektörlerde kayıt dışı çalışma durumu oldukça yaygındır. Bu nedenle iklim politikalarında sosyal güvenliği sağlamak dikkate alınması gereken diğer önemli bir husus olmalıdır. Bu konudaki örneklerden biri tüketicilere verilen fosil yakıt teşvikleriyle ilgilidir. Uluslararası Enerji Ajansı (IEA)'nın son tahminlerine göre, 2022'de dünya çapında fosil yakıt tüketimine yönelik teşvikler 1 trilyon doların üzerine fırlayarak yıllık düzeyde rekor sevilere ulaşmıştır (IEA, 2023b). Tüketicilere yönelik fosil yakıt teşviklerinin kaldırıldığı durumda bu durumdan olumsuz etkilenenecek hanelere sosyal yardımlar devam etmelidir. Aksi halde gıda, ısnama ve enerji gibi pek çok temel kalem, haneler için erişilebilir olmaktan çıkabilir. Ayrıca kömür madenciliği,

enerji/elektrik üretimi gibi geçişten olumsuz etkilenen sektörlerdeki işletmeleri ve çalışanları desteklemek için işsizlik sigortası ve yardımları, sosyal güvenliğin taşınabilirliği, beceri kazandırma, işgünün başka lokasyonlara kaydırılması gibi önlemleri içeren sosyal koruma politikalarının oluşturulması gereklidir (ILO, 2015).

Öte yandan, kurumsal kapasitenin, kamu politikası yapma ve uygulama gücünün sınırlı olduğu ülkelerde sosyal güvenlik sistemleri oluşturmak, meşakkatli ve zor bir politika yapım sürecine sahne olabilir. Bu sebeple iklim politikaları hazırlanırken; tazminat ödemeleri gibi sosyal güvenliği sağlamak için önlemlerin alınması gereklidir. Alınabilecek bu önlemlerle ülkeler ve bölgesel kurumlar iklim politikalarının uygulanması için gereken sosyal güvenlik sistemlerini sağlamakta daha başarılı olabilirler (ILO, 2015).

3.4. Toplumsal Bilinç Kazandırma, Diyalog ve Paydaş Katılımı

Adil geçiş politikaları arasında gerekli olan bir diğer önemli faktör ise sosyal diyalogdur. Bu politikaları hayatı geçirecek mercilerin, sürecin işleyişini kamuoyuna ve kanaat önderlerine anlatmaları gereklidir. Bu sayede uygulanmakta olan ya da uygulanacak olan geçiş politikaları sonucunda ortaya çıkacak fırsatları görmek ve zorlukları aşmak daha kolay olabilir. ILO (2015) yayınladığı adil geçiş kılavuzunda sosyal diyalogun işletme, sektör ve ulusal ölçekte yapılması gereğinin üzerinde durmuştur. Kömürden çıkışla beraber bölgelerde sosyal, kültürel ve iktisadi bir dönüşüm de söz konusudur. Bu dönüşüm dışarıdan bir etki sonucunda meydana geldiği için, belli noktalarda toplumları ve kamuoyunu endişelendirebilir ve toplum kesimlerini “aydın, şehirli çevreciler” ve “yerel halk” şeklinde iki kutba ayırbilir. Ayrıca, kamuoyunun bu endişesi, toplumların doğru bilgiye ulaşamamasına sebep olabilir. İnsanların çevresindeki sosyal dokudan, yerel basından edindiği bilgiler, kömür endüstrisini ve karbon salımının yoğun olduğu sektör ve istihdam alanlarını destekler nitelikte olabilir. Bu noktada toplumların nitelikli ve doğru habere ulaşma hakkı önemlidir.

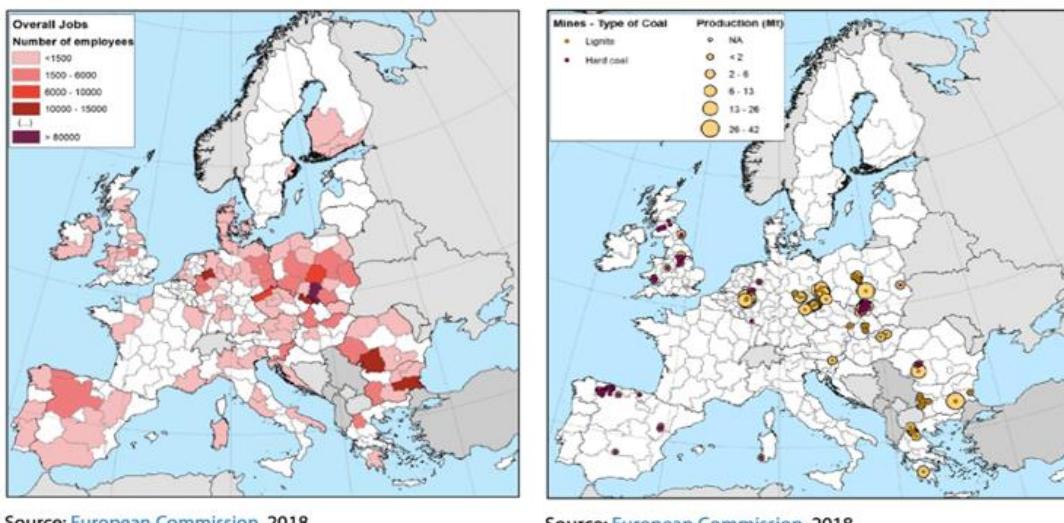
4. Planlı Bir Örnek Olarak AB'nin Adil Geçiş Süreci Tasarımı

Avrupa Yeşil Mutabakatı (AYM) (The European Green Deal) bir yıyla Avrupa'yı iklim açısından nötr bir kıta haline getirmeyi hedefleyen bir iklim projesi olarak görülrken diğer yandan düşük karbonlu ekonomiye adil bir geçiş desteklemeyi amaçlayan bir sosyal projedir. Öngörülen dönüşümün faydaları ya da riskleri ve geçiş maliyetleri ülkeler, bölgeler ve topluluklar arasında eşit olarak dağılmamıştır. Aşağıda adil geçişe gereksinim duyduğu alanlardan biri olan kömüre bağımlı AB ekonomilerine ve buradan hareketle AB'nin adil geçiş tasarımasına örnek verilmektedir.

AB sınırları içerisinde, spesifik bölgelerde kömür madenleri ile kömür santrallerinde istihdam edilmekte olan nüfusun renklere göre yoğunluklandırılması ve kömür

çeşitlerine göre AB bölgelerinde bulunan kömür madenlerinin sayıları Şekil 1a ve 1b'de sunulmaktadır.

Şekil 1a ve 1b. AB'nin Kömür Bölgelerinde İstihdam ve Kömür Üretimi Yoğunlukları¹



Source: European Commission, 2018.

Source: European Commission, 2018.

Kaynak: Avrupa Komisyonu (2018a)

AB Komisyonu'na yapılan bir çalışmaya göre (Kapetaki vd., 2020), Adil Geçiş kapsamında AB'nin 27 üye ülkesinde 2030 itibarıyle 315.000, 2050 itibarıyle 460.000 adet “karbonsuz” istihdamın yaratılması beklenmektedir. Rakamların büyüklüğü göz önüne alındığında, Adil Geçiş'in sosyoekonomik, kültürel ve sosyal etkilerinin büyülüğu de daha iyi anlaşılacaktır. Bu bağlamda Adil Geçiş'in özellikle AB üye ülkeleri arasında, ülke ve bölgeler bazında nasıl değerlendirileceği, kaynakların nasıl dağıtılacığı ve bunların olası etkilerinin ölçülmesi süreçleri, politika yapıcılar ve uyguladıkları bu politika enstrümanlarının verimliliği açısından önem arz etmektedir.

4.1. Güncel Adil Geçiş Ajandası

2014-2020 yıllarını kapsayan Çok Yıllı Mali Çerçeve'de (Multiannual Financial Framework (MFF)), Avrupa Komisyonu tarafından belirlenmiş olan toplam bütçenin yaklaşık %20'sinin iklim krizi ve buna bağlı harcamalara ayrılmaması kararlaştırılmıştı. Bu bütçede Adil Geçiş Mekanızması için ayrı bir yasama çerçevesi bulunmuyordu ama Avrupa Yapısal ve Yatırım Fonları (European Structural and Investment Funds (ESIF)) bu amaç ile alakalı benzer bir işlev sahipti. 2014-2020 yıllarını kapsayan MFF'de, Avrupa Bölgesel Yatırım Fonu (European Regional Development Fund (ERDF)), Uyum

¹ AB'deki kömür maden ve santralleri ile istihdam bilgilerine ayrı ayrı ulaşmak için bkz. Avrupa Komisyonu (2020b), Annex D.

Fonu (Cohesion Fund (CF) - Ulaşım ve Enerji Sektörleri Odaklı), Avrupa Sosyal Fonu (European Social Fund (ESF) - Eğitim ve Altyapı Odaklı) olmak üzere çeşitli bütçe kalemleri bulunuyordu. Bunun yanı sıra Stratejik Yatırımlar için Avrupa Fonu (European Fund for Strategic Investment (EUSI)), enerji sektörü odaklı yatırımları merkeze almıştı ve doğrudan Avrupa Yatırım Bankası tarafından finanse ediliyordu. Modernizasyon Fonu (Modernisation Fund (MF)) adı verilen başka bir harcama kalemi ise, enerji verimliliği ve enerji sistemlerinin iyileştirilmesi ile ilgili harcamalar için oluşturulmuştur. İsmi geçen bu fonlar, 2014-2020 bütçesi içerisinde, Adil Geçiş'in hedeflenen çıktılarına en yakın sonuçları verebilecek, benzer doğrultuda harcama kalemleriyydi. Fakat COVID-19 salgınının başını çektiği küresel konjonktür değişimi ve diğer sebeplerden ötürü Adil Geçiş Fonu, Avrupa siyasetinin merkez konularından biri haline geldi. Fon, 2021-2027 yıllarını kapsayan MFF'de yukarıda belirtilen çok sayıda fonun bazı görevlerini de üstlenmiş, yeniden tanımlanmış bir amaç doğrultusunda tek çatı altında toplanmış oldu. Bu finansal çerçevede aynı zamanda, iklim krizi ve buna bağlı sorunların çözümüne yönelik harcamaların bütçe içerisindeki toplam payı da %30'a yükseltilmiş oldu (Widuto, 2019). MFF dahilinde bulunan ESIF, ERDF, Uyum Fonu gibi pek çok alt bütçe kaleminden gelecek olan fonlar da bu oranın içinde yer almaktır ve AB Komisyonu'nun adil geçiş uygulamalarına ayırdığı fon mekanizmasını belirlemektedir.

4.2 Teklifin Hazırlanması Süreci

AB Komisyonu'nun Ocak-Mart 2018 tarihleri arasında düzenlediği anketlerden elde ettiği sonuçlara göre ankete yanıt verenlerin yaklaşık %85'i, çevre hassasiyetlerini merkeze alan düşük karbon salımı döngüsel bir iktisadi düzene geçişin politika yapım süreçlerinde önceliklendirilmesi gerektiğini bildirdi (Avrupa Komisyonu, 2018b). Aynı anketin bir diğer sonucu ise, yanıtlayanların yalnızca %42'sinin anketin düzenlendiği tarihlerde çevresel sorunların politika yapıcılar tarafından doğru ve yeterli derecede önceliklendirildiğini düşündüklerini bildirmeleri oldu. Bu sonuçlar üzerine 2014-2020 yıllarını kapsayan MFF başta olmak üzere pek çok fonun etki analizleri yapıldı. Buna göre:

- Akıllı endüstriyel dönüşümleri, adil ve temiz enerji yatırımlarını esas alan politikaların önceliklendirilmesinin ve bu alanda yatırım yapacak şahıs ve kurumların desteklenmelerinin gerekliliği ortaya çıktı.
- Yerel aktörler ve bölge halkları ile koordinasyon ve iletişim gerekliliği görüldü; olası temiz enerji yatırımlarında bölgeler arası uyumun gözetilmesi gereği sonuçlarına varıldı.

Yasal ve düşünsel zemini adım adım belirlenmiş ve politika süreçlerine entegre edilmiş olan Adil Geçiş Fonu, yukarıda daha önce de bahsedildiği gibi COVID-19 pandemisi ile Avrupa siyasa yapıcılарının gündeminde daha kritik bir yer bulmaya

başladı. Tablo 1'de adil geçişin yasal ve düşünsel altyapısının hazırlanış süreci ile pandemi sonrası şekillenişi tarihsel olarak sıralanmaktadır.

Tablo 1. Avrupa'da Adil Geçiş Mekanizmasının Tarihçesi

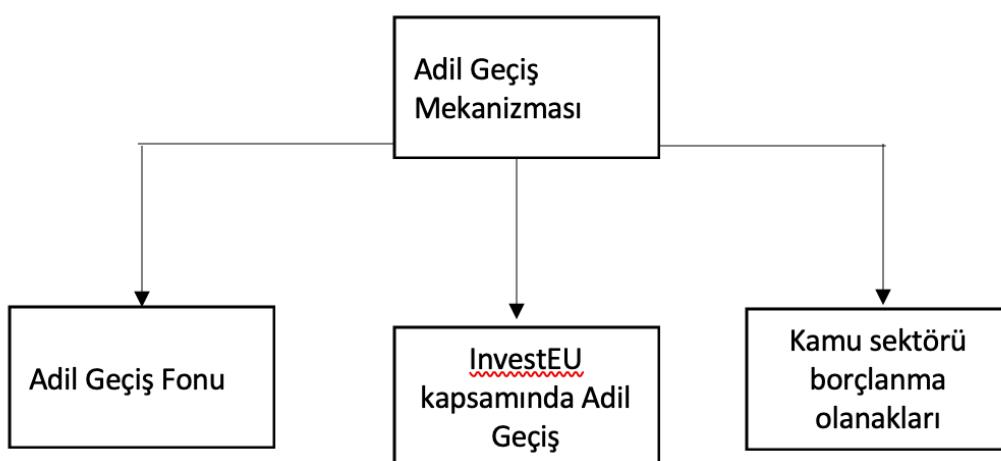
Tarih	Olay
Mart 2018	AB parlamentosunun, 2020 MFF bütçesinin bitisi sonrasında için, enerji sektöründen çıkış kapsamında Adil Geçiş süreçlerini desteklemek adına detaylı bir fonlama sisteminin oluşturulması için
Kasım 2018	2021-2027 MFF bütçesi için alınan meclis kararına göre, enerji sektörünün yeşil dönüşüm süreçlerini desteklemek adına 4.8 milyar euroluk bir destek paketinin Adil Enerji Geçiş Fonu adı altında
Mart 2019	“A Europe that protects: Clean air for all” adı verilen yasa teklifi kapsamında, Parlamentonun özellikle maden bölgelerindeki enerji dönüşüm süreçlerinden etkilenen sosyal dokunun desteklenmesi
18 Ekim 2019	Avrupa Konseyi tarafından, enerji dönüşüm süreçlerinden etkilenen bölgelerin Adil Geçiş Fonu kapsamında desteklenmesi gerekliliğinin
Kasım 2019	AB Parlamentosundan Avrupa Komisyonu'na, yapacağı ve uygulamaya geçireceği tüm hukuki, yasal ve finansal süreçlerin, küresel sıcaklık hedefinin 1.5 derece artış sınırını koruma hedefi ile örtüşmesi gerekliliği
11 Aralık 2019	Adil Geçiş Mekanizmasının ilan edilmesi
14 Ocak 2020	Yeşil Mutabakat çerçevesinde “Adil Geçiş Fonu” isimli yeni bir fon paketinin parlamentoa sunuluşu
28 Mayıs 2020	Düzeltilmiş yeni bir Adil Geçiş Fonu teklifinin tekrar parlamentoa sunuluşu (MFF içindeki kısmı 7.5'ten 10'a çıkarıldı, NextGenEU kısmı 30 milyara çıkarıldı.), Kamu Sektörü Borçlanma Olanakları
17-21 Temmuz 2020	AB liderlerinin Avrupa Konseyi Liderler Zirvesi'nde 40 milyar euroluk bütçeyi 17.5 olarak güncelllemeleri
30 Haziran 2021	Teklifin son halinin Avrupa İklim Kanunu adı altında yayınlanması Kaynak: https://www.ab.gov.tr/fasil-27-cevre_92.html (Erişim: 9 Ağustos 2024)

Kaynak: Yazarlar tarafından derlenmiştir.

4.3 Adil Geçiş Mekanizması

Adil Geçiş Mekanizması, AB'nin iklim-nötr bir ekonomik düzene geçişti sırasında sosyal adaleti ve istihdam süreçlerini adil kılacak politika setine verilen isimdir. Bu mekanizma, tarihçe kısmında verildiği üzere, uzun süren toplumsal ve kurumsal düzeydeki politika yapılmış süreçlerinin bir sonucudur. AB Komisyonu'nun tasarlamış olduğu üzere, Adil Geçiş Mekanizması, üç ana başlık altında farklı finansal ağların ve çıkar gruplarının mobilize edilmelerinden oluşmaktadır (Şekil 2).

Şekil 2. Adil Geçiş Mekanizmasının Bileşenleri



Kaynak: Yazarlar tarafından Avrupa Komisyonu'nun “The Just Transition Mechanism: making sure no one is left behind” başlıklı yazısından Türkçe'ye çevrilmiştir (https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/finance-and-green-deal/just-transition-mechanism_en#introduction) (Erişim: 27 Temmuz 2023).

Şekil 2'de görüldüğü üzere, Adil Geçiş Mekanizması'nı oluşturan üç farklı finansman kanalı vardır. Bunlar doğrudan yatırım fonlarını içerisinde bulunduran Adil Geçiş Fonu, özel sektör yatırımlarını mobilize etmeyen InvestEU ve kamu sektörü borçlanma olanaklarıdır.

a. Adil Geçiş Fonu ve Fonun Dağıtım Kriterleri

AB'nin temel yatırım fonlarının bir araya geldiği politika seti kapsamında yer alacak olan Adil Geçiş Fonu, kömürden çıkış sürecinden en çok etkilenmiş veya etkilenecek olan bölgelere verilecek desteklerin doğrudan finansmanını içermektedir. Avrupa Komisyonu'nun tanımına göre Adil Geçiş Fonu;

- Ekonomik çeşitlendirme
- Geçiş bölgelerinin yeniden işlevlendirilmesi

- İşgücüne yeni ve üstün beceri setlerinin kazandırılması
 - Yeni şirket yatırımlarının desteklenmesi
 - AR&GE
 - Çevresel rehabilitasyon
 - İstihdam süreçlerine destek
- maddeleri ile özetlenebilecek amaçlara sahiptir.

Adil Geçiş Fonu, 7,5 milyar avrosu MFF, 10 milyar avrosu NextGenEU aracılığıyla olmak üzere toplamda 17,5 milyar avroluk (2018 fiyatlarıyla) bir bütçeye sahiptir. Ek olarak, AB'ye üye 27 ülke, eğer uygun görürse kendi planlamaları doğrultusunda öz kaynaklarını, kendilerine AB tarafından tahsis edilen Adil Geçiş Fonu doğrultusunda mobilize edebileceklerdir. Bahsi geçen öz kaynaklar, ERDF ve Avrupa Sosyal Fonu (European Social Fund Plus (ESF+)) kapsamında üye ülkelere dağıtılmış olan kaynaklardan, aktarılan toplam Adil Geçiş Fonu miktarının üç katını geçmeyecek şekilde dağıtılmalıdır. Adil Geçiş Fonu'nun iki temel bütçe kalemi aşağıda ayrıntılı olarak ele alınmaktadır:

MFF: AB Çok Yıllı Mali Çerçeve (Multiannual Financial Framework (MFF)) bütçesi, yedi yıllık bir süreci kapsayacak şekilde tasarlanmış, AB'nin çeşitli harcama kalemlerini belirleyen bütçe tasarısidır. MFF, AB harcamalarının belirlenen süre içerisinde belirlenen öngörlülebilir sınırların altında kalacağına dair bir güvence işlevi görür. 2014-2020 MFF bütçesine göre AB, çevre ve iklim krizi ile alakalı olarak uygulanması beklenen politikalarına, bütçenin yaklaşık toplam %20'lük bir kısmını ayırmıştır (Widuto, 2019). Bu oran, 2021-2027 MFF bütçesinde %30'a yükseldi. Yukarıda belirtildiği üzere, Adil Geçiş Fonu'nun 2018 fiyatlarıyla 7,5 milyar avroluk kısmının 2021-2027 MFF bütçesinden karşılanması planlanmıştır (Avrupa Komisyonu, 2020a).

NextGenEU: NextGenEU, Avrupa Birliği'nin tüm dünyayı etkisi altına alan ve milyonlarca kişinin ölümüne sebep olan COVID-19 pandemisinin AB üye ülkeleri üzerinde yarattığı ekonomik ve sosyal tahribatın etkilerini azaltmak için tasarladığı 800 milyar avro büyülükte bir kurtarma paketidir. NextGenEU paketinin ana bileşenini, AB üye ülkelerine teşvik ve kredi sağlayan Kurtarma ve Dayanıklılık Fonu (Recovery and Resilience Facility (RFF)) adlı fon oluşturur. Bu fonun toplamı günümüz fiyatlarıyla 723,8 milyar avrodur (Avrupa Komisyonu, 2021). Bu fonun 338 milyar avroluk kısmı üye ülkelere verilecek teşvikleri, 385,8 milyar avroluk kısmı üye ülkelere verilecek kredileri kapsamaktadır. Avrupa Parlamentosu'nda alınan en son karara göre, NextGenEU bütçesinden yaklaşık 10 milyar avronun Adil Geçiş Fonu'na aktarılması planlanmıştır.

Yukarıda yasama süreçleri ve detayları verilmiş olan Adil Geçiş Fonu, AB Komisyonu tarafından belirlenen kriterlere göre dağıtılır. Bu kriterler ve ağırlıkları aşağıda verilmiştir (Avrupa Komisyonu, 2020a):

1- 166/2006 Sayılı Tüzüğün (EC) 7. Maddesi uyarınca üye devletler tarafından rapor edilen endüstriyel tesislerin sera gazı emisyonlarının oranı ile tanımlanan karbon yoğunluğunun olduğu NUTS2 bölgelerindeki endüstriyel tesislerin sera gazı emisyonları Sektörün brüt katma değeri ile karşılaşıldığında AB-27 ortalamasını iki

kat aşmaktadır. Belirli bir üye devletteki herhangi bir NUTS2 bölgesinde bu seviyenin aşılmaması durumunda, en yüksek karbon yoğunluğuna sahip NUTS2 bölgesindeki endüstriyel tesislerin sera gazı emisyonları dikkate alınır (%49 ağırlıklı)

- 2- kömür ve linyit madenciliğindeki istihdam (%25 ağırlıklı)
- 3- 1. maddenin amaçları doğrultusunda dikkate alınan NUTS 2. düzey bölgelerindeki sanayi istihdamı (%25 ağırlıklı)
- 4- Bataklık Kömürü üretimi (%0,95 ağırlıklı)
- 5- Petrollü şeyl üretimi (%0,05 ağırlıklı)

Bu ağırlıklandırmalara ek olarak, Avrupa Komisyonu, yukarıda verilen kriterlerin fon alan hiçbir ülkenin 2 milyar avrodan fazla almayacağı ve aynı zamanda yardım yapılan ülkede kişi başına en az 6 avroluk bir yardım düşecek şekilde düzenleneceğini bildirmiştir (Avrupa Komisyonu, 2020a). Buna göre, 2 milyar avroyu aşan fonlar diğer ülkelere yeniden dağıtılacaktır. Bu yeniden dağıtım, iki farklı kritere göre yapılacaktır:

- Artık fonun yeniden dağıtımı söz konusu olan AB üyesi ülkenin gayri safi milli gelirinin, AB üyesi 27 ülkenin 2015-2017 arası ortalama milli gelirinden farkının 1.5 katısayısı ile oranlanmasıyla gerçekleştirilir.
- Bu uygulama, başlangıç dağıtımında 2 milyar avrodan az fon alan ülkelere uygulanmaz.

Söz konusu ağırlıklandırılmış dağıtım mekanızması, Avrupa Birliği tarafından belirlenmiş olan 19,2 milyar avroyu (güncel fiyatlarla) AB üyesi 27 ülkeye adil ve yeşil dönüşüm için teşvik edici bir amaç ile dağıtmayı hedeflemektedir. Bu dağıtım mekanızmasının ardından AB ülkelere verilecek fonların ağırlıklara göre hesaplanmış bir dökümü Tablo 2'de; AB üyesi ülkelere dağıtıacak fon miktarlarının Adil Geçiş Mekanızması altındaki üç ayrı fonlama mekanızması kapsamındaki öngörülen miktarları Tablo 3'te verilmektedir.

Tablo 2. AB Üyesi 27 Ülkenin Ağırlıklandırılmış Adil Geçiş Fon Dağılımı

Ağırlıklar	%49(2)	%25(3)	%25(3)	%6,05(2)	%6,05(2)	AB İçindeki Toplam Pay						Düştürüm	Yerel Yoğunluğu						
						Başlık	Kömür Kömür Üretimi (7)	Kömür petrol Üretimi (8)	Endüstriyel sera gaz emisyonları	Karbon-yoğun endüstriyel sera bölgeinde istihdam	Kömür ve Linyit Madenlerinde İstihdam	Başlık	Kömür Üretimi	Kayıtlı Pay (9)	Kayıtlı Pay	Kayıtlı Pay			
(1) Yerel yoğunlu endüstriyel sera gaz emisyonları (4)	1060 (CO2 Eşdeğeri)	Bin 1000)	Bin 1000)	Ton Eşdeğeri Petrol	Ton Eşdeğeri Petrol	%	%	%	%	%	%	%	%	%	%	%	Milyon Avro	Küçük Bütçenin Dijen Milli Geliş partisi uygulanlığında (10)	
Birim	15.512	100	-	-	-	%1,7	%1,4	-	-	-	-	%1,2	%0,9	%0,9	68,4	6,0	BE		
BE	23.160	177	15	-	-	%2,6	%2,5	%6,1	-	-	-	%3,5	%6,3	%6,1	458,2	65,0	BG		
BG	45.627	355	24	-	-	%5,1	%5,0	%9,6	-	-	-	%6,3	%8,0	%7,7	580,8	34,7	CZ		
CZ	2.325	40	-	-	-	%0,3	%0,6	-	-	-	-	%0,3	%0,1	%0,5	34,7	6,0	DK		
DE	251.158	1.289	17	-	-	%2,9	%1,8	%7,0	-	-	-	%20,7	%12,1	%11,7	876,6	10,6	DE		
EE	12.850	131	-	-	0,01	%1,4	%1,8	-	-	-	-	%10,0	%1,3	%1,3	125,2	94,9	EE		
IE	5.971	165	-	-	0,7	-	%0,7	%1,5	-	-	-	%1,2	%0,4	%0,4	29,9	6,2	IE		
EL	35.367	94	4	-	-	%3,9	%1,3	%1,5	-	-	-	%2,7	%4,1	%3,9	293,6	37,3	EL		
ES	42.768	276	3	-	-	%4,7	%3,9	%1,3	-	-	-	%3,8	%4,3	%4,1	307,4	6,6	ES		
FR	51.454	353	-	-	-	%5,7	%4,9	-	-	-	-	%4,2	%3,7	%5,4	401,6	6,0	FR		
HR	4.503	85	-	-	-	%0,5	%1,2	-	-	-	-	%0,6	%0,5	%0,9	65,8	16,0	HR		
IT	59.472	395	-	-	-	%6,6	%5,5	-	-	-	-	%4,8	%5,0	%4,9	364,3	6,0	IT		
CY	4.714	35	-	-	-	%0,5	%0,5	-	-	-	-	%0,4	%0,5	%0,5	35,8	41,4	CY		
LV	1.751	141	-	0,0005	-	%0,2	%2,0	-	-	-	-	%0,03	%0,6	%0,9	67,8	35,0	LV		
LT	5.037	183	-	-	0,01	-	%0,6	%2,5	-	-	-	%0,4	%1,3	%1,3	96,7	34,4	LT		
LU	1.419	36	-	-	-	%0,2	%0,5	-	-	-	-	%0,2	%0,0	%0,05	3,6	6,0	LU		
HU	8.543	97	-	-	-	%0,9	%1,4	-	-	-	-	%0,8	%1,3	%1,2	92,4	9,4	HU		
MT	124	25	-	-	-	%0,0	%0,3	-	-	-	-	%0,1	%0,1	%0,1	8,2	17,3	MT		
NL	71.609	289	-	-	-	%8,6	%4,0	-	-	-	-	%3,4	%3,1	%2,9	220,5	12,8	NL		
AT	6.445	114	-	-	-	%0,7	%1,6	-	-	-	-	%0,8	%0,4	%0,7	52,9	6,0	AT		
PL	153.192	1.953	139	-	-	%17,0	%27,3	%56,8	-	-	-	%26,7	%26,7	%26,7	2.000,0	52,7	PL		
PT	11.415	41	-	-	-	%1,3	%0,6	-	-	-	-	%0,8	%1,1	%1,1	79,2	7,7	PT		
RO	22.340	374	36	0,001	-	%2,5	%5,2	%14,5	-	-	-	%6,4	%10,5	%10,1	751,1	38,8	RO		
SI	4.743	128	2	-	-	%0,5	%1,8	%1,0	-	-	-	%1,0	%1,3	%1,2	91,5	44,3	SI		
SK	11.076	128	5	-	-	%1,2	%1,8	%2,1	-	-	-	%1,6	%2,2	%2,2	162,4	29,8	SK		
FI	29.388	166	-	-	0,7	-	%3,3	%2,3	-	-	-	%45,6	%2,7	%2,2	164,8	39,9	FI		
SE	13.210	54	-	-	0,1	-	%1,5	%0,8	-	-	-	%1,0	%0,6	%0,8	66,7	6,0	SE		
Total	901.255	7.165,0	245,2	1,6	4,1	%100	%100	%100	%100	%100	%100	%100,0	%100,0	%100,0	7.500,0	17	EU27		

(1) %50'lik birleşik ağırlık ile (2) ekonomik kriterler (sera gazı emisyonları, turba ve şist üretimi) ve (3) sosyal kriterler (kömür ve linyit istihdamı, karbon yoğun bölgelerde sanayide istihdam).

