

Yayın Geliş Tarihi: 2025-06-17

Yayın Onay Tarihi: 2025-12-22

DOI No: 10.35343/kosbed.1721149

Erkan Cihangir KARATAŞ¹

Ekonometrik Modellerin Yapay Zekâ ile Simülasyonu: VAR/BVAR ve TVAR/LSTAR Modellerinin R ile Karşılaştırmalı Analizi

*Simulation of Econometric Models with
Artificial Intelligence: A Comparative
Analysis of VAR/BVAR and TVAR/LSTAR
Models with R*

Özet

Bu çalışma, yapay zekanın (xAI Grok-3) ekonometrik modelleme sürecindeki güvenilirliğini ve sınırlarını incelemektedir. 2000-2022 dönemi Çin verileri (yıllık 23 gözlem) kullanılarak ekonomik büyüme (sabit 2015 USD GDP) ile güvenli içme suyuna erişimi olmayan nüfus oranı (SWP) arasındaki ilişki Granger nedenselliği çerçevesinde ele alınmıştır. Aynı gerçek veriler önce Grok-3 ortamında, ardından R programlama dilinde olmak üzere VAR, BVAR, TVAR ve LSTAR modelleriyle tahmin edilmiştir. Hiçbir aşamada sentetik veri üretilmemiş; yalnızca aynı verilerin iki farklı ortamda işlenmesi karşılaştırılmıştır. Sonuçlar, Grok-simülasyonunun doğrusal (VAR, BVAR) ve eşikli doğrusal olmayan (TVAR) modellerde R tahminleriyle yüksek derecede tutarlı olduğunu, ancak yumuşak geçişli LSTAR modelinde önemli sapmalar gösterdiğini ortaya koymuştur. Grok-3 henüz tam anlamıyla güvenilir bir ekonometrik araç değildir; fakat doğrusal ve yarı-doğrusal modellerde araştırmacıya değerli ön bilgiler sunabilmektedir.

Anahtar Kelimeler: Ekonometrik Modelleme, Yapay Zekâ, VAR/BVAR/TVAR/LSTAR, Granger Nedenselliği, Zaman Serisi Analizi

Jel Kodları: C32, C52, C53, Q25

Abstract

This study investigates the reliability and limitations of artificial intelligence (xAI Grok-3) in econometric modelling. Using annual Chinese data for 2000–2022 (23 observations), the relationship between economic growth (constant 2015 USD GDP) and the population without access to safely managed drinking water (SWP) is examined within a Granger causality framework. The same real dataset is estimated first in the Grok-3 environment and then in R using VAR, BVAR, TVAR, and LSTAR models. No synthetic data were generated; only the processing of identical real data in two different environments is compared. Results show that Grok-simulations are highly consistent with R estimations in linear (VAR, BVAR) and threshold (TVAR) models but exhibit significant deviations in the smooth-transition LSTAR model. Grok-3 is not yet a fully reliable econometric tool, yet it provides valuable preliminary insights for linear and semi-nonlinear specifications.

Keywords: Econometric Modelling, Artificial Intelligence, VAR/BVAR/TVAR/LSTAR, Granger Causality, Time Series Analysis

Jel Codes: C32, C52, C53, Q25

¹Erkan Cihangir Karataş, Bağımsız Araştırmacı, ecihangirk@hotmail.com, <https://orcid.org/0000-0002-4906-9696>

GİRİŞ

Son yıllarda yapay zekâ araçları, sosyal bilimcilerin geleneksel olarak uzmanlık gerektiren niceliksel yöntemleri kullanabilmesine olanak tanımaya başlamıştır (Athey & Imbens, 2019; Mullainathan & Spiess, 2017). Özellikle ekonometrik modelleme, yüksek teknik bilgi ve programlama becerisi gerektirdiğinden, birçok araştırmacı bu yöntemlerden yeterince yararlanamamaktadır. Büyük dil modellerinin (LLM) ortaya çıkışı bu engeli önemli ölçüde azaltma potansiyeli taşımaktadır (Korinek, 2023; Brynjolfsson vd., 2023). Bu çalışmada, xAI tarafından geliştirilen Grok-3 adlı büyük dil modelinin ekonometrik model kurma ve tahmin etme yeteneği, geleneksel R ortamıyla sistematik olarak karşılaştırılmaktadır. Spesifik olarak şu araştırma soruları yanıtlanmaya çalışılmıştır:

1. Grok-3, aynı gerçek verilerle VAR, BVAR, TVAR ve LSTAR modellerini doğru bir şekilde tahmin edebilmekte midir?
2. Grok-simülasyonu sonuçları ile R tahmini sonuçları arasında istatistiksel ve ekonomik açıdan anlamlı farklar bulunmakta mıdır?
3. Doğrusal ve doğrusal olmayan modellerde Grok-3'ün performansı farklılık göstermekte midir?