(4) Bölgesel karbon yoğunluğu, sera gazı emisyon miktarının sanayinin brüt katma değerine bölünmesi ile hesaplanır. Karbon yoğun bölgeler, endüstriyel sera gazı emisyonları AB değerinin iki katından fazla olan bölgelerdir.

(5) Karbon yoğun olarak tanımlanan bölgelerdeki endüstriyel istihdam düzeyi, geçişin sosyal boyutunun bir ölçüsüne sağırlar.

(6) Kömür sektörü geçenen çok etkilenen sektörlerden biri olacak ve bu sektördeki iş sayısı geçişin sosyal etkisinin net bir ölçüsünü sunuyor.

(7) Turba üretimi ve (8) şist üretimi, CO2 yoğunluğu açısından kömürle benzer özelliklere sahiptir.

(9) Herhangi bir Üye Devletin Adil Geçiş Fonu kaynaklarından aşırı pay almasını önlemek için bir üst sınır belirlenmiştir. Üst limit 2 milyar Avro olarak belirlenmiştir.

(10) Kaynakların daha az gelişmiş Üye Devletlerde yoğunlaşmasını sağlamak için Üye Devletlerin kişi başına GSMG'si hesaba katılır. Bu düzeltme, kişi başına düşen ulusal GSMH ile kişi başına ortalama AB GSMH arasındaki farkın %15'ini oranından ulusal tahsisat paylarını sırasıyla artırır veya azaltır. Daha az gelişmiş üye Devletlerin yararına devrileceğini onların daha düşük yatırım kapasitelerini yansır.

(11) Üye Devlet başına asgari bir yardım yoğunluğu seviyesi belirlenir, böylece her Üye Devlet yeterince anlamlı ve etkili eylemlerin desteklenmesine izin veren bir tahsis alır. Asgari yardım yoğunluğu kişi başına 6 avro olarak belirlendi.

Kaynak: Yazarlar tarafından, *Press corner.* (n.d.-b). European Commission. <https://ec.europa.eu/commission/presscorner/api/files/attachment/860491/JTM%20and%20JTF%20Allocation%20Table.pdf> sitesinde bulunan tablolardan Türkçe'ye çevrilmiştir. (Erişim: 27 Temmuz 2023)

Tablo 3. Adil Geçiş Mekanizmasının Tahmini Finansman Mobilizasyonu

	Teklif Edilen Adil Geçiş Fon Miktarı (2018 fiyat seviyesi)	Adil Geçiş Fonu kapsamındaki yaklaşık toplam fon miktarı (2018 fiyat seviyesi)	Adil Geçiş Mekanizmasının tüm enstrümanları için beklenen toplam yatırım hacmi (güncel fiyat seviyesi)
BE	68	311	989
BG	458	1710	6.205
CZ	581	2.074	7.761
DK	35	217	569
DE	877	4.614	13.387
EE	125	569	1.811
IE	30	187	490
EL	294	1.049	3.923
ES	307	1.397	4.445
FR	402	1.825	5.807
HR	66	235	879
IT	364	1.301	4.868
CY	36	163	518
LV	68	242	906
LT	97	345	1.292
LU	4	23	59
HU	92	330	1.234
MT	8	37	119
NL	220	1.045	3.174
AT	53	331	867
PL	2.000	7.692	27.344
PT	79	283	1.058
RO	757	2.704	10.116
SI	92	327	1.223
SK	162	580	2.170
FI	165	749	2.383
SE	61	380	995
Total	7.500	30.719	104.589

* Uyum politikası kapsamında gerekli olan ulusal katkının yanı sıra JTF'den çekilen her 1 Euro için Avrupa Bölgesel Kalkınma Fonu ve/veya Sosyal Fon+'dan en az 1,5 Euro transfer dahil.

** Toplam minimum fonlamayı (JTF) ve Sütun 1, 2 ve 3'te harekete geçirilmesi beklenen yatırımı nominal fiyatlarında yansıtır. Üye Devlet tarafından yapılan ayrımsız gösterge niteliğinde bir tahmindir.

Kaynak: Yazarlar tarafından, *Press corner*. (n.d.-b). European Commission. <https://ec.europa.eu/commission/presscorner/api/files/attachment/860491/JTM%20and%20JTF%20Allocation%20Table.pdf> sitesinde bulunan tablolardan Türkçe'ye çevrilmiştir. (Erişim: 27 Temmuz 2023)

Tablo 2 ve 3'te de görüldüğü üzere Almanya, Polonya, Romanya gibi kömür bölgeleri, yukarıda sözü edilen kriterler göz önüne alındığında Adil Geçiş Mekanizması kapsamında en çok finansmana erişecektir.

b. InvestEU Kapsamında Adil Geçiş

Özel sektör yatırımlarını adil geçiş kapsamında mobilize etmeyi amaçlayan fonları içeren InvestEU, Adil Geçiş Mekanizmasının ikinci ayağıdır. InvestEU, Avrupa Birliği'nin "Avrupa Yeşil Mutabakatı" programından ayrı bir yatırım programı olarak sürdürülebilir yatırım, inovasyon ve yeni istihdam alanları yaratma amaçlarıyla oluşturulmuş bir ekonomik program olsa da Adil Geçiş Mekanizması içerisinde yasama süreçleri sonucunda entegre edilmiştir.

InvestEU programı kapsamında, 2021-2027 yılları arasında yaklaşım 372 milyar avroluk bir miktarın yatırım amacıyla mobilize edileceği öngörlürken bunun %30'luk kısmının Adil Geçiş Mekanizmasına yönlendirilmesi planlanmıştır. Avrupa Komisyonu'nun hedeflediği rakamlar gerçekleşirse, InvestEU programının Adil Geçiş Mekanizması kapsamında 45 milyar avroluk bir ekonomik hacim yaratması beklenmektedir (Avrupa Komisyonu, 2020b).

c. Kamu Sektörü Borçlanma Olanakları

Kamu teşvik ve kredilerini Adil Geçiş süreci kapsamında mobilize etmesi amacıyla oluşturulmuş, Adil Geçiş Mekanizmasının üçüncü ve son ayağıdır. Adil Geçiş Mekanizması kapsamında yaklaşık olarak 25-30 milyar avroluk bir ekonomik hacim yaratması beklenmektedir (Avrupa Komisyonu, 2020b).

d. Bölgesel Adil Geçiş Planları

Sayılan üç ayak dışında AB'nde ayrıca kömürden çıkıştan olumsuz etkilenenek Avrupa ülkelerini desteklemek amacıyla Bölgesel Adil Geçiş Planları (Territorial Just Transition Plans) hazırlanmıştır. Bu planlar, Adil Geçiş Mekanizması kapsamındaki farklı finansman kaynaklarına erişim için birer ön koşuldur. Avrupa Komisyonu'nun 2022 verilerine göre 16 ülke içinde toplamda 38 tane bölgesel adil geçiş planı belirlenmiştir.² Bölgesel Adil Geçiş Planları ile sadece yeşil ekonomiye geçişte ortaya çıkabilecek ekonomik sorunlara odaklanılmayıp, uzun vadede bölgedeki refahı yükseltmek için eğitim ve sağlık gibi diğer temel alanlara da sosyal yatırımlar yapılması planlanmaktadır.

WWF, Şubat 2023'te yayımladığı "Territorial Just Transition Plan Scorecard Assessment" raporunda halihazırda eyleme geçirilen bölgesel adil geçiş planlarının geliştirilmesi gereken yanlarını analiz etmekte ve ülkelerin geçiş süreçlerini notlandırmaktadır. Rapor'a göre mevcut planlar her ne kadar kömürden çıkış hızlandırsa da yaşam kalitesini yükseltmeye ve mevcut eşitsizlikleri ortadan kaldırılmaya odaklanmak yerine teknolojik yatırımlar ve işgücü yetkinliklerinin artırılmasına odaklanmış durumdadır. Öte yandan, planların bölgeye özel olmaları, politika yapıcların ve yerel yöneticilerin eyleme geçmelerini kolaylaştırmaktadır. Bölgesel planlama, kömürden çıkış hızlandırmakla kalmayıp, aynı zamanda yeni sektörler ve iş

² WWF (2023) bu sayının 90'a çıkabileceğini öngörmektedir.

alanları yaratılmasına da olanak sağlamaktadır (WWF, 2023). Fakat bu bölgelerde her ne kadar kömürden çıkış hızlansa da alternatif enerji kaynakları olarak temiz ve yeşil enerji yerine doğal gaz kullanımı yaygın olarak görülmektedir (WWF, 2023). Ayrıca yeni istihdam alanları yaratılmasına rağmen insana yaraşır işlerin az olması, hayat kalitesinin de buna paralel olarak düşük olması, gelir eşitsizliğinin artması ve sosyal dışlanma etkileri birer gözlem olarak karşımıza çıkmaktadır. Planların şeffaf olmaması ve süreç içerisinde kamuoyuna hesap verilmemesi, sosyal diyaloğun yetersiz kalması bölgesel adil geçiş planlarının diğer eksik yanlarıdır. Özetle, WWF (2023), bu nedenlerden ötürü, kendi hazırladığı Adil Geçiş Değerlendirme kriterlerine göre değerlendirdiği çoğu ülkenin adil geçiş notlandırmasına ortalama puan vermiştir.

5. Adil Geçiş İçin Bir Çerçeve Önerisi

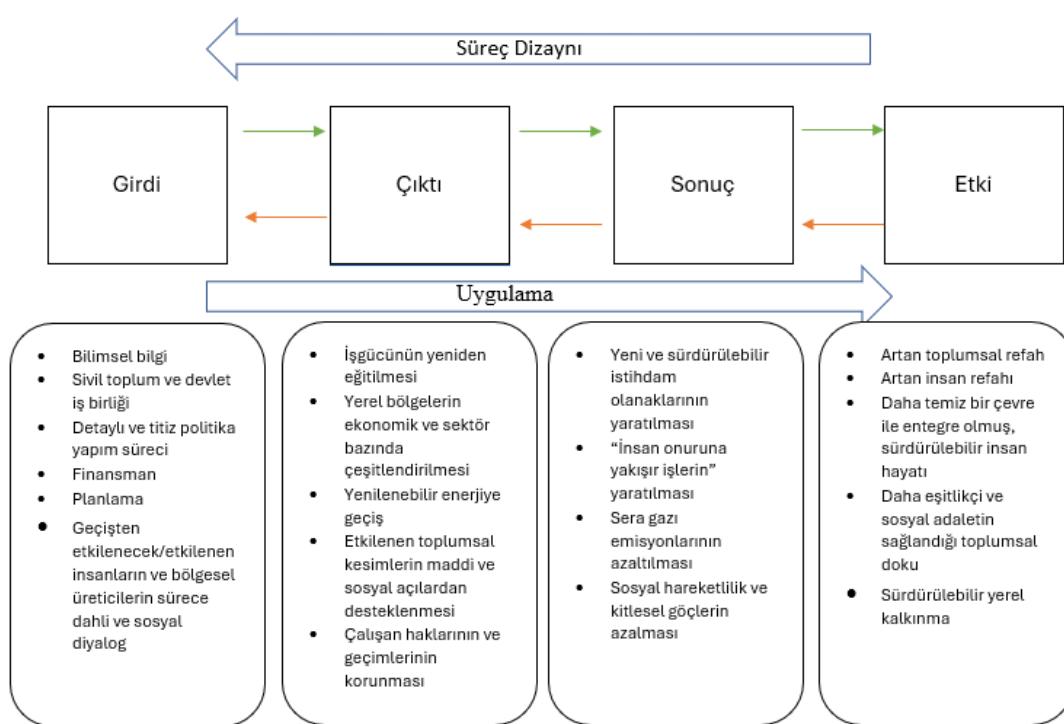
2015 yılında Paris İklim Anlaşması'nın kabul edilmesi ve aynı dönemde Birleşmiş Milletler Sürdürülebilir Kalkınma Hedeflerinin 2030 yılı için belirlenmesiyle birlikte iklim ve sürdürülebilir kalkınma politikalarının önemi tüm dünyada artmaktadır. Hem Paris Anlaşması'nın hem de Sürdürülebilir Kalkınma Hedeflerinin iklim eylemi başlığında, iklim değişikliğiyle mücadele için sera gazı emisyonlarının azaltılması ve ekonomilerin net sıfır (iklim-nötr) dönüşmesi gerektiği belirtilmektedir. Giderek daha fazla ülke net sıfır hedefleri için yıl belirlemekte, bu hedefe ulaşmak için izleyeceği yol haritalarını şekillendirmeye çalışmaktadır.

Dünya çapında enerji üretiminden kaynaklanan sera gazı emisyonları 2022'de yaklaşık %1,3 oranında (423 Mt kadar) artmıştır (IEA, 2023c). Bu nedenle enerji sektörünün dönüşümü ve özellikle kömürden elektrik üretiminden çıkış, karbonsuzlaştırma ekonomileri açısından önceliklidir. Yenilenebilir kaynaklardan enerji üretimindeki teknolojik gelişmeler, maliyetlerindeki düşüşler ve kömürden elektrik üretiminin finansmanının giderek zorlaşması göz önüne alındığında, kömürden uzaklaşmak iklim değişikliğiyle mücadele açısından zorunlu olmanın yanı sıra ekonomik açıdan da anlamlı hale gelmiştir. Ayrıca kömürden elektrik üretimi yerel halk sağlığı, doğal çevre, istihdam, geçim kaynakları ve yaşam tarzı üzerinde de olumsuz etkilere neden olmaktadır. Bu etkiler ve bunlara karşı verilen mücadeleler, kömürün aşamalı olarak ortadan kaldırılmasının toplumsal gerekliliğine işaret etmektedir.

Bu çalışmada, sırasıyla Adil Geçiş kavramının tarihçesini ve şekillenmiş süreci, geçiş sürecinde izlenmesi gereken yol haritaları ve politikaları, AB'nin Adil Geçiş Mekanızması tasarımlı örneklenerek ele alındı. Adil dönüşüm sürecini planlamadan ilk basamağı, başta enerji sektörü olmak üzere ekonominin tüm sektörlerini kapsayan, net sıfır hedefine nasıl ulaşacağına ilişkin ulusal ölçekte, uzun vadeli ve etkili bir karbondan arındırma yol haritası geliştirmektir. Bu karbondan arınma yol haritasının, iklim değişikliğiyle mücadeleyi toplumsal refahı artırma hedefleriyle birleştirmesi

gerekmektedir. Ulusal ölçekte kömürden çıkış stratejilerine paralel olarak, ekonomisi kömüre dayalı bölgelerde bu sürecin olumsuz etkilerini yönetebilmek ve kömüre dayalı dönüşüm yol açabilmek için kapsayıcı ve katılımcı bir yerel/bölggesel adil geçiş planlamasının yapılması ve uygulanması gerekmektedir. Kömürden çıkış bağlamında adil dönüşüm, kömürden çıkış sürecini ve sonasını kapsayıcı ve eşitlikçi bir şekilde planlayarak kömür sektöründe çalışanların haklarının ve geçim kaynaklarının korunması anlamına gelir. Bu, bu bölgelerde yeni istihdam ve insana yakışır iş fırsatları yaratan, sosyal eşitsizlikleri azaltan, doğal kaynakları ve biyoçeşitliliği koruyan adil, sürdürülebilir ve dayanıklı bir kalkınma yolunun belirlenmesi ve uygulanması anlamına gelmektedir (Avcı vd., 2022). Çalışmamızda incelediğimiz literatürden ve AB deneyiminden yola çıkarak, Adil Geçiş'in çerçevesi, özellikleri ve süreç tasarımları Şekil 3'te özetlenmektedir.

Şekil 3. Adil Geçiş İçin Bir Çerçeve Önerisi



Kaynak: İçerik yazarlar tarafından oluşturulmuş olup şekil Sharma (2017)'deki "The Transformational Results Chain" görselinden adil geçiş için uyarlanmıştır.

Şekil 3, makalede ele aldığımız Adil Geçiş çerçevesinin genel bir özeti ve bu süreçte göz ardı edilmemesi gereken hususların bir derlemesi niteliğinde düşünülebilir. Buna göre, sürecin tasarılanmasında girdi olarak değerlendirilebilecek konulardan küresel ısınmaya ve karbonsuzlaşmanın gereğine ilişkin bilimsel bilgi, konunun tarafları

arasında işbirliği, dayanışma ve diyalog, çeşitlendirilmiş finansman kaynakları, unsurları titizlikle saptanmış politika araçları olmazsa olmazdır. Bu girdilerden hareketle geçişe maruz kalan yerlerde fosil yakıta dayalı sektörlerde çalışanların yeniden eğitimi ve yeni becerilerle donatılması, yerel ekonominin geçim kaynaklarının çeşitlenmesi, fosil yakıtlardan çıkışla birlikte yenilenebilir enerjiye geçişin hızlanması, etkilenen kesimlerin haklarının korunarak maddi ve sosyal açılarından desteklenmesi ilk elde edilecek çıktılar olacaktır. Bu çıktıların bir sonucu olarak yeni ve insan onuruna uygun iş imkanları yaratılabilir, sera gazları azalma patikasına girebilir, göçler yön değiştirebilir. Adil geçiş politika tasarıımı sonucunda görülmesi beklenen etkiler ise öncelikli olarak insan ve toplum refahı üzerinedir. Daha eşitlikçi ve kapsayıcı bir ekonomik düzen içerisinde, daha temiz bir çevrede yaşayan insan ve toplulukların daha büyük refah düzeyine kavuşması beklenir.

6. Sonuç ve Öneriler

İklim krizini durdurabilmek ya da en azından yavaşlatabilmek için değişimin elzem olduğu öncelikli alan enerji sisteminin dönüşümüdür. Bununla birlikte sadece enerjinin değil genel olarak ekonominin düşük karbonlu hale getirilmesi sürecinde, bu dönüşümden olumsuz yönde etkilenecek taraflar olacaktır. Hem bu tarafları (bireyleri, haneleri, toplulukları) korumak, hem de dönüşümü adil ve sürdürülebilir kılmak açısından “adil geçiş”in ulusal, bölgesel ve yerel ölçeklerde tutarlı bir biçimde planlanması ve hayata geçirilmesi gerekmektedir.

Çalışmamızda, Adil Geçiş sürecini bütüncül bir perspektifle ele alarak sivil toplumun, devletin, yerel örgütlenmelerin birbirleriyle olan ilişkilerinin, istihdam ve finansman politikalarının düşük karbonlu ekonomiye geçiş sürecinin daha “adil” olabilmesi için önemli olduğunu göstermeye çalıştık. Bu bağlamda, Avrupa Yeşil Mutabakatına (AYM) uyum çerçevesinde Türkiye, Temmuz 2021’de 9 tema altında 81 politika eylemi içeren Avrupa Yeşil Mutabakatı Eylem Planı’ni açıklamıştır. Bu Eylem Planı’nda, AYM tarafından düzenlenen politika alanlarından çoğu kapsanmakla birlikte, fosil yakıttan çıkış taahhüdünün bulunmaması, öngörülen dönüşümü adil bir şekilde güvence altına alacak somut eylem planlarının olmaması ve AYM kapsamındaki Adil Geçiş Mekanizmasına benzer bir mekanizmanın henüz tasarlanmamış olması önemli birer eksikliktir. Bu bakımdan bu çalışmaya ülkemizde olası bir kömürden çıkış sürecinde Adil Geçiş perspektifinin nasıl ele alınabileceğine yönelik bir katkı sunmuş olmayı hedeflemekteyiz.

Özetlemek gerekirse, kömürden çıkışın, yeşil bir ekonomiye geçişin bölge halkının haklarının korunacak şekilde gerçekleşmesi, bu süreçte kimsenin geride bırakılmaması büyük bir önem taşımaktadır. Bu geçişin adil bir şekilde yapılabilmesi için de uzun vadeli planlama yapılp eyleme geçirilmesi şarttır. Ayrıca sivil toplum ve devlet aygıtlarının işbirliği içerisinde olması, yeterli finansmanın sağlanması ve geçişten

etkilenecek kitlelerin sürece sosyal diyalog içerisinde dahil edilmesi büyük önem taşımaktadır. Aksi halde oluşacak işsizlik kalıcı hale gelebilir.

Ek olarak, adil geçişte; ekonomisi kömür, madencilik ve bu alanlarla ilintili bölgelerde kömürden çıkıştan sonra ekonominin canlandırılmalı ve sektörel çeşitliliğin sağlanması için yatırımlar göz önünde bulundurulmalıdır. Ayrıca bölgenin enerji ihtiyacını sağlamak için yenilenebilir enerji gibi çevre dostu enerji sistemlerine yatırım yapılmalı ve bu sistemlerin verimini artırmak için yapılacak AR-GE çalışmaları finanse edilmelidir. Kömürden çıkış süreci hakkında süreci yöneten kurumlar şeffaf olmalı ve süreç hakkında kamuoyu aşama aşama bilinçlendirilmeli, kömür ve madencilik sektöründe çalışan işçilere, oluşacak yeni iş alanlarında çalışmaları için eğitimler verilmelidir. Ayrıca geçiş sürecinde bölge halkın ihtiyaçları göz önünde bulundurulmalı, bunun için de yerel yönetimlerle işbirliği yapılarak geçiş sağlanmalıdır. En önemlisi, ülkeler kömürden çıkıştan sonra bölgenin geleceği için yapılacak yatırımlar için kaynak ayırmalı ve bu kaynakların devamlılığı sağlanmalıdır.

Unutulmamalıdır ki adil bir geçişin her ülkeye ya da bölgeye uyan tek bir formülü ve yol haritası yoktur. Toplumlar, yeşil ve sürdürülebilir bir ekonomik dönüşümü, sosyal ve iktisadi politikaları kendi iç dinamiklerine göre tarihsel ve coğrafi gerçeklikleri içerisinde kurgulayarak geliştirmelidirler. Gelecek çalışmalarında ele alınmak üzere bu çalışmada eksik kalan konular da vardır. Örneğin, Adil Geçiş uygulamalarını kapsayıcı, hakkaniyetli ve bir politikalar bütünü olarak başarılı ve başarısız kılan etmenlerin incelenmesi elzemdir. Ayrıca AB ve AB dışında başarılı ve başarısız geçiş deneyimlerinin incelenmesi de gelecekteki adil geçiş süreçlerine ışık tutacaktır.

Kaynakça

- Avcı, D., Acar, S., Adaman, F., Uncu, B.A. (2022). Net Sıfıra Giden Yolda Adil Dönüşüm İçin Yol Haritası [A Roadmap for Just Transition on the Road to Net Zero Emissions]. WWF-Türkiye Raporu. <https://www.wwf.org.tr/?13101/Net-Sifira-Giden-Yolda-Adil-Donusum> Erişim: 27 Temmuz 2023.
- Avrupa Komisyonu. (2018a). *EU coal regions: opportunities and challenges ahead*. JRC Science for Policy Report. <https://publications.jrc.ec.europa.eu/repository/bitstream/JRC112593/kjna29292enn.pdf> Erişim: 27 Temmuz 2023.
- Avrupa Komisyonu. (2018b). Report on the results of the Public Consultation: Vision for a long-term EU strategy for reducing greenhouse gas emissions. chrome-extension://efaidnbmnnibpcajpcgclefindmkaj/https://climate.ec.europa.eu/system/files/2019-02/report_en.pdf
- Avrupa Komisyonu. (2020a). Allocation method for the Just Transition Fund. Retrieved from https://ec.europa.eu/commission/presscorner/detail/en/QANDA_20_66
- Avrupa Komisyonu. (2020b). Overview of Investment Guidance on the Just Transition Fund 2021-2027 per Member State (Annex D).
- Avrupa Komisyonu. (2021). The Recovery and Resilience Facility. https://commission.europa.eu/business-economy-euro/economic-recovery/recovery-and-resilience-facility_en Erişim: 27 Temmuz 2023.
- Blazejczak, J., Braun, F.G., Edler, D., Schill, W-P. (2014). Economic effects of renewable energy expansion: A model-based analysis for Germany. *Renewable and Sustainable Energy Reviews*, Volume 40, Pages 1070-1080.
- Borbonus, S. (2017). Generating socio-economic values from renewable energies: An overview of questions and assessment methods. IASS Working Paper, (July).
- Carbon Tracker Initiative (CTI) (2022). Unburnable Carbon: Ten Years On. Erişim: <https://carbontracker.org/reports/unburnable-carbon-ten-years-on/>
- Garcia-Casals, X., Ferroukhi, R. & Parajuli, B. (2019). Measuring the socio-economic footprint of the energy transition. *Energy Transitions*, 3(1–2), 105–118. <https://doi.org/10.1007/s41825-019-00018-6>
- Garrett-Peltier, H. (2017). Green versus brown: Comparing the employment impacts of energy efficiency, renewable energy, and fossil fuels using an input-output model. *Economic Modelling*, Elsevier, 61(C), 439–47.
- IEA (2023a). CO2 Emissions in 2022. <https://www.iea.org/reports/co2-emissions-in-2022> Erişim: 21 Temmuz 2023.
- IEA (2023b). Fossil Fuels Consumption Subsidies 2022. <https://www.iea.org/reports/fossil-fuels-consumption-subsidies-2022> Erişim: 27 Temmuz 2023.
- IEA (2023c). World energy outlook 2022. International Energy Agency: Paris, France.

- ILO (2015). Guidelines for a just transition towards environmentally sustainable economies and societies for all. *Publications of the International Labour Office*.
- ILO (n.d.). Decent work. Retrieved from <https://www.ilo.org/global/topics/decent-work/lang--en/index.htm>
- ITUC (2016). Just Transition Centre. <https://www.ituc-csi.org/intro-jcc> Erişim: 27 Temmuz 2023.
- Kapetaki, Z., Ruiz Castello, P., Armani, R., Bodis, K., Fahl, F., Gonzalez Aparicio, I., Jaeger-Waldau, A., Lebedeva, N., Pinedo Pascua, I., Scarlat, N., Taylor, N., Telsnig, T., Uihlein, A., Vazquez Hernandez, C. and Zangheri, P. (2020). Clean energy technologies in coal regions, Kapetaki, Z. editor(s), Publications Office of the European Union, Luxembourg, doi:10.2760/384605, JRC117938.
- O'Sullivan, M., ve Edler, D. (2020). Gross Employment Effects in the Renewable Energy Industry in Germany—An Input–Output Analysis from 2000 to 2018. *Sustainability* 12, no. 15: 6163. <https://doi.org/10.3390/su12156163>
- Pollitt, H., Lee, S., Park, S-J., Ueta, K. (2014). An economic and environmental assessment of future electricity generation mixes in Japan—an assessment using the E3MG macro-econometric model. *Energy Policy* (Elsevier) 67:243–254
- REN21 (2015). Renewables 2015 Global Status Report, Available at: https://www.ren21.net/wp-content/uploads/2019/05/GSR2015_Full-Report_English.pdf
- REN21 (2020). Renewables 2020 Global Status Report, Available at: <https://www.ren21.net/gsr-2020/> Erişim: 27 Temmuz 2023.
- Sharma, M. (2017). Radical Transformational Leadership: Strategic Action for Change Agents. North Atlantic Books.
- The Scottish Government. (2020, September 7). *Just Transitions: a comparative perspective*. <https://www.gov.scot/publications/transitions-comparative-perspective/pages/3/> Erişim: 9 Ağustos 2024
- Widuto, A. (2019). EU support for coal regions. *EPRS*.
[https://www.europarl.europa.eu/RegData/etudes/BRIE/2019/642217/EPRS_BRI\(2019\)_642217_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/BRIE/2019/642217/EPRS_BRI(2019)_642217_EN.pdf) Erişim: 9 Ağustos 2024.
- WWF (2023). Summary Report: Territorial Just Transition Plan Scoreboard Assessment. <https://www.wwf.eu/?9036866/Territorial-Just-Transition-Plan-Scorecard-Assessment> Erişim: 27 Temmuz 2023.
-
- BEYANLAR:**
- Araştırma ve Yayın Etiği Beyanı:** Bu çalışma bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır.
- Yazarların Makaleye Katkı Oranları:** Birinci yazarın makaleye katkısı %33, İkinci yazarın makaleye katkısı %33, Üçüncü yazarın makaleye katkısı %34'tür.
- Çıkar Beyanı:** Yazarlar açısından ya da üçüncü taraflar açısından çalışmadan kaynaklı çıkar çatışması bulunmamaktadır.
- Araştırma Desteği ve Teşekkür:** Bu araştırma 123K509 no'lu TÜBİTAK 1001 Projesi tarafından desteklenmiştir.
- Etik Kurul Onayı Bilgileri:** Makalede açıklanan araştırmada insan denekleri kullanılmadığı için etik kurul onaylı alınmamıştır.

Borders of Socio-Economic Development in Türkiye

Burhan Can KARAHASAN*

Abstract

Turkish economy is characterized by a dual regional structure. Historically, western regions form the relatively more developed and rich geography of the country. In the meantime, landlocked eastern regions are realizing a period of marginalization pushing majority of these regions toward full isolation from rest of the country. Our knowledge on this dual pattern departs mostly from monetary indicators. In this study, I use the socio-economic development index (SDI) which is first constructed by the State Planning Organization (SPO). The main objective is to use spatial tools for the period of 1963-2017 and to explore the historical evolution of spatial externalities and heterogeneity. This aims to visualize the socio-economic borders of Turkish provinces. While our findings confirm the spatial inertia for the under-developed eastern regions, they also show rising spatial spillovers among the developed western geography. However, this positive impact is geographically bounded by the central part of the country.

Keywords: socio-economic development, regional inequality, Türkiye

JEL Codes: R10, R11

* MEF University, Department of Economics, karahasanb@mef.edu.tr, <https://orcid.org/0000-0001-6293-3592>.

I am grateful to Cem Gürlevik for his research assistance during the data digitalization process for SDI. I would also like to thank the two anonymous reviewers and Fatma Doğruel for their valuable comments and suggestions.

Türkiye'de Sosyoekonomik Gelişmişliğin Sınırları

Öz

Türkiye bölgesel olarak ikili bir ekonomik yapıya sahiptir. Tarihsel olarak, zengin bölgeler batı coğrafyasında kümelenirken, görece daha yoksul ve içine kapalı bölgelerin doğu coğrafyasında bulunduğu görülmektedir. Bu konu hakkında sahip olduğumuz bilgiler ise ağırlıklı olarak parasal göstergelerden oluşmaktadır. Bu çalışmada ilki Devlet Planlama Teşkilatı (DPT) tarafından hazırlanan sosyoekonomik gelişmişlik endeksi (SEGE) kullanılacaktır. Temel amaç, 1963-2017 dönemi için mekânsal araçlar kullanarak tarihsel olarak ortaya çıkan mekânsal dışsallıkları ve heterojenlikleri araştırmaktır. Bu şekilde Türkiye'de sosyoekonomik gelişmişliğin gerçek sınırlarının anlaşılması hedeflenmektedir. Mekânsal analizler batı bölgelerinde sosyoekonomik açıdan hızlı bir biçimde mekânsal yayılma olduğuna, öte yandan doğu bölgelerindeki geri kalmış yapının tarihsel olarak değişkenlik göstermediğine işaret etmektedir. Bu açıdan sosyoekonomik gelişmişliğin sınırlarının az gelişmiş bölgeler açısından katı ve sabit olduğu zengin bölgeler açısından ise orta Anadolu'yu geçmeyecek şekilde yayıldığını söylemek mümkün olmaktadır.

Anahtar Kelimeler: bölgesel eşitsizlikler, sosyoekonomik gelişmişlik, Türkiye

JEL Kodları: R10, R11

1. Introduction

The spatial inertia in the Turkish economy is not new to many scholars (see e.g. Filiztekin, 2018; Doğruel and Doğruel, 2003; Aksoy et al., 2019; Karahasan, 2020). The high prosperity observed among the western regions versus the underdeveloped eastern geography is one of the severest regional duality examples across the globe. Rey and Janikas (2005) also listed Türkiye as one of the core cases to investigate the regional disparities in the developing world.

While Türkiye receives huge interest in terms of the regional structure of economic life, majority of the studies depart from monetary measures to understand regional disparities. This could be perceived as an outcome of the theoretical dominance of neo-classical convergence theory (after 1990s) and the recent advances in the New Economic Geography (after 2000s). Inevitably, this results in under examination of other non-monetary dimensions of regional disparities. However, as highlighted in recent policy reports of the United Nations (UN), economic prosperity is no longer bounded within the borders' monetary indicators (UNDP, 2023).

In this study, I depart from the rising policy awareness on economic development dimension of regional disparities and examine the provincial socio-economic development in Türkiye. The main objective is to use a composite index that controls for various monetary and non-monetary dimensions of economic development and to understand the historical evolution of spatial imbalances in a developing economy. While doing this, spatial analyses will be the main tool as they are instrumental for understanding two central dimensions of regional disparities: (i) spatial externality, (ii) spatial heterogeneity. I believe these dimensions will be central to assess the local borders of socio-economic development in Türkiye.

Findings of the paper are expected to contribute not only to our understanding on regional disparities in Türkiye but also would offer additional insight to the evolving discussions on controlling for non-monetary aspects of regional prosperity. Moreover, the use of spatial methods will provide more space to discuss the effectiveness of regional policies. While this could be perceived as a tool to understand the success and failure stories, what is more remarkable is the ability to distinguish the effectiveness of policy borders for developed and less-developed territories.

In the next section (Section 2), I will first introduce the data and provide the technical basics of spatial analyses used in this paper. In Section 3, findings will be summarized, and the paper will end with discussions for future research paths in Section 4.

2. Data and Methodology

2.1 Data

The data source is the Socio-economic development index (SDI) which is first developed by the State Planning Organization (SPO). It covers various dimensions of regional development and not bounded by monetary indicators. Historically, SPO announced the SDI for certain years. Later on, SPO is closed, and the production of the index is carried out by the Ministry of Development. With the very recent constitutional and administrative changes, it is now published by the Ministry of Industry and Technology. The first report of SPO is published in 1969. However, it is remarkable to underline that calculation of the index dates back to 1963 and accessible from the first socio-economic development report of the SPO. This points-out the planning and development awareness of the SPO during the early years of its establishment. Index can be obtained from periodicals continuously covering the years between 1963 and 1972. Later, SDI is announced in a discontinuous way for 1980, 1985, 1991, 1996, 2003, 2011 and 2017 at the provincial level. As of 2024, the whole index reports are provided by the Ministry of Industry and Technology (MIT, 2024). It must be noted that there are various methodological and coverage changes in the SDI throughout the sample period. In this study, I do not carry out any harmonization attempts but the SDI scores are standardized by using the min-max methodology. Moreover, the number of provinces increases from 67 to 81 during the sample period. To make annual analyses comparable, I collapse each year to 67 provinces by taking the mean values of the provinces that used to belong to the same administrative unit.

Overall SDI is an index composed of various monetary and non-monetary indicators. The objective of the index is to provide an aggregate development measure at the regional level. Interestingly, it receives less attention by the scholarly literature as most of the existing studies depart either from monetary dimension of regional disparities (e.g. see Doğruel and Doğruel (2003) for per capita GDP differences among others) or prefer to focus on individual aspects of regional development (e.g. see Karahasan and Bilgel (2019, 2020) for education and health among many others). Yet, a holistic approach to analyze historical origins of regional socio-economic development in Türkiye is still missing.

An important dimension of the SDI is its coverage. Historically, variables and dimensions used in the SDI are updated. While this makes a historical comparison challenging, it also provides a better understanding of regional disparities from a historical perspective. This is because updated dimensions make it easier (and more accurate) to understand the socio-economic development as priorities of regions and Türkiye is not static and stable. Within the recent report for the year 2017, main dimensions covered by the index are gathered under eight domains and are as follows: (i) demography, (ii) labour force, (iii) education, (iv) health, (v) competitiveness and

innovation, (vi) finance and monetary indicators, (vii) accessibility and (viii) quality of life. Details of the variables can be traced from MIT (2024).

2.2 Measuring spatial externalities and heterogeneity

There are two main dimensions in the empirical setup of my analyses. I start by considering the spatial autocorrelation as an important exploratory exercise to understand whether socio-economic development of provinces is spilling over to their proximity. This is what I mean by the spatial externalities generated at provincial level. I believe analyzing spatial externalities includes clues on the potential differences between administrative and factual borders of the Turkish regions. In other words, examining the spatial externalities are expected to show the accurate extent of the socio-economic policies which are not necessarily constrained by the administrative borders of Turkish provinces.

To understand spatial externalities, I refer to a very well-known and commonly used exploratory tool in the spatial data analysis; Moran's I (Equation 1). w is the weight matrix, n is the number of provinces, s is the summation of all elements in the weight matrix. There are different weight matrices to define spatial relationships. Among many, contiguity and different distance-based weight matrices are commonly preferred by scholars. In this study, I use an inverse distance weight matrix that assigns the inverse of the distance between each pair of provinces in the corresponding cell of the weight matrix (67×67). The null hypothesis of the Moran's I test is spatial randomness. Rejection of the null hypothesis confirms the existence of spatial autocorrelation, thus externalities.

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij}(x_i - \bar{x})(x_j - \bar{x})}{s \sum_{i=1}^n (x_i - \bar{x})^2} \quad (1)$$

Analyzing the spatial externalities is vital as it shows the likelihood for close provinces to affect each other. That said, spatial externality detected in Equation 1 gives a global picture to the researchers and fails to provide any feedback on the local reflections. However, detected spatial dependence in the first set of analyses can depart from provinces with different socio-economic fundamentals. It could be the less developed regions that generate negative externalities which spillover towards their proximity. On the contrary, spatial externality can evolve from prosperous regions in the form of rising positive economies. In other words, there can be sizable spatial heterogeneity in terms of the externalities created in close proximity.

One way to understand this locality is to decompose the spatial externalities. Anselin (1995) offers a solid way to decompose the Moran's I (Equation 1) and constructs the Local Indicator of Spatial Association (*LISA*) (Equation 2). The main idea is to cluster regions based on how the values locate within the overall distribution. However, the important modification is the geographical clustering of the provinces.

Four main groups (2 clusters and 2 outliers) are formed and regions that significantly contribute to the spatial externalities are grouped accordingly. High-High (H-H) and Low-Low (L-L) clusters are composed of provinces that have high and low values (compared to the average). Meanwhile, High-Low (H-L) and Low-High (L-H) are the outliers with high and low values unlike their close proximity.

$$I_i = (x_i - \bar{x}) \sum_{j=1}^n w_{ij}(x_j - \bar{x}) \quad (2)$$

A notable dimension of the spatial heterogeneity analysis is its ability to show how regions cluster and polarize from each other. Moreover, it enables to distinguish the low and high values of the association. In other words, it allows for decomposing the spatial externalities and observing the different forms of spatial association at the local level.

3. Findings

I start by analyzing the path of regional disparities and spatial autocorrelation for each year SDI is provided. First set of descriptive findings are summarized in Table 1. Historically, the mean value of the SDI increases. Note that, potential methodological modifications make it difficult to trace the historical evolution. However, it is worth highlighting that rising average socio-economic development also coincides with acceleration in the standard deviation (St. dev.) of the SDI (and partially coefficient of variation-CoV.). This could be the minor signs on the start of socio-economic polarization across the Turkish regions.

Table 1. Regional disparities and spatial externalities

	Mean	St. Dev.	CoV.	Moran's <i>I</i>
1963	0.170	0.148	0.867	0.119***
1964	0.175	0.157	0.900	0.114***
1965	0.166	0.149	0.898	0.113***
1966	0.173	0.147	0.845	0.098***
1967	0.181	0.151	0.830	0.114***
1968	0.185	0.152	0.825	0.113***
1970	0.188	0.154	0.817	0.105***
1971	0.193	0.157	0.812	0.107***
1972	0.199	0.159	0.801	0.103***
1980	0.198	0.160	0.808	0.098***
1985	0.083	0.148	1.788	0.018***
1991	0.325	0.236	0.727	0.225***
1996	0.330	0.224	0.679	0.258***
2003	0.265	0.198	0.746	0.223***
2011	0.501	0.300	0.600	0.288***
2017	0.679	0.344	0.507	0.317***

Notes: *** represents significant spatial autocorrelation at 1%

While dispersion measures are useful to evaluate the path of regional variation in socio-economic development, it fails to describe the formation of spatial clustering and externalities. Missing the information embedded in spatial externality causes loss of information on the true borders of the socio-economic development. Moran's *I* values show significant and positive spatial autocorrelation for each of the years in the sample (Table 1). Moreover, the strength of spatial externality accelerates throughout the sample period. After the early 1990s, there is a significant jump in the spatial autocorrelation which seems to stabilize even at higher levels during the 2000s. From a technical perspective this must be perceived as a vital sign for the acceleration of spatial externalities. On the other hand, globalization trends have inevitable influence on the potential reshuffling of spatial interactions.

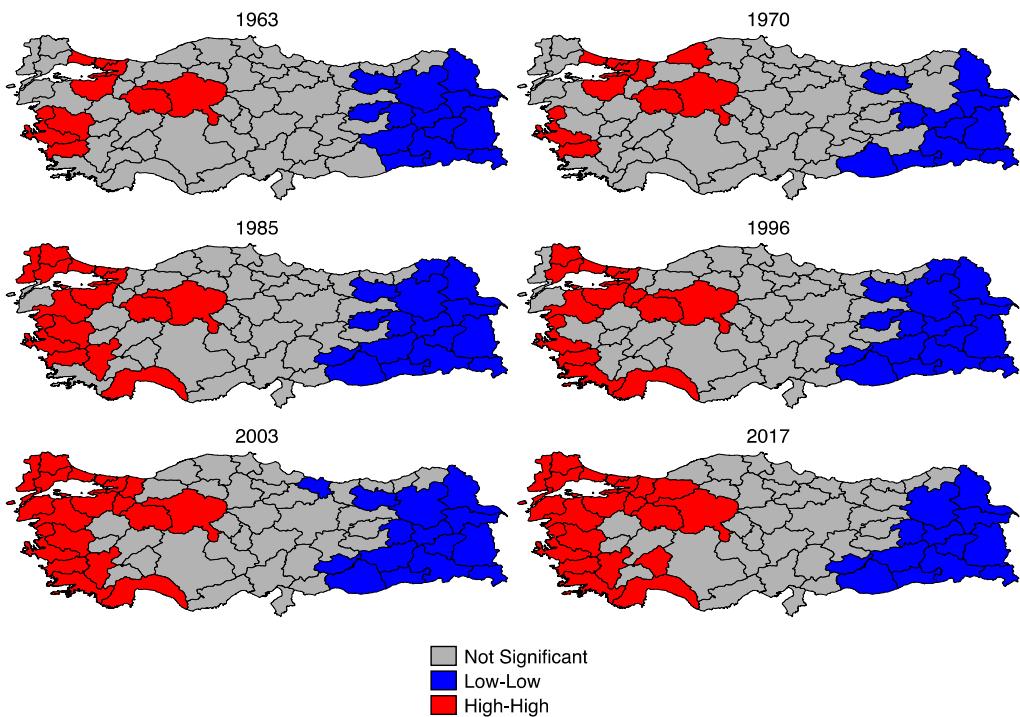
Regions' spatial clustering seems to be weaker during the early 1960s. Interestingly, through 1990s with rising average socio-economic development, one can observe rising spatial autocorrelation as well. This is a sign for more spatial dependence across the Turkish regions. From a developmental perspective, this also signals that while regions on average earn higher socio-economic development, their development

trajectories tend to become more dependent to their spatial proximity. In other words, spatial externality starts to get more central for the socio-economic development of the average Turkish region. This finding is crucial as it contradicts with the expectation that rising socio-economic development will foster more independence at the local level (in terms of economic fundamentals). On the contrary, the first set of analyses show just the opposite as socio-economic progress coincides with the rising spatial externality, thus dependence.

Our findings so far yield information on the average Turkish region. Therefore, from a technical standpoint these results must be perceived as the global analysis of regional socio-economic development. However, one might suspect of the potential spatial heterogeneity which groups winners and losers in terms of socio-economic development. Moreover, spatial heterogeneity is instrumental for understanding the borders of centralized and localized policies. Therefore, remaining analyses is devoted to decomposing the first set of spatial externality analyses by clustering regions based on varying spatial dependence patterns.

I start by implementing the *LISA* analyses for selected year of the sample (1963, 1970, 1985, 1996, 2003 and 2017). This enables a better evaluation of the spatio-temporal patterns in the local spatial interactions. Results for spatial heterogeneity analyses are provided in Figure 2. The first important finding is the lack of any significant spatial outliers during the entire sample. This is an early but an important sign for the polarization of the Turkish regions. In terms of socio-economic development, *LISA* analyses indicate the formation of two separate cluster of regions composed of high and low socio-economic development (High-High and Low-Low, respectively). The second important finding from the *LISA* analyses is about the Low-Low cluster which is historically composed of eastern regions. Careful inspection of the Low-Low cluster points out an important spatial inertia across the less-developed eastern regions. From mid-1960 to 2017, clustering pattern of the socio-economically less developed eastern regions does not change. During the entire sample period, this cluster has almost a stable border covering the historically less developed territory of the country. This reminds that, although we detect rising spatial externality for the average Turkish regions, it seems less likely for the less developed regions to benefit from the positive aspects of spatial externalities. This creates additional concerns on the existence of negative spatial externalities across the less developed regions of Türkiye.

Figure 1. Evolution of spatial heterogeneity



Source: Author's calculations based on SDI

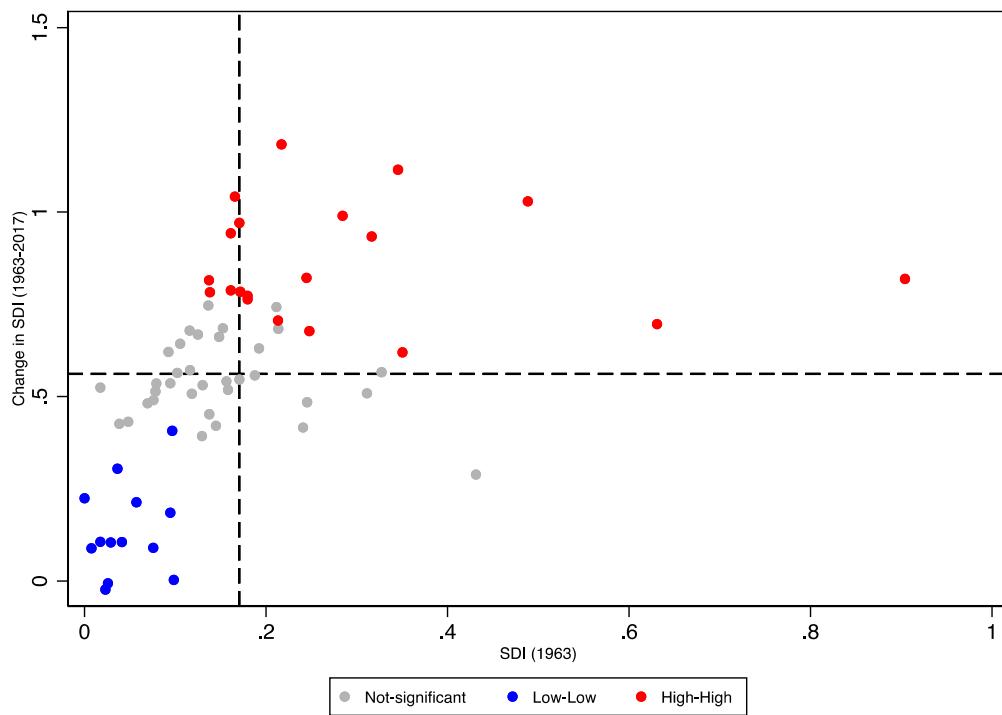
A final important dimension of Figure 1 relates to the High-High cluster which is composed of regions with advanced socio-economic development. Unlike the regions in the Low-Low group we realize increase in the number of regions in this cluster. These findings match with the remarks on manufacturing based industrial development mainly in the hinterland territory of İstanbul and Western Türkiye (Doğruel, 2013). Like the geographical enlargement of industrial externalities in the western part of the country socio-economic development of Turkish regions follow a similar topographical pattern. This reminds that industrialization attempts of the 1960s is beyond changing the production structure and has significant influence on development patterns of Turkish regions.

These exploratory findings provide clues on how the rise in global spatial externality is reflected across the relatively more advanced regions of the country. It is fair to acknowledge that spatial externality creates positive economies mostly across the already developed western regions. Remarkably, spatial externality seems to benefit some of the central regions closed to the western geography. In other words, it is mostly the already developed regions and their proximity that benefit from spatial spillovers.

However, the resulting pattern is a clear spatial heterogeneity which creates massive polarization in terms of local socio-economic development in Türkiye.

Our exploratory analyses so far show the polarization of socio-economic development. Moreover, these analyses also provide clues on the impact borders of spatial externalities. To link these findings with the evolution of regional development gaps in Türkiye, I carry-out a final descriptive exercise by borrowing the neo-classical spirit on the regional catch-up, thus convergence. Simply, I plot the correlation between the provincial SDI in 1963 with the change in the SDI from 1963 to 2017 (Figure 2). At this stage, I must acknowledge the potential limitation as SDI is constructed based on different methodologies (coverage modifications) during the entire sample. However, one must keep in mind that no inferential analyses are carried out at this stage. Still, these final set of descriptive findings must be evaluated based on the methodological differences of the SDI for various years.

While plotting the relationship between the initial SDI scores and the change in the SDI, I also group the 67 provinces based on their spatial clustering behavior at the end of the sample, 2017. Results which are plotted in Figure 2 contain interesting insight on the importance of considering the non-monetary dimensions of regional disparities. These descriptive exercises show that there is no actual catch-up in terms of regional development. The socio-economic difference across the Turkish regions seems to widen even more during the whole sample. Majority of the Turkish regions that locate in the high socio-economic cluster in 2017 are already the ones with above average socio-economic development in 1963. It is remarkable to highlight that these regions realize an above average change in the SDI throughout the sample period. On the contrary, the cluster with lower socio-economic development are composed of regions with below average socio-economic development in 1963 and below average socio-economic development change during the entire analysis period. These results are crucial as they show that regional disparities are even wider once non-monetary and socio-economic aspects of development are considered.

Figure 2. Clustering and polarization

Source: Author's calculations based on SDI

Notes: Dashed lines represent the country averages for SDI (1963) and the change in SDI (1963-2017).

4. Discussion

Socio-economic development across the Turkish provinces mostly mimics the very well-known regional duality. Overall, similar to earlier remarks on monetary dimension of regional disparities (Doğruel and Doğruel, 2003; Filiztekin, 2018; Aksoy et al., 2019; Karahasan, 2020) there is a huge gap between developed west and underdeveloped east part of the country. That said, it also reminds that things are worse than it is believed based on monetary indicators. Specifically for the less developed eastern regions, there is huge spatial inertia rooted with deep negative economies. This pattern is stable for almost five decades for the Turkish economy. In the meantime, for more developed western regions, there is potential to generate a developmental positive externality. Careful inspection of local spatial associations shows that number of provinces in the high development cluster accelerates during the sample period. Yet, one must note that the detected positive economies are geographically bounded by the very close proximity of the developed western regions. It is the central Anatolia where the spillover of positive economies vanishes and loses its effectiveness. These results are consistent with earlier remarks on regional development differences that are measured by examining health and education domains of economic development (Karahasan and

Bilgel, 2019; 2020). However, findings of the paper provide additional information on the historical roots of socio-economic development. Unlike the prior studies which focus mainly on the post 2000s, findings of this study validate that, roots of the socio-economic development date back to almost half-century in Türkiye. Additionally, findings validate that last two-decades witness a clustering across winners and losers of economic development. While, developed west manages to spread its development (to its near proximity) less developed eastern regions become more isolated in terms of socio-economic development.

Moreover, findings provide interesting insight on the true nature of regional catch-up across Turkish provinces. While I do not have any causal assessment in this study, very basic correlation exercises show that socio-economic development and progress is still a phenomenon belonging to the already developed western regions. On the contrary, advancement in economic development of the eastern regions is far below the western counterparts. This suggests limited room to talk about closing the huge gaps between the developed west and the underdeveloped east part of the country.

The central objective of the paper is to analyze regional disparities from a developmental and spatial perspective in Türkiye. The follow-up question and concern should be “*what to do now?*”. Eventually, one might think from a policy perspective and discuss certain tools to combat with regional disparities. Yet, this has already been done both in academic and policy circles. What is less preferred is to think on potential lines of research which will guide the regional science and economics community in the future. In this final part of the paper, I would like to direct a few lines which I believe needs further attention of scholars interested in the Turkish regional duality. It must be noted that listed dimension here should not be regarded as the policy kit to combat regional disparities. Rather, they are better evaluated if considered as potential elements creating endogenous feedback with regional disparities.