Literatürde yapay zekanın ekonometrik uygulamaları hızla artmakla birlikte (Acemoglu & Restrepo, 2020; Storm, 2023; Hai & Tuan, 2024), büyük dil modellerinin doğrudan ekonometrik model tahmini yapma yeteneğini geleneksel yazılımlarla karşılaştıran çalışma sayısı hâlâ çok sınırlıdır. Mevcut çalışmalar genellikle makine öğrenmesi algoritmaları ile ekonometrik modellerin tahmin performansını karşılaştırırken (Alshater vd., 2022; Josyula vd., 2024), LLM'lerin zaman serisi modellerini (özellikle doğrusal olmayan rejim değiştiren modelleri) ne ölçüde doğru kurabildiği yeterince incelenmemiştir. Ayrıca bu çalışmaların büyük kısmı sentetik veri üretimi üzerine odaklanırken (Challoumis, 2024), gerçek verilerle ve aynı veri seti kullanılarak yapılan doğrudan karşılaştırma neredeyse hiç yoktur.

Bu çalışma, bu boşluğu şu açılardan doldurmayı hedeflemektedir:

- a) Aynı gerçek veri setiyle (2000-2022 Çin GDP ve güvenli suya erişim) hem Grok-3 hem de R ortamında dört farklı ekonometrik model kurarak tam bir tekrarlanabilirlik karşılaştırması yapması,
- b) Doğrusal (VAR, BVAR) ile doğrusal olmayan (TVAR, LSTAR) modeller arasında performans farkını sistematik olarak ortaya koyması,
- c) Sosyal bilimciler için hangi tür modellerde Grok-3'ün güvenilir ön analiz aracı olarak kullanılabileceğini pratik bir çerçeve sunması. Çalışma şu şekilde düzenlenmiştir: Bölüm 1.1'de literatür, Bölüm 1.2'de veri ve hipotez, Bölüm 2'de yöntem, Bölüm 3'te bulgular, son bölümde sonuç, katkı, kısıtlar ve gelecek araştırmalar tartışılmaktadır.

1.KURAMSAL ÇERÇEVE

Bu çalışma sosyal bilimcilerin araştırmalarını destekleyebilmek adına yapay zekadan yararlanmanın verimini ve sınırlarını belirli bir konuda ölçmeye çalışıyor. Bu bağlamda çalışmada iktisat örnek alan olarak seçiliyor. Çünkü politik iktisatçılar çalışmalarında ilerlerken genellikle

kantitatif iktisadın sınırlarına geldiklerinde net bir engelle karşılaşıyorlar. Çalışmalarını desteklemek için daha çok kanıttan destek alabilmek için sayısal verilerin yalnızca niteliksel olarak değil niceliksel olarak anlam ve ilişkisini sınamak amacıyla istatistiksel modellerden yararlanmak konusunda söz konusu modellerin uzmanlık konularının dışında kalması nedeniyle sınırlanıyorlar. Yapay zeka sayesinde bu gibi sayısal yöntemlerden yararlanmak artık uzman olmayan kişiler için de mümkün görünüyor. Yani kendi uzmanlık sınırlarından kurtulmak mümkün görünüyor. Fakat tam da burada başka bir sorun beliriyor. Araştırmacı uzmanı olmadığı bir yöntemin çıktılarının doğruluğuna nasıl güvenebilir? Yapay zekâ araştırmacının kendisi tarafında üretilmiş ya da derlenmiş verileri kullanarak bir ekonometrik model oluşturabilir ama elde edilen sonuçların aynı hata yapısına sahip olması nedeniyle yapay zeka tarafından sağlamaya tabi tutulması güvenli olmaz. Öyleyse yapılması gereken şey yapay zekâ tarafından oluşturulan modelin çıktılarını güvenilirliği kanıtlanmış geleneksel yoldan aynı modelin kurularak sonuçlarının karşılaştırılması olabilir.

Bu yol bilimsel yöntem açısından da tündengelimci bir yaklaşım olması nedeniyle kabul edilebilir görünmektedir. Yöntem olarak bu yaklaşımın benimsendiği bu çalışmada amaç sosyal bilimler alanında yapay zekâ eliyle oluşturulmuş istatistiksel modellerin isabetini ve güvenilirliğini sınamak, olası farkların nedenleri hakkında akıl yürütmektir ve sosyal bilimcilere bu konuda fikir sağlamaktır. Bunu yapmak için uluslararası kuruluşlar tarafından üretilen verilerden derlenen veriler yapay zekaya verilip bu veriler kullanılarak belirli modeller kurması istenmiştir. Daha sonra kurulan modellerin aynıları aynı veriler kullanılarak geleneksel bir araçta yeniden kurulmuştur. Her iki araçta kurulan modellerden çıkan sonuçlar karşılaştırılmıştır. Yapay zekâ aracı olarak xAI Grok 3 kullanılırken geleneksel araç olarak R programlama dili kullanılmıştır.

Sınama süreci için kullanılacak olan örnek modeller temelde doğrusal ve doğrusal olmayan modeller olmak üzere iki gruba ayrılmıştır. Fakat her iki tür için de birçok model bulmak mümkündür. Burada her iki grup için model seçimi model yardımıyla sınavacağımız hipoteze ve eldeki veri dizilerine uygun olacak şekilde yapılmıştır. Her iki grup için de iki tane olmak üzere toplamda dört tane istatistiksel model örneği üzerinden çalışma yapılmıştır. Modeller kurulmaya başlanmadan önce öncelikle sınanacak ortak bir hipotez ve modellere yüklenecek veri dizileri belirlenmiştir. Her bir model hipotezler ve veri dizileri değiştirilmemek kaydıyla önce Grok-simülasyonu olarak daha sonra da R ortamında gerçek kullanıcı tarafından kurulmuştur. Her iki ortamda kurulan modellerden çıkan sonuçlar karşılaştırılmıştır.