The main domain that requires further attention is the political economy of regions. Within this domain following dimensions are receiving huge interest by political scientists, regional scholars and eventually economists: the spread of the discontent from global to local economies, the rise of discussions on clientelism which fosters local distributive politics and the potential influence of local institutional quality. The seminal contributions of Rodríguez-Pose (2018) on how falling regions react in elections is an important starting point. However, for the Turkish context “fall” of a region should not be perceived only from an economic perspective. The discontent as a result of non-economic factors is also critical (e.g. healthcare crisis, natural disasters, wildfires and other sector specific disasters among many others). One might argue the exogeneity of these events but must also consider the lack of policy effectiveness which is endogenous by its nature. Related with these non-economic events local infrastructural and institutional capabilities that shape human capital development, cultural and related amenities are also critical dimensions which influence life

satisfaction. Inevitably, life satisfaction stands as a vital candidate to understand local discontent and dissatisfaction. A related dimension of the political economy of regions is the distributive politics. Recent discussions validate that distribution of public sources directly or indirectly affects regional welfare and can be a key element for understanding political decision of regions (see e.g. Livert and Gainza, 2018). This must be perceived crucial for regional disparities as existing geographical gaps stand alone as a motivation for further clientelist relations.

Final dimension I would like to highlight is the role of institutions. When it comes to discuss how institutions influence economic outcomes, we tend to refer inevitably to Acemoğlu and Robinson (2013). As a rapidly developing field, regional science also uses a similar narrative to carry these discussions to local level. Among different attempts the one that receives the huge interest is the quality of government index of the European Union - EU (see Charron et al., 2024 for the most recent version of the index). Various studies show that institutional quality differences across the EU regions explain why some regions are more innovative and why these regions benefit from a better socio-economic well-being within their territories. It is true that institutions are not the only solution for mitigating the adverse effects of regional backwardness. Moreover, the way institutions affect economic development can be asymmetric across developed and developing countries. From the perspective of Türkiye, transformation of various institutions must be analyzed with caution to understand the full effect of institutional change and development. But it must be kept in mind that institutions have huge influence on certain factors that are already discussed to be the effective causes of regional growth and socio-economic well-being (e.g. innovation, investment climate, job creation, investment in human capital among many others).

To sum up, building on our accumulated knowledge on the sources of regional disparities, more effort seems essential to offer new solutions for decreasing the adverse effects of Turkish regional duality. While topics such as green growth, climate change, circular economy and innovation based digital transformation are receiving huge interests nowadays, application of all these batteries to regional level have roots with understanding the political economy of regions. Without proper investigation of discontent, clientelism and role of institutions at the regional level, even contemporary developments in the economic development theory will be threatened by the lack of effectiveness in the future.

References

- Acemoglu, D., & Robinson, J. A. (2013). *Why nations fail: The origins of power, prosperity, and poverty*. Crown Currency.
- Aksoy, T., Taştan, H., & Kama, Ö. (2019). Revisiting income convergence in Turkey: Are there convergence clubs?. *Growth and Change*, 50(3), 1185-1217.
- Anselin, L. (1995). Local indicators of spatial association—LISA. *Geographical analysis*, 27(2), 93-115.
- Charron, N., Lapuente, V., & Bauhr, M. (2024). The Geography of Quality of Government in Europe. Subnational variations in the 2024 European Quality of Government Index and Comparisons with Previous Rounds. University of Gothenburg, QoG Institute Working Paper Series, No: 2024:2.
- Doğruel, F. (2013). Deindustrialization of old industrial regions in Turkey. *Rives méditerranéennes*, (46), 93-108.
- Doğruel, F., & Doğruel, A. S. (2003). Türkiye'de bölgesel gelir farklılıklarını ve büyümeye. Köse, AH, Şenses, F ve Yeldan, E.(der.) *İktisat Üzerine Yazilar I: Küresel Düzen, Birikim, Devlet ve Sınıflar, Korkut Boratav'a Armağan içinde*, 287-318.
- Filiztekin, A. (2018). Convergence across industries and provinces in Turkey. *Ekonomi-tek*, 7(3), 1-32.
- Karahasan, B. C. (2020). Winners and losers of rapid growth in Turkey: Analysis of the spatial variability of convergence. *Papers in Regional Science*, 99(3), 603-644.
- Karahasan, B. C., & Bilgel, F. (2019). Spatial distribution of healthcare access and utilization: do they affect health outcomes in Turkey?. *Middle East Development Journal*, 11(1), 124-163.
- Karahasan, B. C., & Bilgel, F. (2020). Market access and regional dispersion of human capital accumulation in Turkey. *Review of Development Economics*, 24(3), 1073-1101.
- Livert, F., & Gainza, X. (2018). Distributive politics and spatial equity: the allocation of public investment in Chile. *Regional Studies*, 52(3), 403-415.
- MIT (2024). Ministry of Industry and Technology, Socio-economic development index (SDI), <https://www.sanayi.gov.tr/merkez-birim/b94224510b7b/sege> (last accessed on 19 July 2024).
- Rey, S. J., & Janikas, M. V. (2005). Regional convergence, inequality, and space. *Journal of Economic Geography*, 5(2), 155-176.
- Rodríguez-Pose, A. (2018). The revenge of the places that don't matter (and what to do about it). *Cambridge Journal of Regions, Economy and Society*, 11(1), 189-209.
- UNDP (2023). 2023 Global Multidimensional Poverty Index, Unstacking global poverty: Data for high impact action, New York.

DISCLOSURE STATEMENTS:

Research and Publication Ethics Statement: This study has been prepared in accordance with the rules of scientific research and publication ethics.

Contribution rates of the authors: First author (100%)

Conflicts of Interest: Author states that there is no conflict of interest.

Ethics Committee Approval: Ethics committee approval was not obtained because human subjects were not used in the research described in the paper.

Logistics Performance and Environmental Degradation: The Case of MENA Countries

Seda EKMEN ÖZÇELİK*

Ünal TÖNGÜR**

Abstract

This article analyzes the impact of logistics performance on environmental degradation for a panel of 20 economies in the Middle East and North Africa (MENA) from 2007 to 2018. Logistics performance is measured by the Logistics Performance Index (LPI) and its sub-indices as developed by the World Bank, while environmental degradation is measured by CO₂ emissions and ecological footprint. According to the empirical findings, improvements in logistics performance raise environmental degradation for oil-rich MENA countries, while the effect of that variable is statistically insignificant in the case of non-oil-rich MENA countries. Higher values for the LPI and its sub-indices are not necessarily associated with environment-friendly (green) practices. Considering the adverse environmental effects of logistics performance, such regulations as judicial and governmental protection of natural resources and well-designed practices for green logistics are needed. More accurate alternative indicators can also be developed and formulated to evaluate green logistics in the MENA region, as the LPI and its sub-indices do not tend to reflect environment-friendly practices.

Keywords: Middle East and North Africa Economies, logistics performance, environmental degradation, green practices

JEL Codes: C13, C23, C33, F64, Q56

* (Corresponding Author) Department of International Trade and Business, Ankara Yıldırım Beyazıt University, Ankara, Türkiye, sedaekmenozcelik@aybu.edu.tr, <https://orcid.org/0000-0001-9946-4785>

** Department of Economics, Akdeniz University, Antalya, Türkiye, unaltongur@akdeniz.edu.tr, <https://orcid.org/0000-0002-6891-6854>

Lojistik Performans ve Çevresel Bozulma: MENA Ülkeleri Örneği

Öz

Bu makalede lojistik performansın çevresel bozulma üzerindeki etkisi, Orta Doğu ve Kuzey Afrika (MENA) bölgesindeki 20 ekonominin kapsayan bir panel veri kullanılarak 2007-2018 dönemi için analiz edilmektedir. Lojistik performans için Dünya Bankası tarafından geliştirilen Lojistik Performans Endeksi (LPI) ve alt endeksleri, çevresel bozulma için ise CO₂ emisyonları ve ekolojik ayak izi göstergeleri kullanılmaktadır. Ampirik bulgularda lojistik performansındaki iyileşmelerin petrol zengini MENA ülkeleri için çevresel bozulmayı artırmakta (dolayısıyla çevresel sürdürülebilirliği zayıflatmakta) olduğu, petrol zengini olmayan MENA ülkeleri için bu değişkenin etkisinin istatistiksel olarak anlamsız olduğu görülmektedir. LPI ve alt endekslerinin daha yüksek değerler alması ile çevre dostu (yeşil) uygulamalar arasında doğrudan bir ilişki olduğu söylenemez. Dolayısıyla lojistik performansın olumsuz çevresel etkileri göz önüne alındığında, doğal kaynakların hukuki ve resmi olarak korunması gibi düzenlemelere ve yeşil lojistik için iyi tasarlanmış uygulamalara ihtiyaç duyulmaktadır. LPI ve alt endeksleri çevre dostu uygulamaları yansıtma eğiliminde olmadığından, MENA bölgesindeki yeşil lojistiği değerlendirmek için daha uygun alternatif göstergeler geliştirilebilir ve formüle edilebilir.

Anahtar Kelimeler: Orta Doğu ve Kuzey Afrika Ekonomileri, lojistik performans, çevresel bozulma, yeşil uygulamalar

JEL Kodları: C13, C23, C33, F64, Q56

1. Introduction

At national level, a country's logistics performance is a major determinant of its economic capabilities because logistics infrastructure connects producers with supply chains, consumers with products and people with communities through urban and rural networks. At international level, effective and efficient logistics networks constitute the cornerstone of global production and trade. In this context, logistics refers to the group of connected activities necessary to transfer goods through effective supply-chains, which involve freight transportation, information processing, material handling, and the storage and management of inventory (Martel and Klibi, 2016). Ineffectively overseen and unproductive logistics procedures lead to heightened operational and capital expenditures due to such factors as under-utilization of existing resources and prolonged waiting time (Windmark and Andersson, 2015). Therefore, improvements in logistics performance are considered to be a major priority for sustaining economic growth, facilitating trade, increasing export variety and boosting competitiveness in global markets (Gani, 2017; Kim and Min, 2011; Töngür et al., 2020; D'Aleo and Sergi, 2017a).

However, potentially negative effects of logistics activities are also questioned along with the mounting concerns on environmental degradation. According to International Energy Agency (IEA)(2019), transport sectors, together with electricity and heat generation, are accountable for two-thirds of the total carbon emissions in 2017. Similarly, a United Nations (2014) report states that logistics transportation produces around 22% of global carbon dioxide (CO₂) and approximately 19% of black carbon emissions, which are technically negative environmental externalities detrimental to human health. In the face of such alarming estimations, Alam and Lee (2021) warn that, by 2050, carbon emissions from logistics activities may increase by 60%, unless adequate measures are taken. The International Transport Forum's "Freight Model" forecasts approximately a fourfold increase in increased emissions from trade-related freight transportation also by 2050 (Wild, 2021).

Transportation is an obvious cause of greenhouse gas (GHG) emissions, with road transportation being the most significant source (Larson, 2021). This causation runs mainly through the high dependence on fossil fuels for transportation and the fuel inefficiency of vehicles. Intensity of transportation and long delivery times increase carbon emissions by raising fossil fuel consumption (Khan et al., 2019; Rashidi and Cullinane, 2019). Moreover, logistics is a consumptive segment of the economy in terms of its propensity for energy depletion. Immoderate levels of energy usage tend to become all the more problematic especially in emerging and developing economies where transportation systems expand rapidly in response to soaring market demand, degrading the environment further through the augmented need for energy. Last but not least, logistics operations can also have adverse impacts on air and water quality. The use of heavy-duty trucks and other transportation equipment can lead to air pollution, while the

disposal of hazardous materials such as oil and chemicals can result in water pollution (Zaman and Shamsuddin, 2017).

On the other hand, environmentally-conscious improvements in logistics performance can help reduce carbon emissions and enhance environmental quality and sustainability. For example, raising the efficiency of transportation systems can economize fuel consumption and reduce emissions by optimizing transportation routes and vehicle utilization (Barth and Boriboonsomsin, 2009). Effective and prudent investments in logistics can promote modal shifts in transportation, favoring, for instance, substitutable and more sustainable modes like railways or waterways that reduce carbon emissions as well as trucking congestions (Larina et al., 2021). Environment-friendly infrastructure development projects can also be associated with energy-efficient technologies and sustainable construction practices. Such technologies and practices encompassing the entire supply chain, such as waste-reduction acts and eco-friendly procurements, can remarkably improve environmental performance.

On the contrary, increased transport activity resulting from improved logistics can lead to higher carbon emissions and air pollution if it relies on environmentally impactful modes of transport. Infrastructural enlargements to support logistics improvements can effectuate habitat destruction and loss of biodiversity if not properly planned. Unregulated expansion of logistics activities may cause transport congestions, leading to delays, inefficiencies, increased fuel consumption, rising emissions and heavier air pollution. Greater priority put on transportation speed and commercial efficiency in the context of logistics operations can generate environmentally undesirable outcomes, such as resource overutilization and packaging waste. While well-designed logistics improvements have the potential to enhance transportation efficiency and environmental sustainability at the same time, uncontrolled hikes in overall energy consumption can bring about environmental degradation especially if cleaner energy alternatives are not adopted.

This dilemma can be addressed within the context of Jevons' paradox. This paradox was first proposed by William Stanley Jevons in the 19th century in relation to coal consumption in the UK. Jevons (1906) observed that the higher efficiency in coal utilization resulted in an increase in its consumption rather than a decrease, due to the lower cost and increased resource availability. Therefore, it pertains to the occurrence in which enhancements in the efficiency and productivity of resource utilization might result in a rise in the total consumption of the resource, rather than a reduction. Jevons' paradox is relevant to resource efficiency and sustainability discussions in various ways. For example, in the case of irrigation technology, Sears et al. (2018) suggest that embracing advanced irrigation technology for enhanced efficiency may not necessarily lead to a decrease in water consumption, as farmers may choose to irrigate more land or crops due to the lower cost and increased availability of water. Similarly, in the case of agricultural productivity, Ceddia (2019) suggests that increased productivity may lead

to agricultural expansion, rather than land-sparing, due to the increased value of cleared land. Jevons' Paradox is also associated with discussions of energy efficiency, climate change and environmental degradation. Trincado et al. (2021) suggest that energy efficiency measures may lead to higher levels of energy consumption, due to the lower cost and increased availability of energy, which could increase the risk of climate change and environmental degradation.

In our study, Jevons' paradox is discussed in the context of logistics performance and environmental degradation. In this context, Jevons' paradox suggests that even if improvements in logistics efficiency and sustainability practices result in lower energy consumption or emissions per unit of transported goods, the overall environmental benefits may be offset or even eliminated by an increase in the total volume of goods being transported. For example, if logistics improvements allow for faster and cheaper delivery of goods, it can stimulate an increase in consumer demand and global trade. This increase in demand can lead to a higher volume of goods being transported, resulting in more energy consumption, emissions, and environmental impacts. This paradoxical outcome is known as the "rebound effect" or "backfire effect". Therefore, as the "Jevons' Paradox" emphasizes, it is critical to consider the unintended implications of logistics improvements and to take a holistic approach to sustainability that considers the complex interactions between economic, social and environmental factors.

In the empirical literature, the link between logistics performance and environmental sustainability has recently been a topic of discussion (Li et al., 2021; Magazzino et al., 2022). However, the findings show that the nature of the nexus between environmental degradation and logistics performance remains unclear and needs further investigation.

Most developing nations experience logistics-base inefficiencies when it comes to connecting to global manufacturing networks and distributing their products to global markets as well as environmental degradation alongside their economic growth targets (Hausman et al., 2013; Martí et al., 2014; Yadav, 2014; Saslavsky and Shepherd, 2014). This dilemma is particularly critical for the Middle East and North Africa (MENA) region. While environmental degradation is a serious concern for the MENA economies due to the abundant use of fossil fuels and non-renewable energy sources, the need for more sustained growth is also quite high due to occasionally unfavorable conditions in the oil market, rapid population growth, structural unemployment and other socio-economic problems. MENA countries also suffer from logistics inefficiencies such as customs procedures, customs clearance and bureaucratic control in transit. Therefore, balancing economic and environmental aspirations so as to achieve sustainability goals is all the more momentous in the MENA region. Indeed, the gist of the story for MENA is attached to the question as to whether improvements in logistics performance can also serve to eliminate or mitigate the harmful effects of logistics activities on the

environment. And if the answer is negative, countries in the region should look for ways to accomplish this task.

In light of this introductory background, this study aims to fill several gaps in the literature by focusing on the MENA region. Environmental effects of logistics performance are examined in detail through descriptive and econometric analyses for 20 economies in the MENA region, using annual data spanning from 2007 to 2018. Our benchmark regression analysis employs fixed-effects panel data estimation. Considering the potential problem of endogeneity, fixed-effects instrumental variable (FE-IV) regression and generalized methods of moments (GMM) estimation are also implemented, which provide us with robustness checks for the results of the benchmark regression.

The rest of the paper is organized as follows. Section 2 presents the literature review. Section 3 introduces the data and the descriptive statistics. Section 4 presents the econometric methodologies and the regression results. Section 5 concludes with some useful policy implications that can serve as data-based insights for policymakers to pave the way for constructing a sustainable development agenda in the MENA region.

2. Literature Review

Most of the studies in the literature examine the relationship between logistics performance and various economic variables such as trade volumes (Çelebi, 2019; Marti et al., 2014), world economic growth (Coto-Millan et al., 2013) and export variety (Töngür et al., 2020). On the other hand, the relationship between logistics performance and environmental sustainability has begun to be examined systematically quite recently alongside the green supply chain management (GSCM) and green logistics (GL) literatures (Liu et al., 2018). The GSCM aims to ensure environmental protection and increasing environmental quality in all processes of the supply chain, from the procurement of raw materials to their final use by consumers. The GL, which can also be understood as a crucial component of GSCM, refers to the use of environmentally friendly and sustainable processes in logistics activities, and thus intends to reduce the negative environmental effects of logistics operations and provide a long-term balancing of environmental and economic objectives (Carter and Liane Easton, 2011; Min and Kim, 2012; Liu et al., 2018).

In general, the empirical studies examining the relationship between logistics activities and the environment employ the Logistics Performance Index (LPI) and its sub-indices developed by the World Bank (2022a) as indicators of logistics performance, while CO₂ emissions are the primary indicator of environmental degradation (Zaman and Shamsuddin, 2017; Khan et al., 2019; Liu et al., 2018; Li et al., 2021; Magazzino et al., 2021). Some of these studies build green logistics performance

indices by integrating collateral environmental indicators into the LPI. Khan et al. (2017), for example, brought together the logistic performance and environmental indicators to analyze the connection between environmental logistics performance and various economic growth factors in 15 selected countries. In a study covering 104 countries, Mariano et al. (2017) constructed a “composite low-carbon logistics performance index”. Kim and Min (2011) expounded a “green logistics performance index (GLPI)”, applied to 146 nations, merging two out of the six LPI indicators (specifically “infrastructure and timeliness”) with indicators in the “Environmental Performance Index (EPI)” developed by the World Economic Forum, which measure GHG and other emissions. Lu et al. (2019) developed an “environmental logistics performance index (ELPI)” to assess overall logistics performance in terms of environmentally-friendly transportation and logistics applications in 112 countries.

There are few studies that examine specifically the effect of logistics activities on environmental degradation at a macro level, and the results of these studies are mixed. That is to say, there is no consensus as to whether improvements in logistics performance, measured by higher LPI, have significant or positive effects on environmental degradation. Moreover, some of the studies point out that these effects vary considerably according to LPI sub-indices and geographical regions.

Some recent studies find that increases in LPI contribute to environmental sustainability by reducing CO₂ emissions. For instance, Liu et al. (2018) analyze the impact of logistics performance on environmental degradation in 42 ASEAN countries between 2007 and 2016, based on a system-generalized method of moments (GMM) regression model. They conclude that the impact of LPI on environmental degradation varies according to its sub-indicators (e.g., logistics ‘timeliness’ significantly increases CO₂ emissions, whereas ‘international shipment’ significantly reduces them). They also emphasize that the effects of LPI vary in the sub-regions of Asia, such as East Asia, Central Asia, Middle East and South Asia. Zaman and Shamsuddin (2017) analyze the same relationship for 27 European countries from 2007 to 2014 by GMM regressions. Similar to Liu et al. (2018), they use sub-indices of LPI as proxies for logistics performance and conclude that the sub-indices are significantly related to environmental degradation. For example, improvements in ‘transport-related infrastructure’ decrease CO₂ emissions, while higher ‘competence and quality of logistics services’ increase them. Comparing the results of Liu et al. (2018) and Zaman and Shamsuddin (2017), it can be deduced that the impact of logistics performance on environmental degradation is quite different in Asian and European countries. Liu et al. (2018) attribute this variation to the differences in environmental policies and GSCM practices in the two regions. Karaduman et al. (2020) analyzed the effects of logistics performance on environmental degradation for 11 Balkan countries for the period 2010-2016, using the fixed-effects panel data model. Similar to Liu et al. (2018) and Zaman and Shamsuddin (2017), they measure logistics performance by LPI, but unlike them, they use overall LPI instead of its sub-indexes in their models. Their analysis shows that higher LPI

scores lead to lower CO₂ emissions. Suki et al. (2021) analyze the impact of overall LPI on CO₂ emissions in such Asian countries as China, Singapore, India, Japan and Turkey, based on “IPAT (Impacts, Population, Affluence, and Technology)” and “STIRPAT (Stochastic Impacts by Regression on Population, Affluence, and Technology)” models for the period 2010-2018. Similar to Karaduman et al. (2020), they find that LPI contributes significantly to pollution reduction

There are also studies finding that CO₂ emissions increase as LPI increases. For example, Khan (2019) uses two sub-indices of LPI, ‘quality of logistics services’ and ‘infrastructure’, as proxies of logistics performance and concludes that better logistics performance increases environmental degradation for ASEAN countries, based on an GMM estimation from 2007 to 2017. Li et al. (2021) use the same sub-indices. In their study, based on two-stage least squares (2SLS) and GMM models over the period 2007-2019, they find that enhancements in logistics efficiency increase CO₂ emissions in One Belt and Road Initiative (OBRI) countries, Central Asia and MENA, but decreases them in Europe, East and South Asia. The results of Larson (2021) also indicate that logistics activities fail to reduce CO₂ emissions for 160 countries in 2016. Similarly, Magazzino et al. (2021), in his study for 25 countries with the highest LPI between 2007 and 2018, uses Fully Modified Ordinary Least Squares (FMOLS), GMM and Quantile Regression (QR) models to conclude that LPI increases CO₂ emissions. Wan et al. (2022) also investigate the impact of logistics performance on the environmental quality in 22 emerging countries for the period between 2007 and 2018, based on the Method of Moments Quantile Regression (MMQR). Their results show that improving logistics performance reduces environmental quality by raising CO₂ emissions.

Besides logistics performance, the effects of various factors such as per capita income, openness to trade, industrialization, foreign direct investment (FDI) and renewable energy consumption on environmental degradation have also been examined in the literature. For example, income per capita is found to increase environmental degradation (Apergis and Ozturk, 2015). Trade openness has also a significant impact on CO₂ emissions (Dogan and Turkekul, 2016; Ozturk and Acaravci 2016). The findings generally suggest that trade openness increases environmental pollution, as it stimulates growth and therefore energy consumption. The industrialization rate is also generally considered to increase CO₂ emissions since the production processes in the manufacturing, construction, electricity, water and gas sectors require intensive energy use (Hong et al., 2015; Sadorsky, 2013). The impact of FDI on environmental degradation is ambiguous, though. Some studies (e.g. Lee, 2009) confirm the validity of ‘pollution haven’ hypothesis, which states that FDI inflows increase pollution in the host countries, while others (e.g. Wang and Chen, 2014) affirm the ‘pollution halo’ hypothesis, which asserts that FDI inflows reduce pollution. Last but not least, renewable energy consumption is also observed to be one of the determinants of environmental degradation (Adams and Acheampong, 2019).

As the above review shows, the literature does not allow for a consensus on the environmental effects of LPI. Such effects vary according to the sub-indexes of LPI, geographical regions, differences in countries' environmental policies and GSCM practices, as well as estimation methods. In this regard, this article attempts to make several contributions to the literature. First, to the best of our knowledge, this is the first study to focus on the MENA region in the context of the nexus between logistics performance and environmental degradation. Moreover, as a proxy for environmental degradation, we use not only CO₂ emissions, but also "ecological footprint" (EF), which involves the ecological assets to be generated, the natural resources to be utilized and the wastes to be absorbed (Balogh, 2019). Our study also provides region-specific policy recommendations to pave the way for sustainable economic development in the MENA countries.

3. Data and Descriptive Statistics

Our sample comprises an unbalanced panel of 20 MENA countries (Algeria, Bahrain, Egypt, Iran, Iraq, Israel, Jordan, Kuwait, Lebanon, Libya, Morocco, Oman, Qatar, Saudi Arabia, Sudan, Syria, Tunisia, Turkey, United Arab Emirates and Yemen) for the period 2007-2018. Due to heterogeneity in their natural resource endowments, we divide countries into two groups, oil-rich countries (Algeria, Bahrain, Iran, Iraq, Kuwait, Libya, Oman, Qatar, Saudi Arabia and United Arab Emirates) and non-oil-rich countries (Egypt, Israel, Jordan, Lebanon, Morocco, Sudan, Syria, Tunisia, Turkey, Yemen).

Definitions and data sources for all variables are given in Table 1. CO₂ emissions and EF are used as proxies for environmental degradation. CO₂ emissions have traditionally been used as the most common proxy variable to reflect environmental degradation. The data for CO₂ emissions are presented in terms of metric per capita and taken from the WDI by World Bank (2022b). However, since CO₂ emissions account for only a certain portion of environmental degradation, we also employ EF as a broader and more reliable indicator of environmental degradation. The EF is measured by "Global Footprint Network (GFN)", and it indicates the "extent of biologically productive land and water required to meet all the competing demands and to absorb the waste it generates". These land and water areas are defined by GFN as follows: cropland, grazing land, forest land showing forest products and CO₂ sequestration, fishing ground and built-up land. The EF data are obtained from GFN (2022).