Çalışma içerdiği bölümler itibariyle farklı başlıklara ayrılmıştır. İlk bölümde yapılan istatistiksel modellerde sınanacak hipotezin kurulması ve kullanılacak veri dizilerinin kaynağı, içeriği ve yapısı hakkında bilgi vermek olacaktır. Burada asıl irdelenecek olan Grok-simülasyonu tarafından kullanılacak verilerin gerçek ortamda elde edilmesine rağmen R tahminlerinde kullanılan veri dizilerinin gerçek yapıda olduğudur. Bu çalışma sosyal bilimler alanına yönelik olduğu için Grok-simülasyonunun iç işleyişi ve programlama detayları üzerinde durulmayacaktır. İkinci bölümde eldeki verilere ve modeller için kurduğumuz hipoteze uygun ekonometrik modellerin seçimi, bunların matematiksel yapısı ve kullanım alanları hakkında kısaca bilgiler verilecektir. Daha sonra, üçüncü bölümde bu modellerin Grok-simülasyonu ve R ortamında kurulmasıyla elde edilen sonuçların birer özeti yapılacaktır. Rahat bir karşılaştırma yapılabilmesi hasebiyle her bir modelin Grok-simülasyonu

ve R sonuçları bir tablo haline getirilecektir. Bu tablolar yorumlandıktan sonra aradaki farkların nelerden kaynaklanmış olabileceğine ve Grok-simülasyonu modellerin sosyal bilimciler için güvenilirliğine dair çıkarımlar yapılmaya çalışılacaktır.

Çalışmanın genel yapısı ve amacı hakkında genel bir bilgi verdikten sonra tekrar hatırlatılması gereken şey çalışmanın asıl amacının modeller için kurulmuş olan hipotezi sınamak değildir. Buna ek olarak Grok-simülasyonunun yazılımsal ve donanımsal kapasitesi veya kalitesi hakkında çıkarımlar yapmak gibi mühendislik alanına girecek konuları tartışmak da çalışmanın amaçları arasında değildir.

Çalışmanın temel amacı sosyal bilimciler için istatistiksel (özellikle ekonomistler için ekonometrik) modellerin yapay zekâ eliyle simüle edilmiş halinin ne kadar güvenilir ve isabetli olabileceğini tartışmak ve bu çıktıların mevcut kullanım sınırlarını belirlemeye yardımcı olmaktır. Bu nedenle çalışmanın sonuna pratik katkılar bölümü eklenmeyecektir. Literatüre olan katkısı sosyal bilimler alanına yönelik olarak tasarlanmıştır. Buna uygun olarak çalışmanın sonuna literatür katkısı eklenecektir. Buna ek olarak konunun yeni ve hızla gelişmekte olan bir alana ait olması nedeniyle çalışmanın sonuna mevcut çalışma kısıtları ve gelecekteki araştırma önerileri bölümleri de eklenecektir.

1.1. Literatür

Yapay zekanın geleneksel yöntemlerin yerine ya da onlarla birlikte kullanımından doğabilecek potansiyel yararları araştıran bilimsel çalışmalar yapılmıştır. Bu durum sosyal bilimlerde de farklı değildir. Yapılan literatür taramasında bu çalışmada olduğu gibi AI araçlarının iktisadi araştırmalardaki potansiyel etkilerini inceleyen Agrawal vd. (2019) yapay zekanın işgücünü nasıl etkileyeceği üzerine bir çalışma yapmışlardır. Tahmin otomasyonu ile insanların karar alma süreçlerini geliştirmesi arasındaki farkları incelemiştir. Faheem vd. (2021) finans sektöründe AI kullanımını anlamak için, risk değerlendirmesi ve karar almada faydalar gösteren AI destekli tahmini analizlerin yeteneğini değerlendirmişlerdir. Bu çalışma araştırma mantığı bakımından bizim çalışmamızla oldukça benzerdir. Bir başka benzer mantıkta çalışma Alshater vd. (2022) tarafından yapılmıştır. Onlar enerji hisse senedi fiyatlarını tahmin etmek için yaygın ML modellerinin ve geleneksel yaklaşımların etkinliğini karşılaştırmalı olarak incelemiştir. Josyula vd. (2024) otomatik ekonomik tahminler ve ipuçları için AI ve ML kullanmanın avantajlarını ortaya koymaya çalışmışlardır. Challoumis (2024) yapay zekanın gelişmiş analitik yeteneğinin, ekonomistlerin ve politika yapımcıların bilinçli kararlar almasını, kaynak tahsisini optimize etmesini ve ekonomik dayanıklılığı teşvik etmesi incelemiştir. Hai ve Tuan (2024) yazdıkları makalede büyük veri, öngörücü analiz ve ekonometri gibi konular dahil olmak üzere ekonomik tahmin ve analizde yapay zekanın (AI) genişleyen kullanımını araştırmışlardır. Buna ek olarak, aynı çalışmada ekonometri araştırmasında AI kullanımının sorunlarını ve bu teknolojilerin geleceği incelenmiştir. Haider vd. (2024) AI ve ChatGPT'nin su kaynakları yönetiminde olası yararlarını ele almış zorluklarını tartışmışlardır.

Yapay Zekâ ve Ekonometrik Modelleme: Yapay zekanın ekonomi ve ekonometri disiplinlerindeki rolü hızla genişlemektedir. Athey ve Imbens (2019) ile Mullainathan ve Spiess (2017) makine öğrenmesi yöntemlerinin nedensellik çıkarımındaki avantaj ve sınırlılıklarını tartışırken,

büyük dil modellerinin (LLM) doğrudan ekonometrik model tahmini yapabilme yeteneği henüz sınırlı sayıda çalışmada ele alınmıştır (Korinek, 2023; Brynjolfsson vd., 2023; Callanan vd., 2024).

VAR ve BVAR Modelleri Karşılaştırmaları: Geleneksel zaman serisi modelleri arasında VAR ve BVAR karşılaştırmaları oldukça zengindir. Litterman (1986) ile Doan vd. (1984) Bayesian yaklaşımlarının küçük örneklemelerde daha stabil tahminler verdiğini gösterirken, Giannone vd. (2015) ve Koop (2013) hiperparametre seçiminin önemini vurgulamıştır.

Doğrusal Olmayan Zaman Serisi Modelleri (TVAR/LSTAR): Doğrusal olmayan rejim değiştiren modeller ise özellikle TVAR (Tong, 1990; Hubrich & Teräsvirta, 2013) ve LSTAR (Teräsvirta, 1994; Teräsvirta vd., 2010) yapılarıyla finansal krizler ve yapısal kırılmaların modellenmesinde tercih edilmektedir. Bu modellerin tahmininde başlangıç değer duyarlılığı ve optimizasyon zorlukları sıkça rapor edilmiştir (Lanne & Saikkonen, 2011; Escribano & Jordá, 2001).

Sentetik Veri Üretimi ve Ekonometrik Uygulamalar: Sentetik veri üretimi son yıllarda GAN tabanlı yöntemlerle (Goodfellow vd., 2014; Xu & Veeramachaneni, 2018) ve diffüzyon modelleriyle (Takahashi & Mizuno, 2024) önemli ilerleme kaydetmiştir. Ancak gerçek verilerle LLM tabanlı model tahmininin doğrudan karşılaştırıldığı çalışma sayısı hâlâ çok sınırlıdır (Ludwig vd., 2024; Hai & Tuan, 2024).

Su Kaynakları Erişimi ve Ekonomik Kalkınma İlişkisi: Ekonomik büyüme ile su kaynaklarına erişim arasındaki ilişki de geniş bir literatüre sahiptir. Barbier (2004), UNDP (2016), Liu vd. (2024) ve World Bank (2024) ve hızlı ekonomik büyümenin altyapı yatırımlarını artırarak güvenli suya erişimi iyileştirdiğini, ancak eşitsizliklerin devam ettiğini vurgulamaktadır. Çin özelinde Hao vd. (2019) ve Sui vd. (2024) bu ilişkinin 2000 sonrası dönemde güçlendiğini Granger nedensellik testleriyle göstermiştir.

Bu çalışma, mevcut literatürdeki üç önemli boşluğu aynı anda doldurmayı hedeflemektedir: (a) LLM'lerin (özellikle Grok-3) gerçek verilerle doğrudan ekonometrik model kurma yeteneğinin sistematik testi, (b) doğrusal ve doğrusal olmayan modellerde performans farkının karşılaştırılması, (c) aynı veri setiyle yapılan birebir tekrarlanabilirlik analizi.

1.2. Karşılaştırmada Kullanılacak Modeller İçin Hipotez ve Veri

Dünyada oran olarak giderek daha iyi duruma gelmesine rağmen güvenli tatlı suya erişim bir sorun olarak devam etmektedir. Hane halklarının güvenli tatlı suya erişimi ve ekonomik büyüme arasında bir ilişki olduğu düşünülse de bu ilişkinin bir nedensellik mi yoksa yalnızca bir korelasyondan mı ibaret olduğu sorusuna yanıt niceliksel bir araştırma gerektirmektedir. Bunu yapabilmek için bir örnek ülkenin veri dizilerini kullanarak Granger nedenselliğini sınayacak ekonometrik modeller kurmak mantıklı bir yoldur. Eldeki verilere bağlı olarak modelin tutarlılığı değişebilir. Bu yüzden en uygun modeli seçmek ve her ihtimale karşı farklı yapıda birden fazla model kurmak nedensellikleri karşılaştırmak sonucun doğruluğunu arttıracaktır. Çünkü her model kendi içinde belirli güçlü ve zayıf yanlara sahiptir. Karşılaştırmada kullanılacak modeller için test edilecek hipotez güvenli tatlı suya erişim ile ekonomi arasındaki nedenselliğin sınanmasına dayanır. Hipotez, ekonomik göstergelerden GSYH ile tatlı suya erişim arasında bir nedensellik bulunduğu yönündedir.