Table 1. Variable Definitions and Data Sources

Variable	Definition	Data Source
<i>CO2</i>	Carbon dioxide emission per capita (metric tons per capita)	World Bank's World Development Indicators (WDI)
<i>EF</i>	Ecological footprint per capita (in global hectares, gha)	Global Footprint Network (GFN)
<i>LPI</i>	Overall logistics performance index	World Bank's LPI database
<i>LPIC</i>	Logistics performance index measuring the effectiveness of the customs clearance process. This sub-index evaluates the efficiency and effectiveness of customs procedures regarding their rapidity, ease, and predictability.	World Bank's LPI database
<i>LPIIN</i>	Logistics performance index measuring the quality of infrastructure associated with trade and transportation. This sub-index measures the quality of transportation infrastructure.	World Bank's LPI database
<i>LPIIS</i>	Logistics performance index measuring the simplicity of organizing cost-effective shipping. This sub-index assesses how simple it is for the country to organize its international shipping at a reasonable cost	World Bank's LPI database
<i>LPIQC</i>	Logistics performance index measuring the quality and competence of logistics services. This sub-index assesses the quality and competence of local logistics activities.	World Bank's LPI database
<i>LPITT</i>	Logistics performance index measuring the ability to track and trace shipments. This sub-index measures the tracking and tracing of international shipments.	World Bank's LPI database
<i>LPIT</i>	Logistics performance index measuring how often deliveries arrive at their destination in a timely manner. This sub-index assesses deliveries to be on time	World Bank's LPI database
<i>GDP_{pc}</i>	Gross domestic product per capita at constant prices (constant 2015 US\$)	World Bank's World Development Indicators (WDI)
<i>livas</i>	Industrialization: Industry value added as a share of GDP	World Bank's World Development Indicators (WDI)
<i>tros</i>	Trade openness: Sum of exports and imports as a share of GDP	World Bank's World Development Indicators (WDI)
<i>fdis</i>	Foreign direct investment (FDI): FDI inflows as a share of GDP	World Bank's World Development Indicators (WDI)
<i>recs</i>	Renewable energy: Renewable energy consumption as a share of total final energy consumption	World Bank's World Development Indicators (WDI)

We employ overall LPI and its sub-indices as indicators of logistics performance. LPI database was developed by The World Bank and contains information on more than 170 countries for the period 2007-2018 (World Bank, 2022a; Arvis et al., 2016). The LPI score measures a country's logistics performance and is created by analyzing six fundamental indicators through the use of principal component analysis. (1) “the efficiency of customs and border management clearance” (“Customs”); (2) “the quality of trade and transport infrastructure” (“Infrastructure”); (3) “the ease of arranging

competitively priced shipments” (“International shipments”); (4) “the competence and quality of logistics services” (“Services quality and competence”); (5) “the ability to track and trace consignments” (“Tracking and tracing”); and (6) “the frequency with which shipments reach consignees within scheduled or expected delivery times” (“Timeliness”). These indicators were developed through empirical research and extensive consultations with international freight transport experts. The overall LPI is aggregated as a weighted average of these six core indicators. The LPI scores range from 1 to 5, a score of 5 representing the best logistics performance (World Bank, 2022a; Arvis et al., 2016).

In addition to LPI, the variables that may affect environmental degradation are income (measured by GDP per capita), trade openness (measured by trade as percentage of GDP), the industrialization rate (measured by industry value added as percentage of GDP), FDI (measured by FDI inflows as percentage of GDP), renewable energy (measured by renewable energy consumption as percentage of total energy consumption). Data for all these variables are gathered from the World Development Indicators (WDI) database published by the World Bank (World Bank, 2022b).

Trends of CO₂ emissions, EF and LPI values over the 2007-2018 period are presented in Figure A1-A6 in appendix for each oil-rich and non-oil-rich country in the MENA region. Table 2 shows descriptive statistics for the variables in Table 1.

Table 2. Descriptive Statistics

	<u>All sample</u>			<u>Oil-rich</u>			<u>Non-oil-rich</u>		
	Mean	Median	Std.	Mean	Median	Std.	Mean	Median	Std.
<i>CO₂</i>	9.273	4.203	9.361	15.602	16.338	9.495	2.945	2.531	2.251
<i>EF</i>	4.363	3.154	3.499	6.385	5.787	3.839	2.340	1.933	1.264
<i>LPI</i>	2.836	2.839	0.454	2.923	2.985	0.481	2.754	2.727	0.412
<i>LPIC</i>	2.580	2.544	0.490	2.687	2.710	0.527	2.478	2.406	0.431
<i>LPIIN</i>	2.732	2.714	0.554	2.863	2.968	0.590	2.608	2.589	0.488
<i>LPIIS</i>	2.813	2.827	0.428	2.880	2.859	0.451	2.748	2.816	0.396
<i>LPIQC</i>	2.769	2.736	0.486	2.841	2.849	0.489	2.700	2.589	0.475
<i>LPITT</i>	2.821	2.806	0.511	2.898	3.016	0.563	2.747	2.675	0.446
<i>LPIT</i>	3.296	3.280	0.465	3.365	3.398	0.487	3.230	3.218	0.435
<i>GDPpc</i>	14509.4	6164.2	15835.6	21761.2	19907.5	17524.7	7257.6	3759.5	9511.1
<i>livas</i>	39.262	36.367	16.828	52.469	52.135	12.936	26.826	26.121	8.544
<i>tros</i>	80.797	77.372	35.957	94.338	90.521	37.174	66.909	64.386	28.784
<i>fdis</i>	2.521	1.929	2.976	1.700	1.107	2.537	3.393	2.783	3.164
<i>recs</i>	6.471	1.405	13.734	0.522	0.090	0.847	12.420	5.800	17.514
Obs.	240			120			120		
Countries	20			10			10		

According to Table 2, the mean of CO₂ emissions, in terms of metric tons per capita, is 9.27 for the whole sample, 15.60 for the oil-rich countries and 2.94 for the non-oil-rich countries. It is obvious that CO₂ emissions are significantly greater and subject to more pronounced fluctuations in oil-rich MENA countries as compared to non-oil-rich ones. The same pattern applies, though less prominently, to the ecological footprint (EF). On the other hand, the mean of LPI is 2.83 for the whole sample, 2.92 for oil-rich countries and 2.75 for non-oil-rich countries. The volatility of LPI is only slightly higher in oil-rich MENA countries as compared to non-oil-rich ones. Considering LPI sub-indices, the highest mean value among all sub-indices belongs to LPIT (how often deliveries arrive at their destination in a timely manner) (3.29) while the lowest mean value belongs to LPIC (the efficiency of the customs clearance process) (2.580). Also, the mean values of the LPI sub-indices are slightly higher and slightly more volatile in oil-rich countries than in non-oil-rich countries. The mean value of GDP per capita (GDPpc) for the whole sample is \$14509.4. The difference between oil-rich and non-oil-rich countries is all the more pronounced in terms of this variable. That is, the mean and volatility of GDP per capita for oil-rich MENA countries are much higher than for non-oil-rich countries. The mean value of the industrialization ratio (livas) is 39.26 percent for the whole sample, 52.46 percent for oil-rich countries and 26.82 percent for non-oil-rich countries. The mean value of trade openness (tros) for the whole sample is 80.79 percent. The trade openness of oil-rich countries (94.33 percent) is also considerably higher than non-oil-rich countries (66.90 percent). The mean value of FDI inflows is 2.52 for the whole sample. Moreover, non-oil-rich countries have a higher average FDI and greater volatility than oil-rich countries. Similarly, the average renewable energy consumption (reccs) and its volatility are substantially much higher in non-oil-rich MENA countries.

4. Empirical Methodology and Estimation Results

In order to analyze the impacts of logistics performance on environmental degradation, we consider the following benchmark equation:

$$\ln(ED)_{it} = \alpha_0 + \alpha_1 \ln(LPIX)_{it} + \alpha_2 \ln(GDPpc)_{it} + \alpha_3 (livas)_{it} + \alpha_4 (tros)_{it} + \alpha_5 (fdis)_{it} + \alpha_6 (reccs)_{it} + \eta_i + \varphi_t + u_{it} \quad (1)$$

where the subscripts i and t denote countries and years, respectively. ED refers to environmental degradation which is proxied by CO₂ emissions ($CO2$) and ecological footprint (EF), alternatively. The key explanatory variable is logistics performance ($LPIX$). First, we use the overall logistics performance index (LPI) for this variable. We also extend the regression by employing the sub-indices of LPI ($LPIC$, $LPIIN$, $LPIIS$, $LPIQC$, $LPITT$, $LPIT$) to analyze the effects of different dimensions of logistics

performance. We use each sub-index in a separate regression in order to avoid multicollinearity. We add GDP per capita ($GDPpc$), industrialization ($livas$), trade openness ($tros$), foreign direct investment ($fdis$), and renewable energy ($recs$) into the estimation equation as control variables. The variables η_i and φ_t denote time-invariant country-specific effects and time-specific effects, respectively. The last term u_{it} is an idiosyncratic error term.

Equation (1) is estimated by using the fixed effects (FE) model. We adopt Hoechle (2007) approach that produces Driscoll-Kraay standard errors for panel models as those are robust to serial correlation, heteroskedasticity and cross-sectional dependence. Moreover, Driscoll-Kraay standard errors exhibit notably superior characteristics in small samples when compared to commonly used alternative methods for estimating standard errors, particularly in the presence of cross-sectional dependence, as in our case¹.

Additionally, we examine the multicollinearity and endogeneity problems of our regressions, as well as robustness checks with respect to sub-samples and alternative measures of both environmental degradation and logistics performance that we discussed above. First of all, we identify the potential presence of multicollinearity by calculating the variance inflation factor (VIF) for each set of estimations in this work. As a rule of thumb, a VIF larger than ten may be indicative of serious multicollinearity. The computed mean VIF values of the models vary from 1.87 to 2.16 for the whole sample, 2.73 to 3.95 for oil-rich sample, and 2.24 to 2.75 for non-oil-rich sample. These relatively lower VIF values suggest that there is no substantial empirical indication of significant multicollinearity within any set of estimations in the study. In contrast, we acknowledge that logistics performance might be endogenous. To address potential endogeneity issues, we use two alternative estimators. First, we apply FE-IV using lagged values of LPI as its instruments. Second, we conduct a dynamic panel data estimation using GMM specification where one-year lagged dependent variable and LPI are endogenous. The results of alternative estimations are closely similar to the primary findings in our study (see Table A1 in appendix). On the other hand, as another robustness check, after converting the data to 2-year periods by taking a two-year average for each variable, we conduct all FE estimates with these 2-year average data. Our results are very similar to our main results. (see Table A2 in the appendix for overall LPI and Table A3 for LPI-sub-indices)

Table 3 presents the results for the FE panel regressions for Equation (1). Alternative dependent variables are CO₂ emissions and EF, and the main independent variable is the overall LPI. The results are presented separately for the whole sample, oil-rich MENA countries and non-oil-rich ones.

¹ We rejected the null hypothesis of cross-sectional independence for all models by using the Pesaran test. Note that the p-values of Pesaran's cross sectional independence test statistics for our main models are 0.069 (0.078) in whole sample, 0.026 (0.036) in oil-rich sample, and 0.037 (0.027) in non-oil-rich sample for CO₂ (EF) models.

Table 3. Fixed Effect Estimation Results, overall LPI

	<u>All sample</u>		<u>Oil-rich</u>		<u>Non-oil-rich</u>	
	<u>ln (CO₂)</u>	<u>ln (EF)</u>	<u>ln (CO₂)</u>	<u>ln (EF)</u>	<u>ln (CO₂)</u>	<u>ln (EF)</u>
ln (<i>LPI</i>)	0.124** (0.054)	0.437*** (0.056)	0.405*** (0.065)	1.119*** (0.159)	-0.013 (0.071)	0.089 (0.139)
ln (<i>GDPpc</i>)	0.464*** (0.027)	0.503*** (0.067)	0.506*** (0.051)	0.331* (0.165)	0.518*** (0.129)	0.631*** (0.134)
<i>livas</i>	-0.309** (0.104)	-0.346** (0.128)	-0.293*** (0.071)	-0.229 (0.242)	-0.146 (0.300)	0.286 (0.413)
<i>tros</i>	0.061** (0.020)	-0.229*** (0.042)	-0.056* (0.029)	-0.275*** (0.081)	0.087 (0.122)	-0.194 (0.161)
<i>fdis</i>	-0.367*** (0.115)	-0.080 (0.403)	0.290** (0.124)	-0.422 (0.595)	-1.225** (0.487)	0.152 (0.251)
<i>recls</i>	-1.401** (0.631)	-1.097*** (0.347)	-6.241 (3.877)	-4.697 (7.489)	-1.820* (0.831)	-0.705 (0.458)
Observations	217	217	107	107	110	110
Countries	20	20	10	10	10	10
R-squared	0.468	0.468	0.686	0.520	0.492	0.619
F-stat. (Overall)	9.32 [0.000]	9.30 [0.000]	10.27 [0.000]	5.10 [0.000]	4.73 [0.000]	7.94 [0.000]
F-stat. (Country FE)	478.64 [0.000]	78.64 [0.000]	229.78 [0.000]	32.21 [0.000]	262.22 [0.000]	52.95 [0.000]

Note: All models include a constant, country fixed effects and year dummies. Driscoll-Kraay standard errors in parentheses *** p<0.01, ** p<0.05, * p<0.1. p-values for the F-statistics are in brackets.

The first point to note in Table 3 is that there is a significantly positive effect of overall LPI on environmental degradation for the whole sample and oil-rich countries, while this relationship is statistically insignificant for non-oil-rich countries. In other words, improvements in LPI raise environmental degradation in the whole sample and oil-rich countries, but they neither increase nor decrease environmental degradation in the non-oil-rich ones. A one-percent increase in the overall LPI results in a 0.12-percent increase in CO₂ emissions in the whole sample and a 0.40-percent increase in oil-rich countries. Our results, in this regard, are consistent with the findings of Wan et al. (2022), Magazzino et al. (2021) and Kim and Min (2011).

Considering the ecological footprint (EF), Table 3 shows that a one-percent increase in overall LPI increases the EF for the whole sample and oil-rich countries by 0.43 percent and 1.11 percent, respectively. For non-oil-rich countries, the LPI has no significant impact on the EF, similar to CO₂ emissions. One notable point in Table 3 is that the impact of overall LPI on EF is remarkably stronger than CO₂ emissions. When evaluating the impact of the LPI on CO₂ emissions at a local level, the focus is primarily on the direct emissions associated with transportation activities within a specific region or country. The EF provides a broader perspective by considering the overall

environmental impact of various human activities, including logistics, on a global scale. It takes into account not only CO₂ emissions but also other factors such as land use, water consumption, resource depletion and waste generation. Indeed, the EF measures “the amount of biologically productive land and water” required to sustainably support the consumption and waste absorption of a population.

All in all, our results in Table-3 show that an increase in LPI leads to environmental degradation in the form of more CO₂ emissions and a higher EF in the MENA region, especially in oil-rich countries. A higher LPI score indicates a more efficient logistics system. However, the results show that a more efficient logistics system does not maintain a better environmental quality for MENA. This shows us that a kind of Jevons Paradox tends to apply to MENA. Oil-producing MENA countries, for example, may have more efficient customs clearance procedures, but they may also have a high volume of freight traffic, which might result in increased CO₂ emissions. Similarly, they may have a better quality of infrastructure, but it may also have a large EF due to the intense use of resources to build and maintain that infrastructure.

In oil-rich MENA countries, where CO₂ emissions are closely linked to oil-based industries such as oil extraction, refining, transportation and exports, improved logistics performance can lead to increased trade volumes (Çelebi, 2019) and transportation activities. The majority of this increased activity is based on road transport, which is the largest contributor to carbon emissions, thus may lead to higher fossil fuel consumption and therefore higher carbon emissions and air pollution (Liu et al., 2018). Moreover, if efficiency gains achieved through the LPI lead to increased trade volumes and global supply chain activities, they could potentially contribute to a higher overall ecological footprint compared to CO₂ emissions due to increased resource consumption, emissions, and environmental impacts on a global scale.

On the other hand, efforts to increase the efficiency of logistics operations in non-oil-rich MENA countries, that is, do not have significant oil reserves, do not lead to a decrease in CO₂ emissions. In many non-oil-rich MENA countries, the energy sector may not be heavily dependent on fossil fuels such as oil for power generation or transportation. Instead, they might use alternative energy sources such as natural gas and renewables.² In such cases, improving logistics efficiency, which primarily affects the movement of goods and services, may not directly impact the energy mix or carbon emissions. Therefore, improvements in logistics efficiency may not have a direct impact on the energy sector, which contributes significantly to CO₂ emissions in oil-rich countries. This situation can be considered as an advantage of non-oil-rich MENA countries in terms of sustainable development opportunities.

In the case of other explanatory variables, Table 3 shows that per-capita GDP is positively related to environmental degradation for the whole sample, oil-rich and non-

² For example, according to the report by Australian Climate Council Report (2022), Morocco has utilized its abundant solar resources to become a world leader in solar energy.

oil-rich countries. This finding indicates that an increase in per-capita income increases both CO₂ emissions and EF, and thus increased economic activity degrades the environment. This is consistent with the existing literature (e.g., Grossman and Krueger, 1995). Table 3 also shows that the rate of industrialization has a mitigating effect on environmental degradation for the whole sample and the oil-rich countries. An increase in industrial activity reduces CO₂ emissions and EF in the whole sample and reduces CO₂ emissions in oil-rich countries. While our result is consistent with the findings for East Asia and Middle East by Liu et al. (2018), it contradicts the expected result that industrial activity increases carbon emissions. However, this result can be explained by the relatively lower degree of industrialization in MENA region

Trade openness increases CO₂ emissions and reduces the EF in the whole sample. Zaman and Shamsuddin (2017) find a positive relationship between trade openness and CO₂ emissions in European countries. Liu et al. (2018) find this effect to be insignificant for Middle Eastern countries, but their results for Asia and East Asia are similar to our results. In oil-rich countries, trade openness reduces both CO₂ emissions and EF, indicating that trade liberalization policies of oil-rich MENA countries might have been designed to control environmental degradation.

FDI inflows have a significant impact only on CO₂ emissions. Moreover, this impact is positive for oil-rich countries and negative for non-oil-rich countries and the whole sample. These results suggest that the “pollution haven hypothesis” is valid in oil-rich MENA countries, while the “pollution halo hypothesis” applies to non-oil-rich ones. The results of Zaman and Shamsuddin (2017) for European countries are consistent with what we find for non-oil-rich countries. However, Taşdemir and Ekmen-Özçelik (2023) suggest a non-linear relationship between FDI inflows and environmental degradation for the MENA region. They conclude that this relationship is not invariant to country characteristics such as institutional quality and human capital level.

Finally, according to our results, an increase in renewable energy consumption reduces CO₂ emissions and EF in the whole sample, while reducing only CO₂ emissions in non-oil-rich countries, and its impact is insignificant for oil-rich MENA countries.

Next, we analyze the impact of sub-LPI indices on environmental degradation. Table 4 below presents the estimations results of Equation (1) for each sub-LPI index.

Table 4. Fixed Effect Estimation Results: Coefficient estimates of sub-indices

	<u>All sample</u>		<u>Oil-rich</u>		<u>Non-oil-rich</u>	
	<u>ln (CO2)</u>	<u>ln (EF)</u>	<u>ln (CO2)</u>	<u>ln (EF)</u>	<u>ln (CO2)</u>	<u>ln (EF)</u>
ln (LPIC)	-0.005 (0.034)	0.094 (0.063)	0.174*** (0.026)	0.313** (0.107)	-0.159** (0.059)	-0.084 (0.099)
R-squared	0.461	0.411	0.660	0.370	0.514	0.622
ln (LPIIN)	0.129** (0.055)	0.247*** (0.044)	0.346*** (0.058)	0.635*** (0.114)	0.025 (0.068)	0.008 (0.110)
R-squared	0.474	0.438	0.698	0.428	0.493	0.616
ln (LPIIS)	0.152** (0.055)	0.336*** (0.040)	0.135* (0.070)	0.614*** (0.070)	0.174*** (0.055)	0.087 (0.069)
R-squared	0.483	0.478	0.646	0.506	0.510	0.621
ln (LPIQC)	0.066 (0.046)	0.318*** (0.058)	0.244*** (0.045)	0.566*** (0.143)	-0.007 (0.058)	0.131 (0.082)
R-squared	0.464	0.457	0.669	0.424	0.492	0.627
ln (LPITT)	0.123** (0.040)	0.347*** (0.051)	0.196*** (0.040)	0.502*** (0.069)	0.016 (0.077)	0.163 (0.106)
R-squared	0.477	0.493	0.678	0.472	0.492	0.634
ln (LPIT)	-0.063 (0.074)	0.144** (0.062)	-0.083 (0.084)	0.062 (0.123)	-0.048 (0.070)	0.086 (0.124)
R-squared	0.463	0.412	0.630	0.323	0.493	0.619
Control variables	YES	YES	YES	YES	YES	YES
Country FE	YES	YES	YES	YES	YES	YES
Year dummies	YES	YES	YES	YES	YES	YES

Note: All models include a constant, country fixed effects, year dummies, and control variables (*GDPpc*, *livas*, *tros*, *fdis*, *recs*) but the results are not reported to save space. Driscoll-Kraay standard errors in parentheses *** p<0.01, ** p<0.05, * p<0.1.

According to Table 4, LPIC has a significantly positive impact on CO₂ emissions in oil-rich countries. More specifically, a 1-percent improvement in the efficiency of the customs clearance process leads to 0.17-percent increase in CO₂ emissions in oil-rich MENA countries. This result is consistent with what Liu et al. (2018) found for South Asia, but he found this effect insignificant for the rest of Asia, including the Middle East. When customs clearance is more efficient, goods and products can cross borders and ports more easily and faster. Easier and faster customs clearance can increase trade volumes by reducing business delays and transaction costs. This can result in an upsurge in oil exports of oil-rich MENA countries. However, since oil is predominantly transported by fossil-fuel-powered modes of transportation such as ships, trucks and planes, increased trade may result in higher CO₂ emissions. Efficient customs processes could also motivate oil companies to boost their oil production and exports more

frequently. However, this could lead to a rise in the use of fossil fuels, which release CO₂ when burned for energy. On the other hand, as the table shows, an increase in LPIC decreases CO₂ emissions in non-oil countries. Moreover, LPIC is the only LPI sub-index that has a reducing effect on CO₂ emissions.

LPIIN increases environmental degradation both in the whole sample and oil-rich countries. That is, better quality of logistics infrastructure leads to environmental degradation, especially in oil-rich countries. A higher quality logistics infrastructure implies that the oil-rich MENA countries have the capacity to handle more efficient, reliable and larger volumes of goods, including oil and its derivatives, with less delays and interruptions. Thus, shipping of petroleum products will likely contribute to higher CO₂ emissions. This finding may also indicate that environmental standards are neglected while improving logistics infrastructure in oil-rich countries.

LPIIS has a positive impact on both CO₂ emissions and EF. In other words, as the ease of arranging competitively priced shipments increases, both CO₂ emissions and EF increase. This result contradicts the result of Liu et. al. (2018) for Asian, Middle Eastern and East Asian countries, but it is consistent with the findings of Zaman and Shamsuddin (2017). For the MENA region, making shipments more accessible and cost-effective can lead to greater trading volumes, as with other sub-indices of LPI. This, in turn, will contribute to higher transport activities that will lead to higher CO₂ emissions from fossil fuel-powered vehicles.

LPIQC is also positively related to environmental degradation in oil-rich countries. That is, competence and quality of logistics services increase environmental degradation in terms of both CO₂ emissions and EF in oil-rich countries. Zaman and Shamsuddin (2017) also find a positive relationship between LPIQC and CO₂ emissions in European countries. When the efficiency and effectiveness of transportation, storage and distribution of goods within the country's borders are enhanced, domestic trade and transportation of goods may improve as well. Increasing transportation activities is likely to result in more extensive use of fossil fuel-powered cars in oil-rich MENA countries, raising CO₂ emissions.

Similarly, we find a positive effect of LPIIT on environmental degradation for the whole sample and oil-rich countries. This result suggests that an increase in the ability to track and trace consignments can lead to environmental degradation. The result is consistent with what Liu et al. (2018) found for East Asia but contradicts what they found for the Middle East. Logistic activities can be more efficient when shipments are more traceable and visible. This enables firms to detect possible supply chain delays or disturbances and take regularity measures. These actions can lead to faster transport and delivery of goods, resulting in increased fuel consumption and higher CO₂ emissions in the transportation process.

Finally, Table 4 shows that LPIT, which measures the frequency with which shipments reach the recipient within the planned or expected time, is insignificant for

oil-rich and non-oil-rich countries, while positively related to the EF of the entire sample. This is consistent with Liu et al. (2018) for Asian and East Asian countries. As the timeliness of freight transport improves, the EF in MENA also increases, as it affects various environmental aspects beyond carbon emissions. On the other hand, the timeliness of freight transportation reflects the reliability and predictability of the supply chain and is critical for companies in the global value chains (Arvis et al., 2016). Therefore, policymakers should consider this trade-off between the timeliness of freight transport and emissions so as to develop methods to resolve it.

The improvements in LPI and its sub-indices point to a more efficient logistics system. However, the findings in Table-4 indicate generally that an efficient logistics system also generates environmental degradation for MENA. Countries with an efficient logistics structure and hence low logistics costs also have a competitive advantage in the international markets (Aigner, 1998). More efficient logistics systems facilitate international trade, ensure product safety and product mobility, and reduce delivery time and increase delivery speed (La and Song, 2019). Such improvements can augment environmental degradation by increasing transportation activities, which can cause higher energy consumption and carbon emissions, as well as longer supply chains and shifts to higher emission modes of transport. Therefore, it is necessary to deploy preventive policies to eliminate or mitigate such side-effects.

5. Conclusion and Policy Implications

Our results suggest that improvements in logistics performance heighten environmental degradation rather than contribute to environmental sustainability, particularly in oil-rich MENA countries. In other words, a more efficient logistics system does not provide better environmental quality. Indeed, better logistics tends to generate environmentally worse outcomes. This general finding hints at the validity of Jevons Paradox in the case of oil-rich countries of MENA, while others tend to escape this paradox through what may be called the advantage of being a non-oil-rich country in terms of sustainable economic development.

Some reasonable explanations for this result are due. Improvements in logistics performance can increase transportation activities, which, in turn, raise fossil fuel consumption and lead to higher CO₂ emissions. For example, oil-producing MENA countries tend to have more efficient customs clearance procedures, but at the same time they have higher volumes of freight traffic, which can also result in increased CO₂ emissions. Similarly, they may have a higher quality infrastructure but also a larger EF due to the more intensive use of resources to build up and maintain that infrastructure. In addition, improved logistics performance can lead to increased trade volumes and shipping activities, resulting in higher fossil-fuel consumption and hence higher carbon emissions and air pollution, especially in oil-rich MENA countries. Moreover, if the

efficiency gains achieved through the LPI lead to increased trade volumes and global supply chain activities, they can potentially generate a higher overall EF, as compared to CO₂ emissions, due to increased resource consumption, larger emissions and more detrimental environmental impacts on a global scale.

On the other hand, in non-oil-rich MENA countries, endeavors aimed at improving the efficiency of logistics operations do not result in a reduction in CO₂ emissions. In those countries, enhancing the efficiency of logistics, which primarily influences the transportation of goods and services, may not directly influence the energy sources used or carbon emissions. This situation can be viewed as a benefit for MENA nations without significant oil reserves when it comes to opportunities for sustainable development.

All in all, it can be argued that logistics performance in the MENA region, and especially in oil-rich countries, has not progressed through an environmentally friendly path. This undesirable outcome seems to point out the neglect of environmental concerns along the supply chain process. To mitigate the negative impacts associated with the logistics-version of the Jevons Paradox, it is crucial to reconcile efficiency gains with sustainability measures throughout the supply chains. Around the discussions about logistics activities and the environment, the issue of green and sustainable logistics development has recently come to the fore. In this regard, environmentally friendly methods can be used in the processes of handling materials, processing information, storing the inventory and also implementing waste management (Li et al., 2021). Incentive-oriented policies such as subsidies and tax reductions can be applied to companies that use biofuels and renewable energy sources in their logistics processes (Li, 2014). Environmentally friendly modes of transportation can also be encouraged and policies to increase vehicle efficiency can be implemented (Abbasi and Nilsson, 2016; Rodt et al., 2010). The importance of technological developments to achieve environmental sustainability goals is particularly emphasized (Winkler and Mocanu, 2020). Environmentally sustainable production strategies can be developed by taking measures for optimizing the consumption of energy and resources required for the production of environmentally friendly goods and services (Yaprak and Doğan, 2019). By integrating such green practices, it is possible to reduce both the environmental impact per unit of transported goods and the overall volume of environmental resources being consumed.