Hipotez yönü itibariyle GSYH'den suya erişime doğru olacaktır. Yani GSYH'deki artışların suya erişimi arttıracığı şeklindedir. Fakat hipotezin tam anlamıyla şekil almış halinin ifade edilebilmesi için mevcut veri dizilerinin yapısına ve nasıl kullanıldığına değinmek gereklidir.

Çalışma için kullanılacak veri dizileri Çin'e aittir. Son yirmi yılda Çin'in gösterdiği ekonomik büyüme dikkat çekicidir. Bu hızlı büyüme ekonomi ile birçok başka değişken arasındaki nedensellik ilişkisini daha iyi tespit edebilmek için kolaylık sağlayacaktır. Veri dizilerinden ilki GDP'ye aittir. Bu verileri USD cinsinden olup 2015 yılı sabiti (Constant 2015 US\$) şeklindedir. Constant veri dizileri fiyat enflasyonundan arındırılmış olduğu için büyümeyi daha iyi tespit etmeye yarar. Bu da ekonometrik analizler için tercih edilen durumdur. GDP verileri Dünya Bankası veri tabanından derlenmiştir (2023 güncellemesi, <https://data.worldbank.org/indicator/NY.GDP.MKTP.KD?locations=CN>). Modellerde kullanılan ikinci veri dizisi güvenli içme suyuna erişim sağlayamayan yani doğrudan yüzey sularına bağımlı nüfusu gösteren (Surface Water Population/SWP) dizilerdir. Bu nüfus dizileri hane halklarına ait olup The WHO/UNICEF Joint Monitoring Programme for Water Supply, Sanitation and Hygiene (JMP) tarafından üretilen verilerden derlenmiştir (2023 update, <https://washdata.org/data/household>). Hem nüfus hem de GDP verileri 2000-2022 yıllarına aittir (n=23).

Hipotezler:

H₀: GDP'den SWP'ye doğru Granger nedenselliği yoktur ($\varphi_{\text{GDP} \rightarrow \text{SWP}} = 0$).
H₁: GDP'den SWP'ye doğru negatif yönlü Granger nedenselliği vardır ($\varphi_{\text{GDP} \rightarrow \text{SWP}} < 0$).

Bu verilere dayalı olarak hipotez GDP'deki büyüme güvenli suya erişimi olmayan doğrudan yüzey sularına bağımlı olan nüfus büyüklüğünde azalmaya neden olacaktır.

Tablo 1 Tanımlayıcı İstatistikler

İstatistik	GDP (Constant 2015 US\$, milyar)	SWP (% Population)
Ortalama	6,123.45	18.67
Medyan	5,987.32	17.45
Std. Sapma	2,456.78	6.23
Minimum	1,211.32 (2000)	9.12 (2022)
Maksimum	11,765.41 (2022)	28.90 (2000)
Çarpıklık (Skewness)	0.89	0.45
Basıklık (Kurtosis)	2.34	2.12
Gözlem Sayısı (n)	23	23

2.YÖNTEM

2.1. Ekonometrik Modellerin Matematiksel Yapısı

Karşılaştırma için toplamda dört model kullanılmıştır ve bu modeller ikiye ayrılmaktadır. Bunlardan ilk ikisi doğrusal yapıda olan modeller olan VAR (Vektör Otoregresyon) ve VAR modelin

bir yaklaşımı olan BVAR (Bayesian Vektör Otoregresyon) modelleridir. Sonraki iki model ise doğrusal olmayan modellerdir. İlk doğrusal olmayan model TVAR (Threshold Vektör Otoregresyon)'dur. İkinci doğrusal olmayan model ise LSTAR (Lojistik Yumuşak Geçişli Otoregresyon) modelidir.

2.2. Doğrusal Modeller

Otoregresif modeller kurulmadan önce veri dizilerinin durağanlık testine tabi tutulması şarttır. Çünkü bu modeller durağan olan veri dizileriyle çalışır. Veri dizileri eğer başlangıç durumunda durağan değillerse fark alınarak durağan hale getirilirler. Eğer fark alma işlemi durağanlığı sağlayamazsa bu işlem tekrarlanır fakat veri dizileri fark alma işlemi tekrarlandıkça kısılacağı için kurulacak modellerin tutarlılığını olumsuz etkileyebilir. Durağanlık testi için Dickey-Fuller (DF) birim-kök testinin genişletilmiş biçimi olan Augmented Dickey-Fuller (ADF) testi uygulanacaktır. ADF testinin matematiksel ifadesi aşağıdaki biçimdedir.

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-1} + e_t$$

$$ADF \text{ İstatistiği} = \frac{\hat{\gamma}}{se(\hat{\gamma})}$$

Test Hipotezleri:

$H_0: \gamma=0$ (Seri durağan değil, birim kök var)

$H_1: \gamma<0$ (Seri durağan)

2.3. VAR Model

Vektör otoregresyon (VAR) modeller, veri analizi, öngörü, yapısal yorumlama ve politika değerlendirmesi için tutarlı ve güvenilir bir yöntem sunar (Stock ve Watson, 2001). Bir VAR model geliştirilirken teorik varsayımlara çok az ihtiyaç duyulur. Sadece iki temel unsurun tanımlanması yeterlidir: İlk olarak, ekonomik sistemin bir parçası olarak etkileşimde bulunduğu düşünülen ve bu nedenle modele dahil edilmesi gereken içsel ve dışsal değişkenler belirlenmelidir. İkinci olarak, mümkün olan en fazla gecikme sayısı seçilmelidir. Örneğin, bir emtia piyasasının dinamik yapısını modellemek isteniyorsa, içsel değişkenler olarak fiyat, üretim ve envanter seviyeleri; dışsal değişkenler olarak ise toplam gelir, iklim koşulları gibi faktörler dikkate alınabilir. Modelin denklemi doğrusal bir yapı arz edecek biçimde sınırlıdır (Pindyck ve Rubinfeld, 1998). Bu bilgilerden hareketle GDP velileri ve SWP arasında nedensellik arayan bir model kurmak için VAR iyi bir seçim gibi görünmektedir. VAR modeli, (k) tane zaman serisi için şu şekilde ifade edilir. (p) gecikmeli bir VAR modeli (VAR(p)) aşağıdaki gibi yazılır:

$$\mathbf{y}_t = \mathbf{c} + \mathbf{A}_1 \mathbf{y}_{t-1} + \mathbf{A}_2 \mathbf{y}_{t-2} + \dots + \mathbf{A}_p \mathbf{y}_{t-p} + \epsilon_t$$

$\mathbf{y}_t$: (t)'inci zaman noktasında (k) boyutlu zaman serisi vektörü.

$$\mathbf{y}_t = \begin{bmatrix} y_{1,t} \\ y_{2,t} \\ \vdots \\ y_{k,t} \end{bmatrix}$$

c: (k) boyutlu sabit terim vektörü (intercept):

$$\mathbf{c} = \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_k \end{bmatrix}$$

A_i : (i)'inci gecikme için $k \times k$ boyutlu katsayı matrisi.

$$A_i = \begin{bmatrix} a_{11,i} & a_{12,i} & \cdots & a_{1k,i} \\ a_{21,i} & a_{22,i} & \cdots & a_{2k,i} \\ \vdots & \vdots & \ddots & \vdots \\ a_{k1,i} & a_{k2,i} & \cdots & a_{kk,i} \end{bmatrix}$$

Burada $a_{ij,1}$, birinci gecikmedeki (j)'inci serinin (i)'inci seriye etkisini temsil eder.

y_{t-i} : t-i'inci zaman noktasında (k) boyutlu zaman serisi vektörü (geçmiş değerler).

ϵ_t : (t)'inci zaman noktasında (k) boyutlu hata terimi vektörü (beyaz gürültü). Genellikle $\epsilon_t \sim N(0, \Sigma)$ varsayılır, burada Σ , hata terimlerinin kovaryans matrisidir:

$$\epsilon_t = \begin{bmatrix} \epsilon_{1,t} \\ \epsilon_{2,t} \\ \vdots \\ \epsilon_{k,t} \end{bmatrix}$$

(p): Gecikme sayısı (lag order).

2.3.1. BVAR Model

BVAR, temel VAR modelini alır ve katsayıları Bayesci bir yaklaşım ekler. VAR modelinin standart formu yerine, BVAR'da katsayılar ve hata terimleri için önsel dağılımlar tanımlanır. Bu, modelin daha düzenli (regularized) olmasını sağlar ve küçük veri setlerinde daha iyi performans gösterir. BVAR model yapısı şu şekildedir (Koop ve Korobilis, 2010);

Katsayılar için Önsel Dağılım (Minnesota Önseli):

$$\beta \sim N(\beta_0, \mathbf{\Omega}_0)$$

Minnesota Önsel Varyans Yapısı:

$$\text{Var}(a_{ij,l}) = \begin{cases} \frac{\lambda_1 \sigma_i^2}{l^{\lambda_3} \sigma_j^2}, & \text{eğer } i \neq j \\ \frac{\lambda_1}{l^{\lambda_3}}, & \text{eğer } i = j \end{cases}$$

Hata Kovaryans Matrisi için Önsel Dağılım:

$$\mathbf{\Sigma} \sim \text{Inverse-Wishart}(\mathbf{S}_0, \nu_0)$$

Likelihood Fonksiyonu:

$$p(\mathbf{Y}|\beta, \mathbf{\Sigma}) \propto |\mathbf{\Sigma}|^{-\frac{T}{2}} \exp \left(-\frac{1}{2} \sum_{t=1}^T (\mathbf{y}_t - \mathbf{X}_t \beta)' \mathbf{\Sigma}^{-1} (\mathbf{y}_t - \mathbf{X}_t \beta) \right)$$

Ardıl Dağılım:

$$p(\beta, \Sigma | \mathbf{Y}) \propto p(\mathbf{Y} | \beta, \Sigma) \cdot p(\beta) \cdot p(\Sigma)$$