In the face of environmental challenges, some MENA countries are already making efforts to improve the sustainability of their logistics operations (e.g. Dubai Green Mobility Initiative-2030, investments in sustainable transportation systems in Qatar, promotion of renewable energy sources by Saudi Arabia, Egypt's development of logistics infrastructure on important shipping routes such as the Suez Canal in line with green sustainability, adoption of more efficient and sustainable practices by Tunisia). Indeed, there are many opportunities to improve the environmental sustainability of

logistics operations through green practices, such as adoption of new technologies, better planning and coordination, the use of alternative fuels, etc. By addressing these challenges and opportunities, MENA countries can promote economic growth and development while protecting the environment effectively for future generations.

Finally, our results also suggest that more accurate alternative measures are needed to evaluate MENA's green logistics performance, as higher LPI does not reflect better green logistics performance for MENA countries. Future research can aim to develop a new and MENA-specific performance metric that simultaneously considers environmental sustainability and logistics efficiency.

References

- Abbasi, M., & Nilsson, F. (2016). Developing environmentally sustainable logistics: Exploring themes and challenges from a logistics service providers' perspective. *Transportation Research Part D: Transport and Environment*, 46, 273-283.
- Adams, S., & Acheampong, A. O. (2019). Reducing carbon emissions: the role of renewable energy and democracy. *Journal of Cleaner Production*, 240, 118245.
- Aigner, K. (1998). A framework for evaluating the dynamic competitiveness of countries. *Structural change and economic dynamics*, 92, 159-188.
- Alam, M.M. & Lee, Y. (2021). Cleaner Vehicles and Charging Infrastructure : Greening Passenger Fleets for Sustainable Mobility. Transport Decarbonization Investment Series, World Bank, Washington, DC.
- Apergis, N., & Ozturk, I. (2015). Testing environmental Kuznets curve hypothesis in Asian countries. *Ecological Indicators*, 52, 16-22.
- Arvis, J.F., Saslavsky, D., Ojala, L., Shepherd, B., Busch, C., Raj, A. (2016). Trade Logistics in the Global Economy-The Logistics Performance Index and Its Indicators, World Bank, Washington, DC.
- Balogh, J. M. (2019). Agriculture-specific determinants of carbon footprint. *Studies in Agricultural Economics*, 121(3), 166-170.
- Barth, M., & Boriboonsomsin, K. (2009). Energy and emissions impacts of a freeway-based dynamic eco-driving system. *Transportation Research Part D: Transport and Environment*, 14(6), 400-410.
- Climate Counsil Report (2022). Australia, available at "<https://www.climatecouncil.org.au/11-countries-leading-the-charge-on-renewable-energy/>"
- Carter, C.R. & Liane Easton, P. (2011). Sustainable supply chain management: evolution and future directions. *International Journal of Physical Distribution & Logistics Management*, 41(1), 46-62.
- Ceddia, M. G. (2019). The impact of income, land, and wealth inequality on agricultural expansion in Latin America. *Proceedings of the National Academy of Sciences*, 1167, 2527-2532.
- Coto-Millán, P., Agüeros, M., Casares-Hontañón, P., & Pesquera, M. Á. (2013). Impact of logistics performance on world economic growth 2007–2012. *World Review of Intermodal Transportation Research*, 44, 300-310.
- Çelebi, D. (2019). The role of logistics performance in promoting trade. *Maritime Economics & Logistics*, 213, 307-323.
- D'Aleo, V. & Sergi, B. S. (2017a). Does Logistics Influence Economic Growth? The European Experience. *Management Decision*, 558, 1613-1628.

- Dogan, E. & Turkekul, B. (2016). CO₂ emissions, real output, energy consumption, trade, urbanization and financial development: testing the EKC hypothesis for the USA. *Environmental Science and Pollution Research*, 23, 1203–1213.
- Gani, A. (2017). The logistics performance effect in international trade. *The Asian Journal of Shipping and Logistics*, 33(4), 279–288.
- Global Footprint Network (GFN), 2022. National Footprint Accounts, 2022 Edition
- Grossman G.M. & Krueger A. B. (1995). Economic growth and the environment. *The Quarterly Journal of Economics*, 110 (2), 353-377.
- Hausman, W. H., Lee, H. L., & Subramanian, U. (2013). The impact of logistics performance on trade. *Production and Operations Management*, 222, 236-252.
- Hoechle, D. (2007). Robust standard errors for panel regressions with cross-sectional dependence. *The Stata Journal*, 73, 281-312.
- Hong, J., Shen, G. Q., Feng, Y., Lau, W. S. T., & Mao, C. (2015). Greenhouse gas emissions during the construction phase of a building: A case study in China. *Journal of Cleaner Production*, 103, 249-259.
- International Energy Agency (IEA). (2019). CO₂ emissions from fuel combustion, IEA Data and statistics.
- Jevons, W.S. (1906). *The Coal Questions, an Inquiry Concerning the Progress of the Nation, and the Probable Exhaustion of our Coal-mines*", Macmillan Press, Third Edition.
- Karaduman, H. A., Karaman-Akgül, A., Çağlar, M., & Akbaş, H. E. (2020). The relationship between logistics performance and carbon emissions: an empirical investigation on Balkan countries. *International Journal of Climate Change Strategies and Management*, 12(4), 449-461.
- Khan, S. A. R. (2019). The nexus between carbon emissions, poverty, economic growth, and logistics operations-empirical evidence from Southeast Asian countries. *Environmental Science and Pollution Research*, 2613, 13210-13220.
- Khan, S. A. R., Jian, C., Zhang, Y., Golpîra, H., Kumar, A., & Sharif, A. (2019). Environmental, social and economic growth indicators spur logistics performance: From the perspective of South Asian Association for Region Cooperation countries. *Journal of Cleaner Production*, 214, 1011–1023.
- Khan, S. A. R., Zhang, Y., Anees, M., Golpîra, H., Lahmar, A., & Qianli, D. (2018). Green supply chain management, economic growth and environment: A GMM based evidence. *Journal of Cleaner Production*, 185, 588-599.
- Khan, S. A. R., Qianli, D., SongBo, W., Zaman, K., & Zhang, Y. (2017). Environmental logistics performance indicators affecting per capita income and sectoral growth: evidence from a panel of selected global ranked logistics countries. *Environmental Science and Pollution Research*, 242, 1518-1531.
- Kim, I. & Min, H. (2011). Measuring supply chain efficiency from a green perspective. *Management Research Review*, 3411, 1169-1189.

- La, K. W. & Song, J. G. (2019). An Empirical Study on the Effects of Export Promotion on Korea-China-Japan Using Logistics Performance Index (LPI). *Journal of Korea Trade*, 23(7), 96–112.
- Larina, I. V., Larin, A. N., Kiriliuk, O., & Ingaldi, M. (2021). Green logistics-modern transportation process technology. *Production Engineering Archives*, 27(3), 184-190.
- Larson, P. D. (2021). Relationships between logistics performance and aspects of sustainability: A cross-country analysis. *Sustainability*, 13(2), 623.
- Lee, C. G. (2009). Foreign direct investment, pollution and economic growth: evidence from Malaysia. *Applied Economics*, 41(13), 1709-1716.
- Li, X., Sohail, S., Majeed, M. T., & Ahmad, W. (2021). Green logistics, economic growth, and environmental quality: evidence from one belt and road initiative economies. *Environmental Science and Pollution Research*, 28, 30664-30674.
- Li, Y. (2014). Environmental innovation practices and performance: moderating effect of resource commitment, *Journal of Cleaner Production*, 66, 450-458.
- Liu, J., Yuan, C., Hafeez, M., & Yuan, Q. (2018). The relationship between environment and logistics performance: Evidence from Asian countries, *Journal of Cleaner Production*, 204, 282-291.
- Lu, M., Xie, R., Chen, P., Zou, Y. & Tang, J. (2019). Green transportation and logistics performance: an improved composite index. *Sustainability*, 11(10), 1-17.
- Magazzino, C., Mele, M., & Schneider, N. (2022). A new artificial neural networks algorithm to analyze the nexus among logistics performance, energy demand, and environmental degradation. *Structural Change and Economic Dynamics*, 60, 315-328.
- Magazzino, C., Alola, A. A., & Schneider, N. (2021). The trilemma of innovation, logistics performance, and environmental quality in 25 top most logistics countries: A quantile regression evidence. *Journal of Cleaner Production*, 322, 129050.
- Mariano, E.B., Gobbo, J.A., Jr, de Castro Camioto, F. & do Nascimento Rebelatto, D.A. (2017). CO₂ emissions and logistics performance: a composite index proposal. *Journal of Cleaner Production*, 163, 166-178.
- Martel, A., Klibi, W. (2016). Supply Chains: Issues and Opportunities. In: *Designing Value-Creating Supply Chain Networks*. Springer International Publishing, 1-43.
- Martí, L., Puertas, R., & García, L. (2014). The importance of the Logistics Performance Index in international trade. *Applied Economics*, 46(24), 2982-2992.
- Min, H., & Kim, I. (2012). Green supply chain research: past, present, and future. *Logistics Research* 4, 39-47.
- Ozturk, I., & Acaravci, A. (2016). Energy consumption, CO₂ emissions, economic growth, and foreign trade relationship in Cyprus and Malta. *Energy Sources, Part B: Economics, Planning, and Policy*, 114, 321-327.

- Rashidi, K., & Cullinane, K. (2019). Evaluating the sustainability of national logistics performance using data envelopment analysis. *Transport Policy*, 74, 35–46.
- Rodt, S., Georgi, B., Huckestein, B., Mönch, L., Herbener, R., Jahn, H., Koppe, K., Lindmaier, J., 2010. CO₂ emissions reduction in the transport sector in Germany. Possible measures and their reduction potential. A status report by the Federal Environment Agency.
- Sadorsky, P. (2013). Do urbanization and industrialization affect energy intensity in developing countries? *Energy Economics*, 37, 52-59.
- Saslavsky, D., & Shepherd, B. (2014). Facilitating international production networks: The role of trade logistics. *The Journal of International Trade & Economic Development*, 23(7), 979-999.
- Sears, L., Caparelli, J., Lee, C., Pan, D., Strandberg, G., Vu, L., & Lin Lawell, C. Y. C. (2018). Jevons' paradox and efficient irrigation technology. *Sustainability*, 10(5), 1590.
- Suki, N. M., Suki, N. M., Sharif, A., & Afshan, S. (2021). The role of logistics performance for sustainable development in top Asian countries: Evidence from advance panel estimations. *Sustainable Development*, 29(4), 595-606.
- Taşdemir, F., & Ekmen-Özçelik, S. (2023). Do human capital and governance thresholds matter for the environmental impact of FDI? The evidence from MENA countries. *Environmental Science and Pollution Research*, 30(14), 41741-41754.
- Trincado, E., Sánchez-Bayón, A., & Vindel, J. M., 2021. The European Union green deal: clean energy wellbeing opportunities and the risk of the Jevons paradox. *Energies* 14(14), 4148.
- Töngür, Ü., Türkcan, K., & Ekmen-Özçelik, S., 2020. Logistics performance and export variety: Evidence from Turkey. *Central Bank Review* 20(3), 143-154.
- United Nations, 2014. Climate Summit -2014: Catalyzing Action. Global Green Freight Action Plan, UN Climate Summit.
- Wan, B., Wan, W., Hanif, N., & Ahmed, Z., 2022. Logistics performance and environmental sustainability: Do green innovation, renewable energy, and economic globalization matter?. *Frontiers in Environmental Science* 10(996341), 1-10.
- Wang, D. T., & Chen, W. Y., 2014. Foreign direct investment, institutional development, and environmental externalities: Evidence from China. *Journal of Environmental Management* 135, 81-90.
- Wild, P., 2021. Recommendations for a future global CO₂-calculation standard for transport and logistics. *Transportation Research Part D: Transport and Environment* 100, 103024.
- Windmark, C., & Andersson, C., 2015. Cost models of inbound logistics activities: supporting production system design. *International Journal of Supply Chain and Operations Resilience* 1(2), 181-200.

- Winkler, C., & Mocanu, T., 2020. Impact of political measures on passenger and freight transport demand in Germany. *Transportation Research Part D: Transport and Environment* 87, 102476.
- World Bank, 2022a. Logistics performance index database. Retrieved from. <https://lpi.worldbank.org>
- World Bank, 2022b. World development indicators (WDI). Retrieved from. <https://data.worldbank.org/data-catalog/world-development-indicators>.
- Yadav, N., 2014. Impact of trade facilitation on parts and components trade. *The International Trade Journal* 28(4), 287-310.
- Yaprak, İ. & Doğan, N. Ö., 2019. Yeşil Tedarik Zinciri Yönetimi: İlgili Literatüre Dayalı Bir Mevcut Durum Analizi. *Uluslararası Yönetim İktisat ve İşletme Dergisi* 15(4), 1143-1165.
- Zaman, K., & Shamsuddin, S., 2017. Green logistics and national scale economic indicators: evidence from a panel of selected European countries. *Journal of Cleaner Production* 143, 51–63.

DISCLOSURE STATEMENTS:

Research and Publication Ethics Statement: This study has been prepared in accordance with the rules of scientific research and publication ethics.

Contribution Rates of the Authors: The first author's 50%, the second author's 50%,

Conflicts of Interest: On behalf of all authors, the corresponding author states that there is no conflict of interest.

Financial research support statement and acknowledgement: We would like to thank Economic Research Forum (ERF) for supporting our participation in the "ERF 29th Annual Conference: The Future of MENA Development Path – Risks and Opportunities in an Emerging World Order" conference, where the first version of this article was presented.

We would like to express our gratitude to Prof. Dr. Matthew Agarwala who has enabled us to evaluate environmental degradation in the context of the Jevons paradox were not used in the research described in the paper.

Appendix

Figure A1. CO₂ emissions, metric tons per capita (Oil-rich countries)

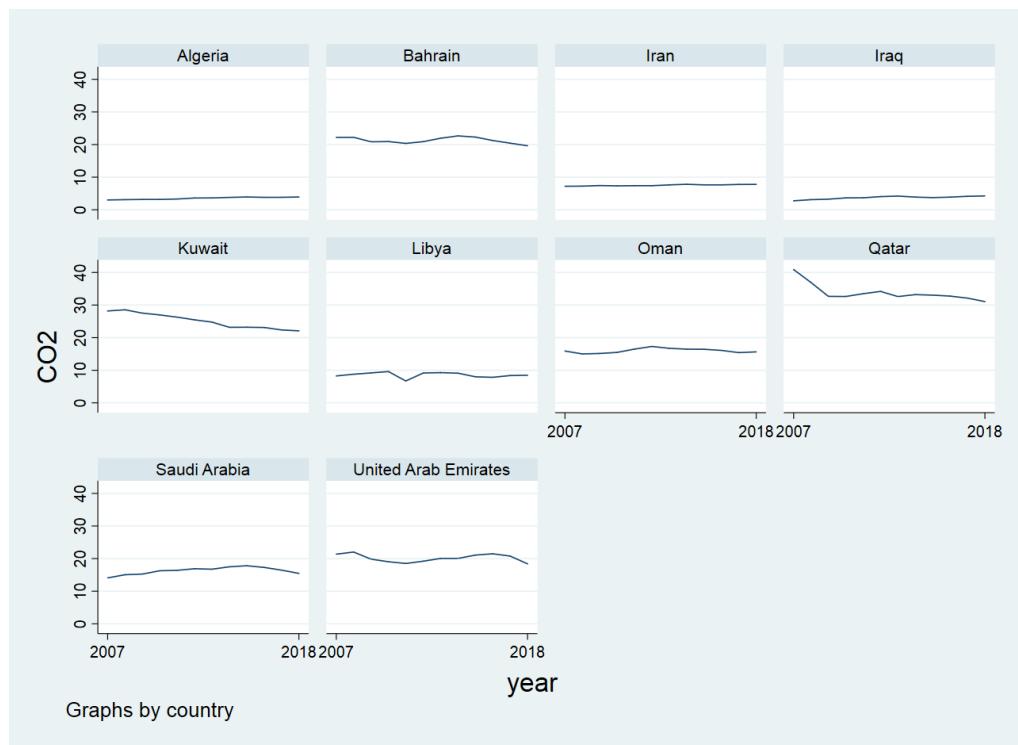


Figure A2. CO₂ emissions, metric tons per capita (Non-oil-rich countries)

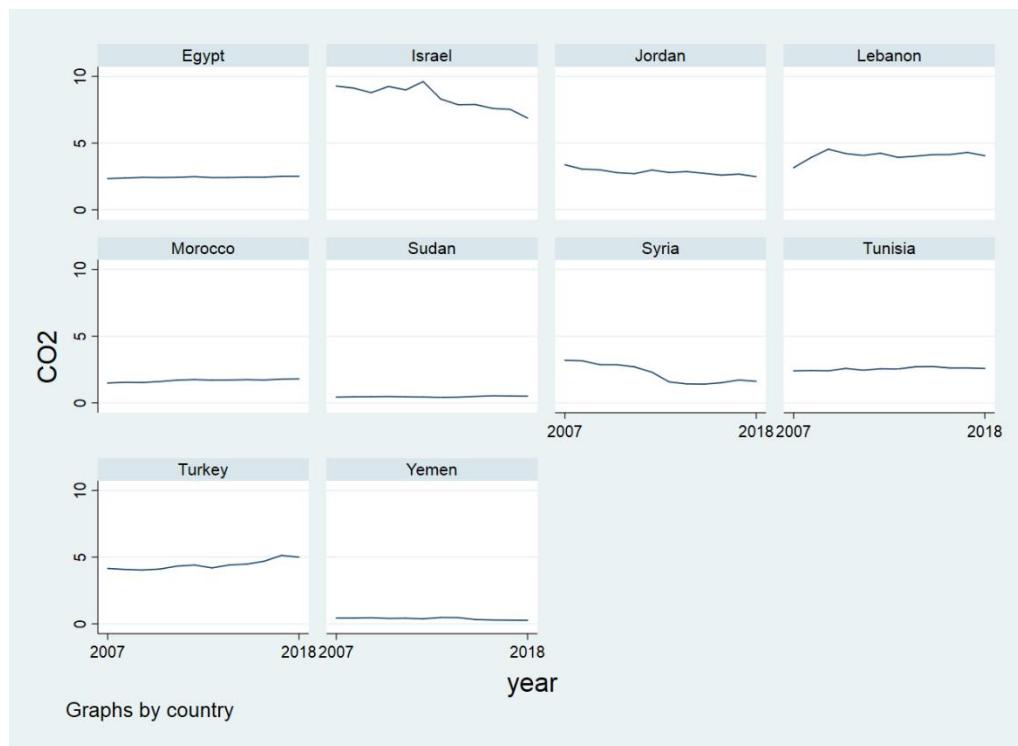


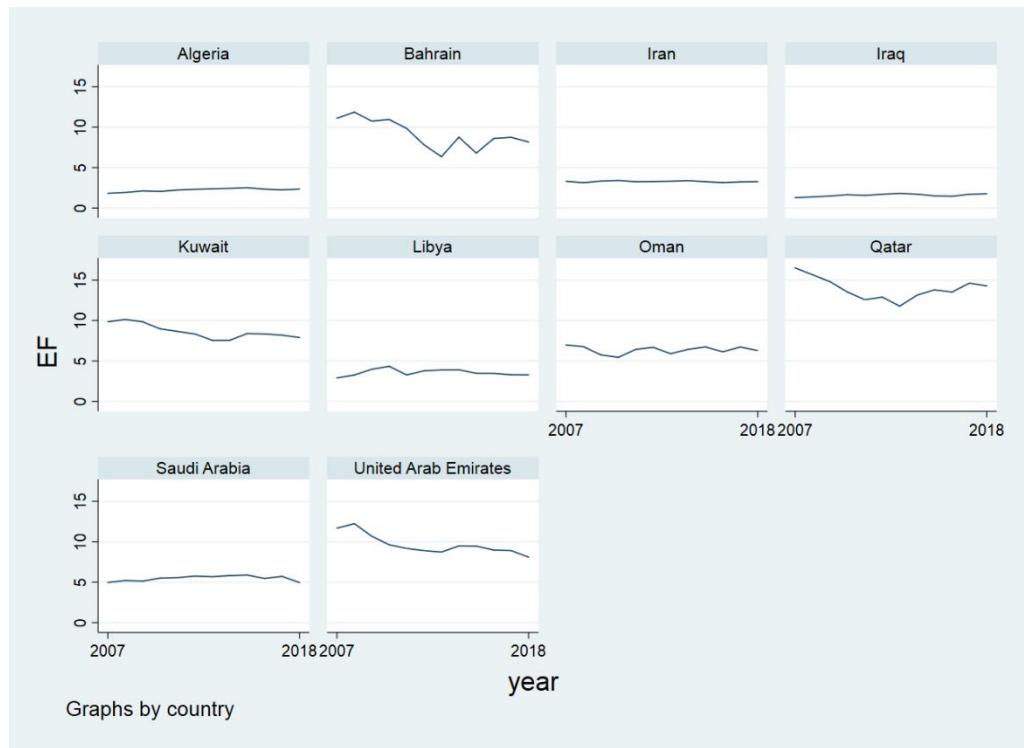
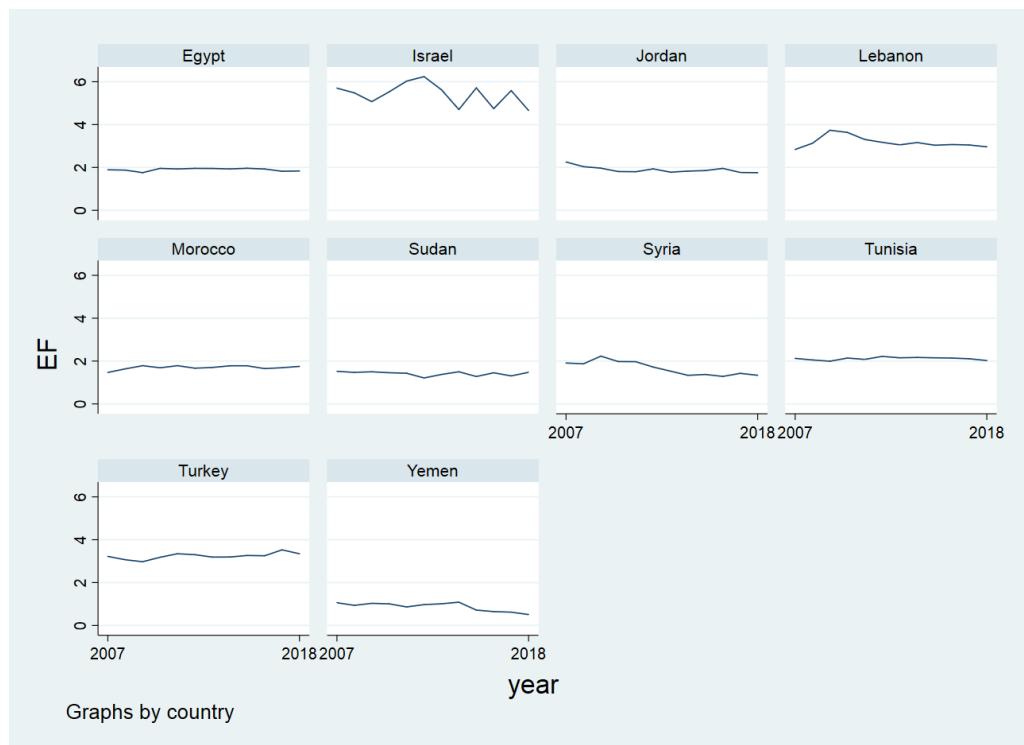
Figure A3. Ecological Footprint per capita, in global hectares (gha) (Oil-rich countries)**Figure A4. Ecological Footprint per capita, in global hectares (gha) (Non-oil-rich countries)**

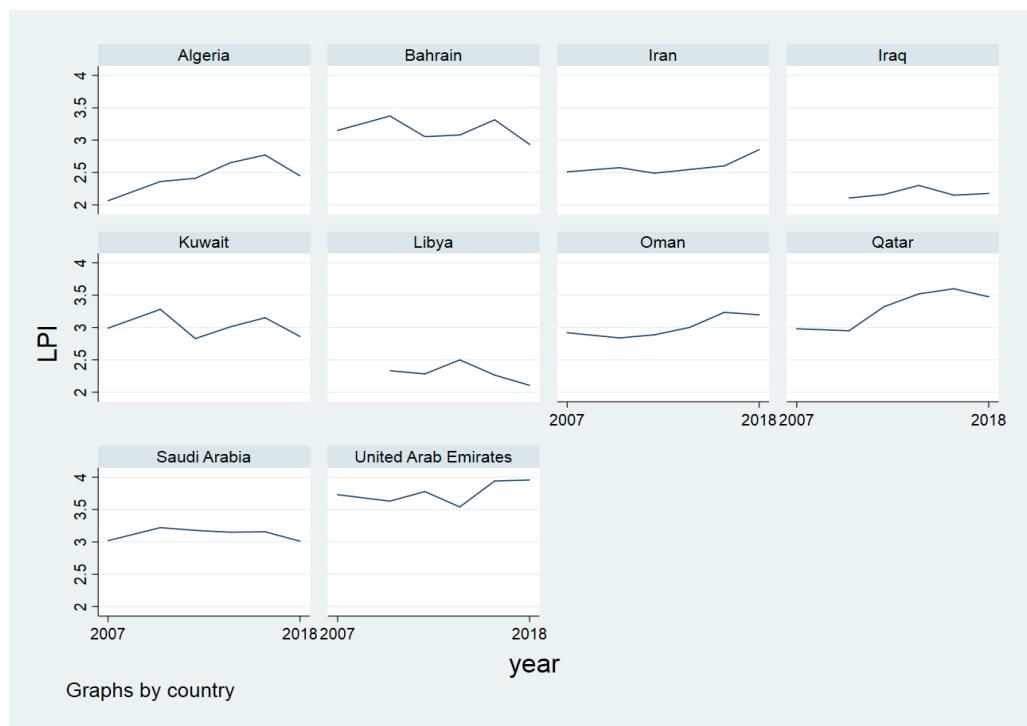
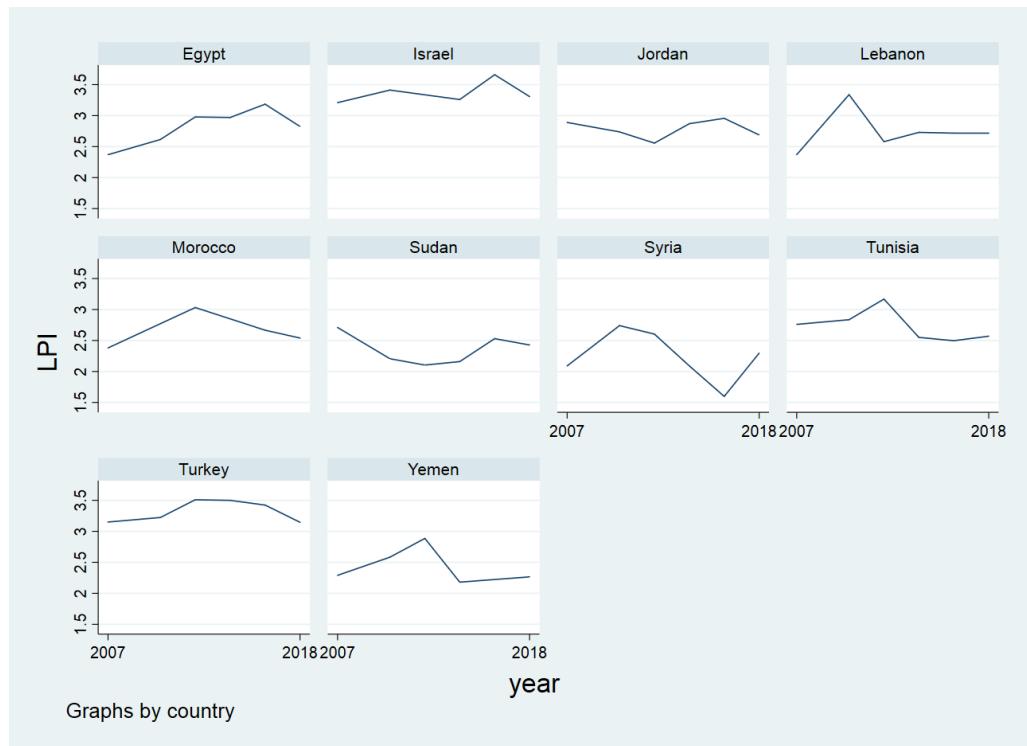
Figure A5. Overall logistics performance index (LPI) (Oil-rich countries)**Figure A6. Overall logistics performance index (LPI) (Non-oil-rich countries)**

Table A1. FE-IV (2SLS) and GMM Results

	All sample				Oil-rich		Non-oil-rich	
	IV ln (CO2)	IV ln (EF)	GMM ln (CO2)	GMM ln (EF)	IV ln (CO2)	IV ln (EF)	IV ln (CO2)	IV ln (EF)
ln (LPI)	0.167 (0.105)	0.599*** (0.124)	0.157 (0.374)	0.668* (0.391)	0.348*** (0.125)	1.179*** (0.221)	0.091 (0.153)	0.129 (0.120)
ln (GDPpc)	0.471*** (0.063)	0.478*** (0.089)	0.341** (0.162)	0.227 (0.160)	0.526*** (0.076)	0.235* (0.120)	0.556*** (0.099)	0.663*** (0.097)
<i>livas</i>	- 0.236*** (0.091)	-0.285** (0.114)	-0.032 (0.213)	-0.016 (0.376)	-0.295** (0.149)	-0.238 (0.265)	-0.232 (0.333)	0.193 (0.329)
<i>tros</i>	0.044 (0.046)	-0.233*** (0.079)	-0.075 (0.115)	0.084 (0.187)	-0.070* (0.038)	-0.259*** (0.088)	0.023 (0.119)	-0.236* (0.124)
<i>fdis</i>	-0.411 (0.301)	-0.460 (0.484)	1.850 (1.550)	1.020 (1.540)	0.389* (0.219)	-0.824 (0.602)	-1.435** (0.656)	-0.076 (0.528)
<i>recls</i>	-1.012 (0.732)	-0.849 (0.659)	-1.212 (1.564)	-0.575 (1.392)	-10.878*** (4.058)	-5.856 (6.916)	-1.318* (0.755)	-0.305 (0.660)
Lag.ln (CO2)			0.450* (0.247)					
Lag.ln (EF)				0.461** (0.185)				
Observations	200	200	202	202	99	99	101	101
Countries	20	20	20	20	10	10	10	10
R-squared	0.464	0.428			0.655	0.475	0.507	0.622
F-stat	8.88***	7.84***	526.75***	68.84***	8.20***	3.63***	4.87***	7.85***
Hansen (p-val)	0.491	0.182	0.999	0.857	0.081	0.724	0.795	0.135
AR (1) (p-val)			0.072	0.028				
AR (2) (p-val)			0.723	0.353				

Note: All models include a constant and year dummies but not reported to save space.