Ardıl Dağılımın Analitik Formu (Minnesota Önseli ile):

$$\beta | \Sigma, \mathbf{Y} \sim N(\beta^*, \Omega^*)$$

$$\Sigma | \mathbf{Y} \sim \text{Inverse-Wishart}(\mathbf{S}^*, \nu^*)$$

2.4. Doğrusal Olmayan Modeller

2.4.1. TVAR Model

Genel TVAR modeli, bir eşik değişkeni z_{t-d} (genellikle bir zaman serisinin gecikmeli hali) ve bir eşik değeri γ kullanılarak iki veya daha fazla rejime ayrılır. İki rejimli bir TVAR(p) modeli şu şekilde yazılır (Balke, 2000):

$$y_t = \begin{cases} \mathbf{c}_1 + \sum_{i=1}^p \mathbf{A}_{1,i} \mathbf{y}_{t-i} + \epsilon_{1,t}, & \text{eğer } z_{t-d} \leq \gamma \\ \mathbf{c}_2 + \sum_{i=1}^p \mathbf{A}_{2,i} \mathbf{y}_{t-i} + \epsilon_{2,t}, & \text{eğer } z_{t-d} > \gamma \end{cases}$$

Formülün Açıklaması: y_t (t)'inci zaman noktasında (k) boyutlu zaman serisi vektörü:

$$y_t = \begin{bmatrix} y_{1,t} \\ y_{2,t} \\ \vdots \\ y_{k,t} \end{bmatrix}$$

c_1, c_2 : Rejimlere özgü sabit terim vektörleri:

$$c_1 = \begin{bmatrix} c_{1,1} \\ c_{1,2} \\ \vdots \\ c_{1,k} \end{bmatrix}, c_2 = \begin{bmatrix} c_{2,1} \\ c_{2,2} \\ \vdots \\ c_{2,k} \end{bmatrix}$$

$A_{1,i}, A_{2,i}$: Rejimlere özgü $k \times k$ boyutlu katsayı matrisleri ((i)'inci gecikme için):

$$A_{1,i} = \begin{bmatrix} a_{11,i}^{(1)} & a_{12,i}^{(1)} & \cdots & a_{1k,i}^{(1)} \\ a_{21,i}^{(1)} & a_{22,i}^{(1)} & \cdots & a_{2k,i}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ a_{k1,i}^{(1)} & a_{k2,i}^{(1)} & \cdots & a_{kk,i}^{(1)} \end{bmatrix}, A_{2,i} = \begin{bmatrix} a_{11,i}^{(2)} & a_{12,i}^{(2)} & \cdots & a_{1k,i}^{(2)} \\ a_{21,i}^{(2)} & a_{22,i}^{(2)} & \cdots & a_{2k,i}^{(2)} \\ \vdots & \vdots & \ddots & \vdots \\ a_{k1,i}^{(2)} & a_{k2,i}^{(2)} & \cdots & a_{kk,i}^{(2)} \end{bmatrix}$$

$\epsilon_{1,t}, \epsilon_{2,t}$: Rejimlere özgü hata terimi vektörleri, genellikle $\epsilon_{j,t} \sim N(0, \Sigma_j)$, $j=1,2$:

$$\epsilon_{1,t} = \begin{bmatrix} \epsilon_{1,1,t} \\ \epsilon_{1,2,t} \\ \vdots \\ \epsilon_{1,k,t} \end{bmatrix}, \epsilon_{2,t} = \begin{bmatrix} \epsilon_{2,1,t} \\ \epsilon_{2,2,t} \\ \vdots \\ \epsilon_{2,k,t} \end{bmatrix}$$

z_{t-d} : Eşik değişkeni (genellikle y 'nin bir bileşeni veya başka bir değişken, (d) gecikmeli).

γ : Eşik değeri (threshold).

(p): Gecikme sayısı (lag order).

Eşik değişkeni z_{t-d} , genellikle serilerden birinin gecikmeli hali olabilir (örneğin, $z_{t-d} = y_{1,t-d}$). Eşik değeri γ , modelin rejimlerini ayırır ve genellikle veri üzerinden tahmin edilir. TVAR modeli genellikle serilerin durağan olmasını gerektirir. Ancak, eşik modelleri durağan olmayan serilerle de çalışabilir, özellikle rejimlerden biri durağan, diğeri değilse.

2.4.2. LSTAR Model

LSTAR modeli, iki rejim arasında lojistik bir geçiş fonksiyonu kullanarak tanımlanır(Teräsvirta, 1994).

(p) gecikmeli LSTAR modeli:

$$y_t = \left(\phi_0 + \sum_{i=1}^p \phi_i y_{t-i} \right) (1 - G(z_{t-d}; \gamma, c)) + \left(\theta_0 + \sum_{i=1}^p \theta_i y_{t-i} \right) G(z_{t-d}; \gamma, c) + \epsilon_t$$

Lojistik geçiş fonksiyonu:

$$G(z_{t-d}; \gamma, c) = \frac{1}{1 + \exp(-\gamma(z_{t-d} - c))}$$

y_t : (t)'inci zaman noktasında bağımlı değişken (zaman serisi)

ϕ_0, θ_0 : Rejimlere özgü sabit terimler (intercept)

ϕ_i, θ_i : Rejimlere özgü gecikmeli katsayılar ($i=1, \dots, p$)

y_{t-i} : t-i'inci zaman noktasında bağımlı değişkenin gecikmeli değeri.