Robust standard errors in parentheses *** p<0.01, ** p<0.05, * p<0.1

Table A2. Environmental Degradation and Overall LPI, FE Estimations with 2-year averages

	<u>All sample</u>		<u>Oil-rich</u>		<u>Non-oil-rich</u>	
	$\ln(CO2)$	$\ln(EF)$	$\ln(CO2)$	$\ln(EF)$	$\ln(CO2)$	$\ln(EF)$
$\ln(LPI)$	0.100 (0.053)	0.317*** (0.059)	0.353*** (0.036)	0.896*** (0.067)	0.011 (0.094)	0.159 (0.173)
$\ln(GDPpc)$	0.504*** (0.026)	0.571*** (0.042)	0.503*** (0.022)	0.255 (0.166)	0.590*** (0.120)	0.703*** (0.136)
<i>livas</i>	-0.345* (0.142)	-0.433*** (0.094)	-0.300** (0.088)	-0.325 (0.300)	-0.661** (0.239)	-0.482 (0.569)
<i>tr os</i>	0.073* (0.033)	-0.230*** (0.034)	-0.092 (0.053)	-0.296* (0.126)	0.138 (0.258)	-0.058 (0.276)
<i>fdis</i>	-0.657*** (0.156)	0.125 (0.358)	0.486** (0.155)	0.240 (0.777)	-2.062*** (0.426)	-0.659 (0.366)
<i>re cs</i>	-1.329 (0.806)	-1.071*** (0.214)	-11.079*** (2.331)	-15.502*** (3.772)	-1.842 (1.075)	-0.478 (0.336)
Observations	106	106	54	54	52	52
Countries	20	20	10	10	10	10
R-squared	0.473	0.550	0.744	0.620	0.549	0.778
F-stat. (Overall)	6.12 [0.000]	8.33 [0.000]	8.71 [0.000]	4.90 [0.000]	3.44 [0.003]	9.85 [0.000]
F-stat. (Country FE)	217.20 [0.000]	49.30 [0.000]	125.85 [0.000]	19.97 [0.000]	118.05 [0.000]	39.17 [0.000]

Note: All models include a constant, country fixed effects and year dummies. Driscoll-Kraay standard errors in parentheses *** p<0.01, ** p<0.05, * p<0.1. p-values for the F-statistics are in brackets.

Table A3. Environmental Degradation and Sub-indices of LPI, FE Estimations with 2-year averages

	<u>All sample</u>		<u>Oil-rich</u>		<u>Non-oil-rich</u>	
	<u>ln (CO2)</u>	<u>ln (EF)</u>	<u>ln (CO2)</u>	<u>ln (EF)</u>	<u>ln (CO2)</u>	<u>ln (EF)</u>
ln (LPIC)	-0.008 (0.040)	0.039 (0.060)	0.111*** (0.028)	0.196* (0.096)	-0.127 (0.103)	-0.032 (0.123)
R-squared	0.466	0.497	0.696	0.453	0.566	0.764
ln (LPIIN)	0.102* (0.046)	0.167*** (0.032)	0.324*** (0.035)	0.533*** (0.061)	0.036 (0.081)	0.056 (0.157)
R-squared	0.478	0.521	0.767	0.539	0.550	0.765
ln (LPIIS)	0.106* (0.051)	0.241*** (0.038)	0.100* (0.044)	0.447*** (0.046)	0.128 (0.069)	0.117 (0.060)
R-squared	0.482	0.557	0.697	0.587	0.564	0.777
ln (LPIQC)	0.056 (0.032)	0.202** (0.051)	0.240*** (0.032)	0.453*** (0.112)	0.028 (0.064)	0.144 (0.087)
R-squared	0.469	0.532	0.739	0.527	0.550	0.786
ln (LPITT)	0.098* (0.042)	0.287*** (0.046)	0.166** (0.046)	0.415*** (0.047)	0.001 (0.093)	0.164 (0.104)
R-squared	0.482	0.600	0.739	0.601	0.549	0.796
ln (LPIT)	-0.017 (0.067)	0.115** (0.035)	-0.015 (0.088)	0.088 (0.150)	-0.000 (0.038)	0.112 (0.144)
R-squared	0.466	0.504	0.680	0.433	0.549	0.772
Control variables	YES	YES	YES	YES	YES	YES
Country FE	YES	YES	YES	YES	YES	YES
Year dummies	YES	YES	YES	YES	YES	YES

Note: All models include a constant, country fixed effects, year dummies, and control variables (*GDPpc*, *livas*, *tros*, *fdis*, *recs*) but the results are not reported to save space. Driscoll-Kraay standard errors in parentheses *** p<0.01, ** p<0.05, * p<0.1.

The Role of Pearl's Causal Framework in Empirical Research

Fırat BİLGEL*

Abstract

This paper underscores the necessity of formulating precise research questions that clarify causal relationships rather than simply identifying correlations and highlights the perils of relying solely on regression analysis in tackling complex causal inquiries without causal diagrams or structural causal models. It introduces Judea Pearl's causal epistemology, including causal graphs, structural causal models, and do-calculus as vital tools for estimating causal effects. It extends to the challenges of confounding and collider effects, the application of do-calculus with basic examples from Law & Economics and the advancements in causal discovery methods through constraint-based algorithms. The paper also offers a brief roadmap on best practices for identification and estimation.

Keywords: Pearl's causal epistemology, causal discovery, identification

JEL Codes: A12, C18, C51, K14

* MEF University, Department of Economics, bilgelf@mef.edu.tr, <https://orcid.org/0000-0002-2585-5975>

Pearl'in Nedensel Modelinin Ampirik Araştırmadaki Rolü

Öz

Bu çalışma, korelasyonları tespit etmek yerine neden-sonuç ilişkilerini açıklığa kavuşturan kesin araştırma soruları formüle etmenin gerekliliğini vurgulamakta ve karmaşık nedensel sorularla baş etmede, nedensel grafikler veya yapısal nedensel modeller olmadan sadece regresyon analizi kullanmanın tehlikelerine dikkat çekmektedir. Judea Pearl'ün nedensel epistemolojisinde kullanılan, nedensel grafikler, yapısal nedensel modeller ve do-kalkülüs gibi araçları nedensel etkileri tahmin etmek için tanıtır. Çalışma aynı zamanda karıştırıcı ve çarışma etkileriyle ilgili zorluklara, Hukuk ve Ekonomi'den basit örneklerle, do-kalkülüs uygulamalarına ve tahdit temelli algoritmalar aracılığıyla nedensel keşif yöntemlerindeki gelişmelere değinmektedir. Makale ayrıca etki tanımlama ve tahmin konusunda en iyi uygulamalar hakkında kısa bir yol haritası sunar.

Anahtar Kelimeler: Pearl'ün nedensel epistemolojisi, nedensel keşif, etki tanımlama

JEL Kodları: A12, C18, C51, K14

1. Introduction

Strong research hinges on well-defined questions. Beyond simply identifying a topic of interest, a good research question should be free of ambiguity, address a specific and well-defined issue. In empirical research, it is crucial to distinguish between questions aimed at predicting outcomes and those seeking to establish causal relationships, as each requires different tools and approaches. For example, “what are the determinants of judicial bias?” is a valid research question if the goal is to predict judicial decisions based on a set of inputs. However, if the focus is on uncovering causal relationships, the question should be reformulated to target a specific cause-and-effect, such as “what is the causal effect of exposure to pretrial media coverage of criminal cases on sentencing outcomes?” This revised question focuses on the specific relationship as a form of judicial bias and is phrased to explore a causal relationship. Similarly, the question “what is the relation between income inequality and crime?” aims to identify a potential association but does not establish causality. Income inequality could be caused by other factors such as education, employment opportunities, or social policies that also cause crime rates. In response, one may attempt to control for these “other factors” in a regression context; however, not only does this practice fail to rectify the problem, it could make it worse if the researcher lacks causal language. A good question is “what is the impact of a progressive tax system on property crime rates?” This question is stronger because it suggests a mechanism where changes in the tax system might cause property crime by potentially altering income distribution and economic incentives.

This study underscores the critical importance of causal reasoning and advocates the adoption of Pearl’s causal framework as a complementary approach to existing tools to identify causal effects in economics and related fields. This approach not only addresses identification challenges but also enhances the rigor of empirical analysis through best practices that emphasize a solid understanding of causal relationships. The paper aims to serve as a guide and a starting point for researchers interested in understanding the basics of Pearl’s framework and employing structural causal models in empirical research. The paper also aims to equip economists with robust methodologies to discern causal mechanisms, ultimately leading to more informed policy decisions and a deeper understanding of socioeconomic phenomena.

Section 2 assesses the consequences of relying solely on regression analysis without a foundational understanding of causal relationships. It utilizes an example from sentencing and recidivism to illustrate the perils of drawing misleading inferences when conditioning on variables without considering their causal role. Section 3 discusses Pearl’s causal epistemology and employs a hypothetical dataset on eyewitness identification and wrongful convictions to showcase how do-calculus can help clarify the distinction between deliberate intervention and passive observation. Section 4 discusses selected causal discovery algorithms that can be useful as a reinforcing

strategy along with causal reasoning. Section 5 provides a brief roadmap to a well-executed empirical analysis and Section 6 concludes.

2. Regression is Evil

Regression in general has, unfortunately, become a black box in empirical research. Many researchers mistakenly believe that simply applying Ordinary Least Squares (OLS) to their data can provide clear answers to complex causal questions (Sekhon, 2010). Modern causal inference methods, such as Structural Causal Models (SCMs) and Directed Acyclic Graphs (DAGs), provide a more rigorous framework for identifying and estimating causal effects. These methods help clarify the assumptions needed for causal inference and guide the proper conditioning on variables to avoid bias. Without identification, researchers may overlook important aspects of causal inference that estimation alone cannot address.

Inference based on observational data requires stronger assumptions relative to experimental data. Imagine that we are interested in the causal impact of sentencing on repeat-offending. While comparing recidivism rates for criminals with varying sentencing schemes, we make a strong and unrealistic assumption that criminals sentenced by different judges are otherwise identical in terms of the severity of crime, prior criminal record and other defendant characteristics such as age, socioeconomic status, mental health record and rehabilitation experience. We conjecture that criminals who committed serious crimes are more likely to re-offend compared to less severe crimes regardless of sentence length; those with a history of violence or repeat offenses might receive longer sentences; and age, mental health and socioeconomic status of the individual and participation in rehabilitation programs (e.g. substance abuse treatment, job training) can affect recidivism. We therefore collect data on all these observable characteristics and run a regression that looks like this:

$$Y_i = \alpha + \beta T_i + \delta' X_i + \varepsilon_i \quad (1)$$

where Y is a measure of recidivism, T is the severity of punishment, and X denotes all other observable differences mentioned above.

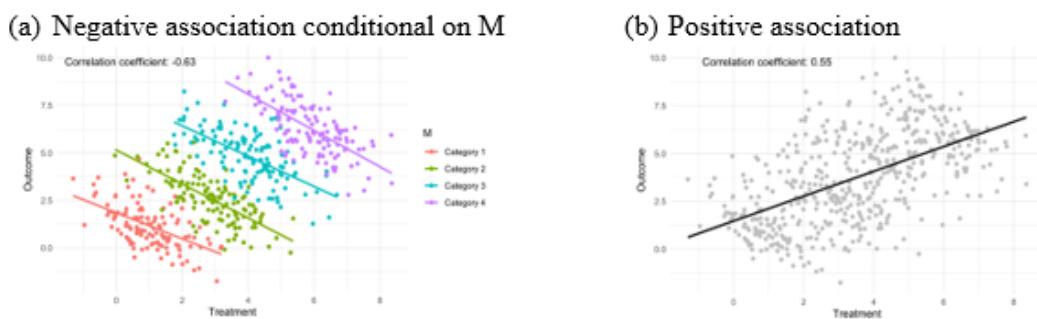
Those who receive harsher penalties might be systematically different from those who do not even after adjusting for observable confounders. For example, how about judges being more likely to impose harsher sentences on criminals that they perceive as high-risk for recidivism? Or how about criminals who are more likely to re-offend being less likely to respond positively to rehabilitation programs? Ignoring the first question leads to selection bias and the second to reverse causation. Unfortunately, this is not the

entire story. How could one possibly know that one should include every observable factor into eq. (1) the way we did without knowing how these factors interact with each other and with T and Y? As Pearl and Mackenzie (2018) note, data are agnostic to cause and effect, so are regressions.

In a randomized experiment, we could randomly assign convicted criminals to varying sentencing schemes. Although highly unethical, randomization of sentencing would rule out not only the effects of observable factors but also those that are not observable (either because data is missing or because we have not even considered they existed) and that bias the β estimate. Even if a randomized controlled trial (RCT) had been ethical, it may not be feasible for a multitude of factors.

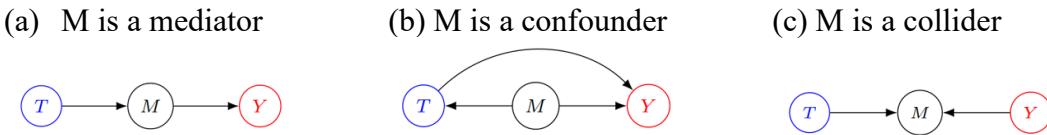
To make my earlier point concrete, consider a hypothetical dataset that shows a mild positive correlation between the treatment (T) and the outcome (Y). Let us generate another variable, M, that is a multi-valued variable with four categories, M=1,2,3,4. Assume that we do not know anything about the type of relationship that M has vis-a-vis T and Y and simply include it as a covariate in the relationship between T and Y. The scatter plot of this situation is given in Figure 1a. For every category of M, it shows that T and Y are inversely related with a correlation coefficient of about -0.63. Then, the researcher plots another scatter diagram using the exact dataset, this time not stratified by M. This situation is given in Figure 1b. It shows a positive relationship between T and Y, with a correlation coefficient of +0.55. Which one should the researcher trust? This situation is a classical example of the Simpson's paradox and the answer depends on the nature of the triangular relationships among M, T and Y.

Figure 1. Scatter plot of a hypothetical dataset



If M mediates the relationship between T and Y, we have the situation in Figure 2a that shows a pure mediating effect, meaning that T would have no effect on Y in the absence of M. Controlling for M will cut off the flow of information from T to Y, hence the correct strategy is to not stratify by M (Figure 1b).

Figure 2. Three types of relationships



For example, patent law grants inventors exclusive rights over their inventions (T) for a period to incentivize innovation (Y). This exclusivity allows the inventor to disclose (M) the details of their invention publicly but retain control over its commercial use. Disclosure of the invention (M) can directly stimulate further innovation (Y) by allowing other researchers and inventors to build upon the disclosed knowledge. Without proper disclosure (M), the details of the invention remain secret and a patent grant (T) might not directly lead to further innovation (Y).

If, on the other hand, M is a variable that confounds the relationship between T and Y, we have the situation in Figure 2b, showing that M is a common cause of T and Y. Here, the causal path is $T \rightarrow Y$ and $T \leftarrow M \rightarrow Y$ is a confounding path that creates a backdoor from T to Y. That is, if we follow the incoming arrow to T all the way back, we can reach Y through a path other than $T \rightarrow Y$. If we do not adjust for M, this backdoor path will remain open (it leads us back to Y) and the effect of T on Y will be biased. It will not only contain the causal effect but also the impact of M on Y. Conditioning on M will close the backdoor $T \leftarrow M \rightarrow Y$. Hence the correct strategy is to stratify by M (Figure 1a).

For example, patent grants (T) are often seen as a sign of a company's innovative potential, which can positively affect its stock price (Y). However, we know that high-quality inventions (M) with significant commercial potential are more likely to be patented (T) and that high-quality inventions (M) can also affect stock price (Y). Investors might see patents as a signal of innovation and future profitability, while high-quality inventions inherently hold greater commercial value.

Another most frequently encountered type of relationship is given in Figure 2c. Here, both T and Y cause M, which is known as a collider, referring to the fact that the

arrows emanating from T and Y collide on M. A stylized example from criminology is parole supervision (T), re-offending (Y) and employment (M) (Novak et al., 2023). In the population of parolees, there is no relation between parole supervision and re-offending. However, if we restrict the sample to employed individuals only, we induce an artificial correlation between parole supervision and re-offending.

The minority status of an individual (T) might affect the police use of force (M) due to potential racial biases in policing practices. Neighborhood crime rate (Y) could also cause police use of force (M) because areas with higher crime rates might see more frequent or aggressive police interventions. If we condition on or restrict our sample to cases in which police used force, there might appear to be a relationship between the minority status of the individual and crime rate even if they were unrelated to one another in the general population.

Hence, paths that include a collider that has not been conditioned upon are closed. Adjusting for or conditioning on a collider variable opens that path. Incorrect handling of collider variables can lead to false inference and misinterpretation of causal paths.

3. Pearl's Causal Framework

Judea Pearl's causal epistemology (Pearl, 2009; Pearl et al., 2016) offers a revolutionary framework for understanding causal relationships, particularly in situations where experimentation is not possible. By grounding causality in probability and graph theory, he developed a formal language for reasoning about interventions and counterfactuals. This framework has significantly advanced our ability to draw inferences from observational and experimental data, with profound implications in social sciences and medicine.

While Pearl's framework has undeniably transformed our approach to causal inference, it is not the only methodology available to researchers seeking to uncover causal relationships. Other causal inference methods include Structural Equation Modeling (SEM) and the Potential Outcomes (PO) Framework of Rubin (2005) and Imbens and Rubin (2010), which provide alternative, yet complementary approaches to causal inference.

SEM is a statistical approach that models relationships between variables using a system of (linear) equations. It can be viewed as a generalization of path analysis and allows researchers to specify and test complex causal relationships by incorporating both observed and unobserved variables.

Rubin's Potential Outcomes (PO) framework, also known as the Rubin Causal Model (RCM), is a foundational approach to causal inference in social sciences. The PO framework conceptualizes causality through counterfactuals. For each unit, there are potential outcomes corresponding to each possible treatment condition. The causal effect is defined as the difference between these potential outcomes.

The PO framework is widely used in economics, epidemiology, political science, and social sciences, particularly in studies where the goal is to estimate the causal effect of a treatment, intervention, or policy. It is also the basis for many modern causal inference techniques, including Difference-in-Differences (DiD), Instrumental Variables (IV), and Regression Discontinuity Design (RDD).

While the PO framework focuses on the estimation of causal effects through counterfactual reasoning and emphasizes the importance of treatment assignment and covariate adjustment, Pearl's Causal Framework provides a more formalized approach to understanding and modeling the structure of causal relationships and places more emphasis on the role of causal diagrams in identifying and clarifying assumptions about causal relationships.

Pearl proposes a hierarchical framework called the Ladder of Causation that categorizes causal knowledge into three levels: association (seeing), intervention (doing) and counterfactuals (imagining) (Pearl and Mackenzie, 2018). Association is the most basic level, where one simply observes a relationship between two variables. Intervention involves manipulating variable X to observe its effect on variable Y. Finally, counterfactuals deal with hypothetical scenarios of "What would have happened if...?" and they are crucial for causal inference. But they can only be imputed, not directly observed for they contradict what is seen. For instance, "What would have happened to the presidential race or the polling results had Donald Trump not been shot?" is a counterfactual question. Each unit has multiple potential outcomes, one for each possible treatment level. The causal effect for a unit is the difference between the potential outcome under treatment and the potential outcome under control. Unfortunately, we can only observe one potential outcome for each unit, known as the fundamental problem of causal inference (Holland, 1986). To estimate causal effects from observed data, one relies on multiple units of treatment and control.

A causal graph, or a directed acyclic graph (DAG), is a visual representation of causal relationships among variables. In a DAG, nodes represent variables and directed edges (arrows) indicate causal effects. For instance, if variable A causes B, an arrow points from A to B. A crucial aspect of DAGs is that they are acyclic, meaning that following the arrowheads, you cannot start from node A and return to itself. This ensures that causality runs in a single direction.

Directed Acyclic Graph (DAG):

A DAG is a graph $G = (V, E)$ where

1. V is a set of vertices (nodes) representing variables,
2. $E \subseteq V \times V$ is a set of directed edges (arrows) between vertices.

While DAGs offer a visual representation, Structural Causal Models (SCMs) provide a mathematical framework for specifying causal relationships (Pearl, 2009). A SCM comprises a set of variables, a set of functions that determine the value of each variable given the values of its parents in the DAG, and a probability distribution over the exogenous variables. SCMs describe how variables are generated based on their causes and encode our knowledge about causal relationships.

Structural causal model (Pearl, 2009):

A SCM consists of:

1. A set of endogenous variables $\{Y_1, Y_2, \dots, Y_n\}$.
2. A set of exogenous variables $\{U_1, U_2, \dots, U_n\}$.
3. A set of structural equations $\{f_1, f_2, \dots, f_n\}$ such that each $Y_i = f_i(PA_i, U_i)$ where $PA_i \subseteq \{Y_1, Y_2, \dots, Y_n\}$ represents the parent variables of Y_i and $U_i \subseteq \{U_1, U_2, \dots, U_n\}$ are the exogenous variables affecting Y_i .

D-separation (Pearl, 1988):

D-separation (d stands for directional) plays a crucial role in understanding how the structure of a DAG encodes conditional independence between variables.

For all connecting paths between X and Y in the DAG, a path is considered blocked by Z if (i) it contains a collider where Z is not a descendant (does not have an incoming arrow to it) of the collider; and (ii) all other nodes along the path are not in Z. If all paths between X and Y are blocked by Z, then X and Y are d-separated given Z (Pearl, 1988). D-separation allows us to efficiently determine which variables are independent given others based solely on the DAG structure and to verify if the conditional independence assumptions encoded in the DAG structure hold.

Fourth aspect, the do-calculus is a mathematical framework within SCMs that allows us to formally analyze the effects of interventions (Pearl, 1995). It uses the concept of potential outcomes to represent the outcome that would have occurred under different treatment conditions (even if unobserved). By manipulating the SCM and applying the do-calculus, we can estimate the causal effect of an intervention on the outcome variable. The do-notation is characterized by the do-operator, denoted by $do(\)$, used to represent an intervention. For example, $do(X = x)$ indicates setting variable X to a specific value x. After an intervention on X in causal graph G, the incoming arrow to the intervened variable

(X) can be removed, resulting in a mutilated graph $G_{\bar{X}}$. Similarly, if X has no effect on the outcome, we can express this by removing the outgoing arrow from X as $G_{\underline{X}}$.

The three rules of do-calculus are intervention rule, composition rule and reduction rule.

Intervention rule (insertion/deletion of observations):

The first rule of do-calculus iterates d-separation and states that we can ignore a node Z if it does not affect the outcome Y. As long as the path between Y and Z is blocked, conditional on X and W, the node Z can be removed from the do-expression:

$$Pr(Y|do(X = x), Z, W) = Pr(Y|do(X = x), W) \text{ if } Y \perp Z|X, W \text{ in } G_{\bar{X}} \quad (2)$$

which means “Y is independent of Z, given W and X” in the mutilated graph.

Composition rule (action/observation exchange):

The second rule of do-calculus allows us to combine multiple interventions. It states that the effect of an intervention $do(Z = z)$ has the same effect as observation $Z = z$ if Y and Z are independent, conditional on X and W. For this, we need to remove all outgoing arrows from Z to reflect the premise that an intervened Z has the same effect as a passively observed Z:

$$Pr(Y|do(X = x), do(Z = z), W) = Pr(Y|do(X = x), Z, W) \text{ if } Y \perp Z|X, W \text{ in } G_{\bar{X}Z} \quad (3)$$

Reduction rule (insertion/deletion of actions):

The third rule of do-calculus allows us to remove an intervention ($do(Z = z)$) from the expression completely if Z does not have a causal effect on the outcome Y, either directly or indirectly through any other variables in the model. Intuitively, if Z has no influence on Y, then intervening on it will not change the outcome distribution, and we can remove it from the expression:

$$Pr(Y|do(X = x), do(Z = z), W) = Pr(Y|do(X = x), W) \text{ if } Y \perp Z|X, W \text{ in } G_{XZ(W)} \quad (4)$$

where $Z(W)$ denotes any Z node that is not an ancestor or parent of W .

These rules are shown to be sufficient and complete in the sense that any acyclic causal relationship can be captured as long as a causal question can be represented by a DAG and an associated SCM, and that all causal questions can be answered by these rules (Huang and Valtorta, 2012).

Backdoor criterion (Pearl, 1995):

The backdoor criterion is a method for identifying a set of variables to adjust for or condition on when estimating a causal effect. A set of variables, Z , satisfies the backdoor criterion relative to an ordered pair of variables (X, Y) in a DAG if (i) no node in Z is a descendant of X and (ii) Z blocks every path between X and Y that contains an arrow into X (Pearl, 1995). In simpler terms, the backdoor criterion requires that the set Z does not itself be affected by the treatment (X) and that they block all alternative paths between the treatment and outcome that could confound the relationship. By conditioning on the variables in Z , we can control for confounding and estimate the causal effect of X on Y .

Frontdoor criterion (Pearl, 1995):

The frontdoor criterion is an alternative approach to estimating causal effects when the backdoor criterion cannot be satisfied. It involves a mediator variable, M , that lies on the causal pathway between the treatment, X , and the outcome, Y .

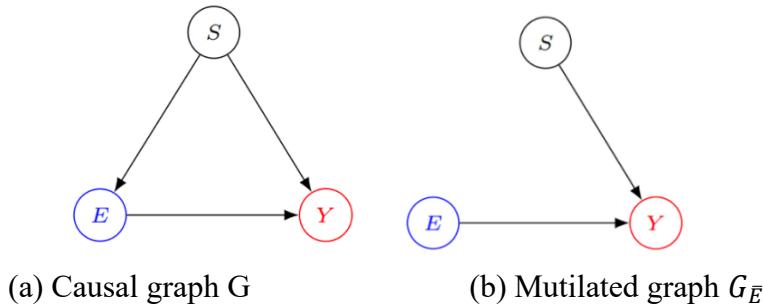
The conditions for the frontdoor criterion are (i) all directed paths from X to Y are blocked by M , (ii) there are no unblocked paths from X to M given W , and (iii) all backdoor paths from M to Y are blocked by X and W (Pearl, 1995). If these conditions hold, the causal effect of X on Y can be estimated by first estimating the effect of X on M , then the effect of M on Y while controlling for X and W , and finally multiplying these two estimates. The frontdoor criterion can be useful when it is difficult to measure or control for all confounders.¹

Let us take on a stylized example from criminology in which wrongful conviction (Y) is a function of eyewitness identification (E) and stressful interview techniques used by police (S) only. Eyewitness identification is a common method used in criminal investigations. However, eyewitness memory can be unreliable, especially when influenced by factors like stress or leading questions. Hence, it can directly contribute to wrongful conviction if the eyewitness misidentifies an innocent person. On the other hand, stressful interview techniques used by police (S) can act as a confounder in the relationship between

¹ There are other core elements such as necessary and sufficient causation, counterfactuals, mediation, selection, transportability and Z -identifiability, which are beyond the scope of this paper. For a review of Pearl's causal framework, see Bareinboim and Pearl (2016); Bareinboim et al. (2022) and Hünermund and Bareinboim (2023).

E and Y. We conjecture that stressful interview techniques can pressure suspects into making false confessions or providing inaccurate identifications of others. A simple DAG of this situation is given in Figure 3.

Figure 3. Eyewitness Identification and Wrongful Conviction



Assume all three variables are binary and consider an individual-level dataset with 1000 conviction cases whose tabulation is given in Table 1. We are interested in the causal effect of eyewitness identification (E) on wrongful convictions (Y). We can express this causal query using the do-operator as $Pr(Y = 1|do(E = 1))$. Intervening on E means that we are performing a surgery in Figure 3a by removing all arrows that goes into E. The resulting graph, called the mutilated graph, is given in Figure 3b.

Table 1. A hypothetical dataset on convictions, N = 1000

	Treatment (E = 1)			Treatment (E = 0)		
	Y = 1	Y = 0	%Y = 1	Y = 1	Y = 0	%Y = 1
Stressful techniques used (S = 1) $\frac{269}{100} = 0.27$	100	21	$\frac{100}{121} = 0.83$	132	16	$\frac{132}{148} = 0.89$
Stressful techniques not used (S = 0) $\frac{731}{100} = 0.73$	402	91	$\frac{402}{493} = 0.82$	200	38	$\frac{200}{238} = 0.84$
Total	502	112	$\frac{502}{614} = 0.82$	332	54	$\frac{332}{386} = 0.86$

Let us elaborate the causal query to obtain a do-free expression using the rules of do-calculus:

$$\begin{aligned}
 & Pr(Y = 1|do(E = 1)) = \sum_S Pr(Y = 1, S = s, do(E = 1)) \\
 &= \sum_S Pr(Y = 1, S = s, do(E = 1))Pr(S = s, do(E = 1)) \\
 &= \sum_S Pr(Y = 1, S = s, E = 1)Pr(S = s) \\
 &= Pr(Y = 1|S = 1, E = 1)Pr(S = 1) + Pr(Y = 1|S = 0, E = 1)Pr(S = 0) \\
 &= (0.83 \times 0.27) + (0.82 \times 0.73) = 0.134
 \end{aligned} \tag{5}$$

The first expression is eq. (2) states that the probability of $Y=1$ given that we intervene to set $E=1$ is the sum over the joint distribution of $Y=1$ and all possible values of confounder S . The second expression applies the chain rule decomposing the joint probability into a product of conditional probabilities. The third expression uses the third rule of do calculus (insertion/deletion of observations), stating that S is not affected by the intervention on E . Hence $Pr(S = s, do(E = 1)) = Pr(S = s)$. The fourth expression uses the second rule of do-calculus (action/observation exchange), stating that if S blocks all backdoor paths between E and Y , then conditioning on S is the same as intervening on E . Hence $= Pr(Y = 1, S = s, do(E = 1)) = Pr(Y = 1, S = s, E = 1)$. Plugging in the values from Table 1, the causal effect of eyewitness identification on wrongful convictions is 0.134. The association between E and Y on the other hand is $Pr(Y = 1|E = 1) = 0.82 \neq Pr(Y = 1|do(E = 1)) = 0.134$. The discrepancy between the two estimates is due to confounding bias induced by ignoring S .

4. Causal Discovery

Causal reasoning and causal discovery, while intricately linked, address different aspects. Causal reasoning uses existing knowledge or a defined causal structure via SCMs or DAGs to draw conclusions about cause and effect. It analyzes the consequences of interventions or counterfactual scenarios. Causal reasoning therefore runs from a causal model and observational data to outcomes, changes and interventions. On the other hand, causal discovery runs in the opposite direction. It aims to identify the underlying causal structure between a set of variables from data.

Table 2 shows the number of DAGs that can be built for a given number of nodes, without incorporating any prior domain knowledge or restriction. For example, with 2 nodes, say A and B, either A causes B, or B causes A or neither causes the other (i.e. unrelated), giving rise to a total of 3 unique DAGs. Notice that the series is explosive,

reaching about 3.8 million unique DAGs with only 6 nodes. However, once prior knowledge and assumptions based on a given theory are embedded via required or forbidden edges between any two nodes and the implied conditional dependencies are conformable to the data, this number will reduce considerably. Even so, it is not possible to obtain a single DAG for a given problem with observational data, nor is it possible to ensure that prior knowledge and conditional dependencies will be one-on-one mapped with a causal model. A very large number of causal diagrams may be consistent with our background knowledge and the implied conditional dependencies, but a subset of these causal diagrams may lead to different inferences than others (Scheines et al., 1998). However, it is possible to learn a completed partially DAG (CPDAG) from data, which is an equivalence class of DAGs that contains some undirected edges.

Table 2. Number of DAGs as a function of nodes

nodes (j)	Number of DAGs with j nodes
2	3
3	25
4	543
5	29281
6	3781503
7	1138779265
8	783702329343
9	1213442454842881
10	4175098976430598143
11	31603459396418917607425
12	521939651343829405020504063
13	18676600744432035186664816926721
14	1439428141044398334941790719839535103
15	237725265553410354992180218286376719253505
16	83756670773733320287699303047996412235223138303
17	62707921196923889899446452602494921906963551482675201
18	99421195322159515895228914592354524516555026878588305014783
19	332771901227107591736177573311261125883583076258421902583546773505
20	2344880451051088988152559855229099188899081192234291298795803236068491263

Source: <https://oeis.org/A003024/b003024.txt>

Constraint-based methods use a set of logical constraints or rules to identify possible causal relationships. They focus on identifying constraints that must be satisfied by the causal structure consistent with the observed data. This section focuses on causal discovery algorithms that allow for latent confounding. In order to understand how these algorithms work, a good starting point is the Peter-Clark (PC) algorithm of Spirtes and Glymour (1991), one of the algorithms that uses a constraint-based approach. PC algorithm relies upon the assumptions of causal Markow condition (two variables that are d-separated are probabilistically independent), faithfulness (conditional independences that hold in the data implies absence of a direct causal relationship between them), absence of latent confounding (there are no unobservable common causes) and acyclicity (there are no cycles in the resulting graph, which is a CPDAG).

The PC algorithm consists of two phases. In the adjacency phase, it starts with a complete, undirected graph where every variable is connected to every other variable. The algorithm iteratively removes edges between variables based on d-separation. If finding a set of conditioning variables (Z) renders two variables (X and Y) independent, the undirected edge between X and Y is removed. This process continues until no more edges can be removed based on d-separation. In the orientation phase, it uses conditioning sets from the adjacency phase and determines the direction of as many edges as possible based on the information from the conditioning and specific collider and non-collider structures.

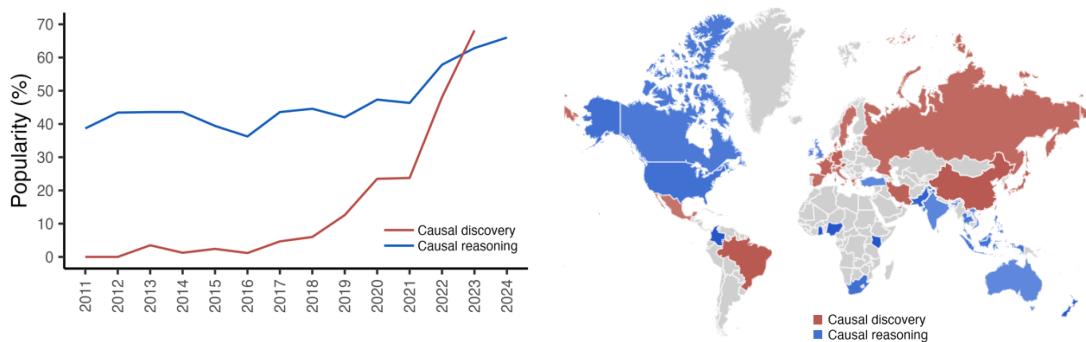
The Fast Causal Inference (FCI) algorithm, developed by Spirtes et al. (1993, 1999) and Spirtes et al. (2000) is a constraint-based algorithm that accepts sample data and background knowledge as inputs and produces an equivalence class of Causal Bayesian Networks (CBNs) that reflect the set of conditional independence relationships present in the population. It uses the adjacency and the orientation phases as in the PC algorithm. The resulting graph is a partial ancestral graph (PAG) in which all edges are directed but the pairwise relationships may contain latent confounders. Relative to PC, the FCI algorithm is computationally intensive due to the additional tests and rules for handling latent variables, making it suitable for more complex datasets.

Two notable variants of the FCI that allow for latent confounding whose resulting graph is also a PAG are the greedy FCI (GFCI) and really FCI (RFCI). The GFCI is a hybrid algorithm that combines constraint-based (FCI) and score-based (fast greedy search or FGES of Meek (1997) and Chickering (2002)) methods. RFCI, which is an improved version of FCI developed by Colombo et al. (2012), runs faster to mitigate computational inefficiencies of the FCI, making it suitable for larger datasets.²

² A comprehensive overview of causal discovery methods is given in Nogueira et al. (2022).

Figure 4 displays the worldwide popularity of causal reasoning and causal discovery over the last 14 years using data from Google Trends along with a world map showing countries where each topic is dominantly popular. Causal discovery has witnessed a significant surge in popularity in the last 5 years, recently surpassing that of causal reasoning. One particular reason of this surge lies in the popularity of Large Language Models (LLMs) that integrate causal reasoning capabilities and Causal AI, a branch of artificial intelligence that focuses on understanding and modeling cause-and-effect within data. Causal reasoning is the dominant web search topic, clustered in North America, Oceania, India, United Kingdom and South Africa whereas causal discovery is more popular in western Europe, Scandinavia, Asia and South America.

Figure 4. Trends in causal reasoning vs. causal discovery



Source: Google Trends under the topics “Causal discovery” and “Causal reasoning”.

5. A Roadmap

The roadmap to a well-executed empirical analysis consists of several critical steps. It begins with acquiring domain knowledge and making explicit assumptions, followed by building a causal graph to visualize relationships. The causal graph may be reinforced using causal discovery techniques to validate existing patterns or to uncover potential unforeseen causal links. The next step is refutation or validation of the causal model to ensure that the implied conditional independencies are satisfied. Subsequently, the causal query and the corresponding causal estimand are identified. Only then statistical methods should be employed to estimate the causal effect, followed by a series of falsification tests to verify its credibility.

5.1. The Causal Problem

“Give me a causal graph and I will tell you whether and if so how, a causal query can be answered.” Although simplified, Pearl’s framework is about an epistemological problem. “How a causal graph is constructed?” on the other hand is an ontological problem. For example, Pearl’s framework cannot tell you what kind of relationships exist between income equality, crime and a plethora of surrounding factors. As Pearl notes on many occasions, this requires expert knowledge. The accuracy of a causal diagram can be seen as an ontological concern, as it reflects how well it represents the “true” causal structure of the world. However, Pearl’s framework does not provide definitive answers about the “true” ontological nature of the system being studied. It offers a flexible tool to model causal relationships based on available knowledge and data.

The causal relationship we are trying to understand should be clearly articulated. What is the treatment and the outcome of interest? We need to list all the variables we believe might influence the relationship between the treatment and outcome, irrespective of whether they are measured or not. A DAG should not only consider measured variables but also acknowledge the existence of unmeasured variables. These can be factors we are aware of but have not been included in our data collection (known unknowns). Even more challenging are the variables we might not even be aware of that could be influencing the relationships in our model (unknown unknowns). Economic theory, existing literature, and domain knowledge should be considered here. Arranging variables/nodes in a chronological order based on when they are measured or occur helps determine the direction of the arrows. For each pair of nodes, we need to consider the underlying causal mechanisms and assess whether one variable directly causes the other and/or whether there are any measured or unmeasured mediators along the way or measured or unmeasured confounding factors influencing both.

You should resist the urge to look at the data before building a causal diagram for it can introduce a number of biases, even if you plan on using causal discovery algorithms along the way. Peeking at the data before constructing the DAG might lead to (*i*) favor evidence that confirms our initial hunch about the causal relationships and interpret patterns in a way that reinforces pre-existing ideas, potentially overlooking alternative causal structures that the data might also support; (*ii*) decide about which variables to include or exclude in the DAG, or how to connect them; (*iii*) or choose to focus on specific subsets or exclude outliers, leading to a biased representation of the causal relationships. You cannot possibly include every factor into a causal diagram, and no one expects you to do so. Essentially, what you need to incorporate are the ones that are highly-plausible to exist but also identification-altering. For example, if your DAG does not incorporate a known-unknown treatment-outcome confounder that you think should have been there but could

not incorporate because of data unavailability, this will change identification and consequently inference because it will introduce a backdoor that cannot be closed.

There are several packages that will help you construct and analyze causal diagrams using R statistical software (R Core Team, 2024): **DiagrammeR** (Iannone and Roy, 2024), **causaloptim** (Sachs et al., 2023), **causaleffect** (Tikka and Karvanen, 2017), **dagitty** (Textor et al., 2016), **MRPC** (Badsha et al., 2021), **ggdag** (Barrett, 2024) and **dosearch** (Tikka et al., 2021). Beyond these, there is an online software, **Causal Fusion** (Bareinboim and Pearl, 2016) that incorporates Pearl's framework, developed by Elias Bareinboim, Juan, D. Correa and Chris Jeong.³ For Python users, the **DoWhy** library for causal inference would be an excellent alternative.⁴ Unfortunately, as far as the identification and causal problems are concerned, Stata users are empty-handed.

Once all prior knowledge and assumptions about the causal question are embedded in the causal diagram, the conditional independencies implied by the causal graph should be checked using the data. If at least one conditional independency is not met by the data, the DAG should be revised. What makes the construction of a causal graph extremely challenging and intriguing are the unknown unknowns. Causal reasoning has little to offer in that respect. You cannot possibly incorporate a node that you are not aware of. Fortunately, there is at least a partial remedy via causal discovery, which is very useful once a reasonably accurate DAG is obtained. Causal discovery using observational data is not infallible as it can be sensitive to various assumptions and limitations of the data. Therefore, our background knowledge should steer the wheel.

There are several packages that will help you perform causal discovery in R: **pcalg** (Kalisch et al., 2012), **bnlearn** (Scutari et al., 2024), **causalDisco** (Petersen, 2022) and **tetrad** (Scheines et al., 1998; Ramsey and Andrews, 2023).⁵

5.2. The Statistical Problem

Once identification is complete, the next step is estimation or the statistical problem. There are many options to choose from, depending on the context, the nature of the data and most importantly, whether and if so, how identification can be achieved. It is crucial to ensure that the estimated effects are not driven by biases, confounders, or artifacts of the data. Falsification tests provide a rigorous approach to assess the robustness of causal estimates by introducing hypothetical scenarios or alternative models. One such test involves introducing a random confounder, an independent random variable added to the

³ Available at: causalfusion.net (login required)

⁴ Available at: <https://www.pywhy.org/dowhy/v0.11.1/>

⁵ Tetrad is available at: <https://github.com/cmu-phil/py-tetrad/tree/main/pytetrad/R>

model as a common cause. If the causal estimate remains stable, this suggests that the original estimate is not driven by unmeasured confounding. A significant change in the estimate indicates potential vulnerability to confounding and raises concerns about the validity of the causal inference.

Further falsification strategies include placebo tests. A placebo treatment test examines whether replacing the actual treatment variable with an independent random variable significantly changes the estimate. The expectation is that the estimated effect should become indistinguishable from zero to reinforce the idea that the original treatment variable was indeed causally related to the outcome. Similarly, a placebo outcome test replaces the actual outcome variable with another, known to be unrelated to the treatment and other observables. Again, the estimated effect should not be significantly different from zero at conventional test levels.

To ensure that the estimates are consistent across different subsamples of data, data subset validation and bootstrap validation can be performed. In data subset validation, the dataset is replaced by random subsets of the same data. The estimated effects should be similar to the original estimate. Bootstrap validation involves replacing the dataset with bootstrap samples, where the estimated effects should also remain stable. Together, these tests assess the internal consistency and generalizability of the causal estimate, ensuring that the findings are not artifacts of a specific dataset.

Sensitivity analysis complements falsification tests by evaluating how sensitive the causal estimates are to various assumptions and potential deviations. A leave-one-out (LOO) analysis examines the stability of the estimates by iteratively excluding each unit from the sample. If the estimates change significantly with the exclusion of any single unit, it may indicate that the findings are overly dependent on particular observations, which could undermine the generalizability of the results.

Another critical aspect of sensitivity analysis is assessing unobserved confounding. This involves introducing a hypothetical unobserved confounder that is correlated with both the treatment and the outcome. By observing how the estimates change, researchers can gauge how robust their results are to potential biases from unmeasured variables. If the causal estimate remains relatively stable despite the introduction of a latent confounder, it suggests that the original estimate is likely to be robust. Similarly, one can assess the strength of a latent confounding that would explain away the estimate of the impact of treatment on the outcome via formal sensitivity analysis of Cinelli and Hazlett (2020). In the context of instrumental variables (IV), the identification of the average causal effect relies upon the instrument being (1) relevant (the instrument has a clear effect on treatment), (2) clean (the instrument affects the outcome only and only through the treatment) and (3) excludable (there is no latent confounding between the instrument and the outcome). While

(1) and (2) can be assessed, (3) is untestable. Therefore, researchers may be concerned with the possibility that the instrument may not satisfy the exclusion restriction and therefore may be invalid. One can conduct a sensitivity analysis to invalid IV of Wang et al. (2018) for this purpose.

6. Conclusion

Pearl's causal epistemology provides a robust framework for understanding and analyzing causal relationships in empirical research. Through the use of causal graphs, structural causal models, and do-calculus, researchers can move beyond mere correlations. The distinction between causal reasoning and causal discovery highlights the different methodologies employed to derive causal insights. While causal reasoning allows us to draw conclusions based on established causal structures, causal discovery seeks to identify these structures from the data. The feedback between the two approaches can help researchers better navigate the complexities of causal relationships and avoid pitfalls associated with regression analysis.

Graphical approaches, particularly DAGs, are powerful tools for identifying causal relationships, especially in microeconomic analysis where individual-level data often allow for a clear delineation of causal pathways. However, these methods are not without limitations. One significant challenge arises when applying DAGs to aggregated data, common in macroeconomic analysis. In such contexts, simultaneity, unmeasured confounders, and the nature of aggregated variables can obscure the causal relationships that DAGs are designed to clarify. The assumptions required for DAGs to provide valid causal insights may not hold as readily in aggregated datasets, where complex feedback loops and interdependencies are more prevalent. Acknowledging these challenges is important for a balanced understanding of the applicability of graphical causal models across different levels of economic analysis. While DAGs offer clear advantages in microeconomic contexts, their utility in macroeconomic analysis may be limited without careful consideration of the underlying data structure and potential biases introduced by aggregation.

References

- Badsha, M. B., Martin, E. A., and Fu, A. Q. (2021). MRPC: An R package for inference of causal graphs. *Frontiers in Genetics*, 12:651812.
- Bareinboim, E., Correa, J. D., Ibeling, D., and Icard, T. (2022). In H. Geffner, R. Dechter, and J. Y. Halpern (Eds.). *Probabilistic and Causal Inference: The Works of Judea Pearl* (1st. ed., pp. 507–556). New York: ACM Books, Vol. 36. Association for Computing Machinery.
- Bareinboim, E. and Pearl, J. (2016). Causal inference and the data-fusion problem. In Shiffrin, R. M. (Ed.). *Proceedings of the National Academy of Sciences*, 113, 7345–7352.
- Barrett, M. (2024). ggdag: Analyze and Create Elegant Directed Acyclic Graphs. R package version 0.2.12, <https://r-causal.github.io/ggdag/>.
- Chickering, D. M. (2002). Optimal structure identification with greedy search. *Journal of machine learning research*, 3(Nov), 507–554.
- Cinelli, C. and Hazlett, C. (2020). Making sense of sensitivity: Extending omitted variable bias. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 82(1), 39–67.
- Colombo, D., Maathuis, M. H., Kalisch, M., and Richardson, T. S. (2012). Learning high-dimensional directed acyclic graphs with latent and selection variables. *The Annals of Statistics*, 40 (1), 294–321.
- Holland, P. W. (1986). Statistics and causal inference. *Journal of the American Statistical Association*, 81(396), 945–960.
- Huang, Y. and Valtorta, M. (2012). Pearl’s calculus of intervention is complete. arXiv preprint arXiv:1206.6831.
- Hünermund, P. and Bareinboim, E. (2023). Causal inference and data fusion in econometrics. *The Econometrics Journal*, page utad008.
- Iannone, R. and Roy, O. (2024). DiagrammeR: Graph/Network Visualization. R package version 1.0.11.9000, <https://github.com/rich-iannone/DiagrammeR>.
- Imbens, G.W., Rubin, D.B. (2010). Rubin Causal Model. In: Durlauf, S.N., Blume, L.E. (Eds.) *Microeconometrics*. (pp. 229–241). London: The New Palgrave Economics Collection. Palgrave Macmillan.
- Kalisch, M., Mächler, M., Colombo, D., Maathuis, M. H., and Bühlmann, P. (2012). Causal inference using graphical models with the R package pcalg. *Journal of Statistical Software*, 47, 1–26.
- Meek, C. (1997). Graphical Models: Selecting causal and statistical models. Ph.d thesis, Carnegie Mellon University.

- Nogueira, A. R., Pugnana, A., Ruggieri, S., Pedreschi, D., and Gama, J. (2022). Methods and tools for causal discovery and causal inference. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 12(2): e1449.
- Novak, A., Boutwell, B. B., and Smith, T. B. (2023). Taking the problem of colliders seriously in the study of crime: A research note. *Journal of Experimental Criminology*, 1–10.
- Pearl, J. (1988). Probabilistic reasoning in intelligent systems. San Mateo, CA: Morgan Kaufmann.
- Pearl, J. (1995). Causal diagrams for empirical research. *Biometrika*, 82(4), 669–688.
- Pearl, J. (2009). *Causality: Models, Reasoning and Inference* (2nd ed.). New York, NY: Cambridge University Press.
- Pearl, J., Glymour, M., and Jewell, N. P. (2016). *Causal inference in statistics: A primer*. John Wiley & Sons.
- Pearl, J. and Mackenzie, D. (2018). *The book of why: the new science of cause and effect*. Basic Books.
- Petersen, A. H. (2022). causalDisco: Tools for Causal Discovery on Observational Data. R package version 0.9.1.
- R Core Team (2024). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria.
- Ramsey, J. and Andrews, B. (2023). Py-Tetrad and RPy-Tetrad: A new Python interface with R support for tetrad causal search. *Proceedings of Machine Learning Research (PMLR), Causal Analysis Workshop Series*, 223, 40-51.
- Rubin, D. (2005). Causal inference using potential outcomes: Design, modeling, decisions. *Journal of the American Statistical Association*, 100 (469), 322–331.
- Sachs, M. C., Jonzon, G., Sjölander, A., and Gabriel, E. E. (2023). A general method for deriving tight symbolic bounds on causal effects. *Journal of Computational and Graphical Statistics*, 32(2), 567–576.
- Scheines, R., Spirtes, P., Glymour, C., Meek, C., and Richardson, T. (1998). The tetrad project: Constraint based aids to causal model specification. *Multivariate Behavioral Research*, 33(1), 65–117.
- Scutari, M., Silander, T., and Ness, R. (2024). bnlearn: Bayesian Network Structure Learning, Parameter Learning and Inference. R package version 4.9.4.
- Sekhon, J. S. (2010). The Statistics of Causal Inference in the Social Sciences. Political Science 236A and Statistics 239A Lecture Notes, Berkeley Political Science.
- Spirtes, P. and Glymour, C. (1991). An algorithm for fast recovery of sparse causal graphs. *Social science computer review*, 9(1), 62–72.

- Spirites, P., Glymour, C., and Scheines, R. (1993). *Causation, Prediction, and Search*. Lecture notes in Statistics. Springer.
- Spirites, P., Glymour, C., and Scheines, R. (2000). *Causation, prediction, and search*. MIT Press Books, 1.
- Spirites, P., Meek, C., and Richardson, T. (1999). An algorithm for causal inference in the presence of latent variables and selection bias. *Computation, causation, and discovery*, 21, 1–252
- Textor, J., Van der Zander, B., Gilthorpe, M., Liśkiewicz, M., and Ellison, G. (2016). Robust causal inference using directed acyclic graphs: the R package dagitty. *International journal of epidemiology*, 45(6), 1887–1894.
- Tikka, S., Hyttinen, A., and Karvanen, J. (2021). Causal effect identification from multiple incomplete data sources: A general search-based approach. *Journal of Statistical Software*, 99, 1–40.
- Tikka, S. and Karvanen, J. (2017). Identifying causal effects with the R package causaleffect. *Journal of Statistical Software*, 76(12), 1–30.
- Wang, X., Jiang, Y., Zhang, N., and Small, D. (2018). Sensitivity analysis and power for instrumental variable studies. *Biometrics*, 74(4), 1150–1160.

BEYANLAR:

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

Yazarların Makaleye Katkı Oranları: Birinci yazarın makaleye katkısı %100'dür.

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

Araştırma Desteği ve Teşekkür: Bu araştırma herhangi bir kurum tarafından desteklenmemiştir.

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

ISSN 2146-6173
e-ISSN 2791-7991