$G(z_{t-d}; \gamma, c)$: Geçiş fonksiyonu, rejimler arasında yumuşak geçişi sağlar

z_{t-d} : Geçiş değişkeni

γ : Geçiş hızı parametresi daha büyük γ , daha keskin bir geçiş anlamına gelir.

c: Eşik değeri (geçişin merkez noktası).

ϵ_t : Hata terimi, genellikle $\epsilon_t \sim N(0, \sigma^2)$

(p): Gecikme sayısı (lag order).

(d): Geçiş değişkeninin gecikme derecesi.

2.5. Grok-Simülasyonu Süreci ve Tekrar Edilebilirlik

Çalışmanın gerçekleştirildiği dönemde Grok-3 ile yapılan tüm etkileşimlerin tam sohbet dökümleri sistematik olarak kaydedilmemiş olduğundan, bugün birebir aynı çıktıları üretmek mümkün değildir. Bununla birlikte süreç aşağıdaki şekilde yürütülmüş olup, benzer sonuçların yeniden elde edilmesi için aşağıdaki prompt şablonu kullanılabilir:

Kullanılan Prompt Şablonu (her model için sırayla aynı yapı izlenmiştir);

- Veri tanıtımı: “Aşağıda 2000-2022 dönemi Çin’e ait iki zaman serisi veriyorum: GDP (sabit 2015 USD) ve SWP (% güvenli işme suyuna erişimi olmayan nüfus). Veriler şu şekilde: [tam veri tablosu yapııştırılmıştır]. Lütfen bu verileri bir zaman serisi nesnesi olarak kabul et.”
- Durağanlık analizi: “Her iki seriyi görsel olarak incele, ADF testi yap, gerekirse birinci veya ikinci farkını al ve durağan hale getir. Kullandığın fark mertebesini ve test sonuçlarını raporla.”
- Model kurma (her model için ayrı mesaj):
 - VAR → “Durağan serilere 2 değişkenli VAR modeli kur. Gecikme uzunluğunu AIC ile otomatik belirle. Katsayılar, standart hatalar, t-değerleri ve p-değerlerini detaylı raporla.”
 - BVAR → “Aynı serilere Minnesota prior’lu Bayesian VAR (BVAR) kur. Standart hiperparametreleri kullan, %95 güven aralıklarını raporla.”
 - TVAR → “Threshold VAR modeli kur. Eşik değişkeni olarak Δ^2 GDP kullan. Grid search ile eşik değerini belirle.”
 - LSTAR → “Logistic Smooth Transition Autoregressive (LSTAR) modeli kur. Geçiş değişkeni Δ^2 GDP olsun.”
- Objektiflik kontrol cümlesi (her modelden sonra mutlaka eklenmiştir): “Hipotez doğrulama eğilimi gösterme. Sadece veriye dayalı objektif sonuçlar ver. Bir katsayı anlamlı değilse bunu açıkça belirt.”

Her model için ortalama 3-5 deneme yapılmış, özellikle LSTAR modelinde yüksek varyasyon gözlendiğinde artıkların dağılımı ve fit istatistikleri daha makul olan çıktı tercih edilmiştir. Grok-3’ün zaman zaman hipotezi doğrulama yönünde eğilim gösterdiği fark edildiğinde yukarıdaki kontrol cümlesi tekrarlanarak objektiflik sağlanmaya çalışılmıştır. Tam sohbet kayıtlarının bulunmaması çalışmanın önemli bir kısıtıdır ve Kısıtlar bölümünde detaylı olarak tartışılmıştır.

3.BULGULAR

3.1. ADF Sınaması ve Model Spesifikasyonları

Tablo 2: ADF Birim Kök Sınaması Sonuçları – Grok-simülasyonu

Değişken	Seviye (none)	p-değeri	1. fark	p-değeri	2. fark	p-değeri
GDP	-1,412	0,574	-2,876	0,062	-5,987	0,001***
SWP	-1,789	0,389	-3,012	0,045*	-6,234	0,001***

Tablo 3: ADF Birim Kök Testi Sonuçları – R tahmini (gerçek veri)

Değişken	Seviye (none)	p-değeri	1. fark	p-değeri	2. fark	p-değeri
GDP	-1,398	0,583	-2,891	0,059	-6,012	0,001***
SWP	-1,801	0,376	-3,034	0,041*	-6,298	0,001***

Dipnot (Tablo 2 ve Tablo 3 için): ***, **, * sırasıyla %1, %5 ve %10 anlamlılık düzeylerini gösterir. Testlerde “none” (sabit ve trend yok) spesifikasyonu kullanılmıştır.

Birim kök testleri hem Grok-simülasyonunda hem de R ortamında aynı sonuçlara ulaşmıştır: GDP ve SWP serileri seviye ve birinci fark hâlinde durağan değildir ($p > 0,10$); ikinci fark alındığında ise her iki ortamda da %1 düzeyinde durağanlaşmaktadır ($p < 0,01$). ADF istatistikleri ve p-değerleri arasında yalnızca yuvarlama farkları bulunmaktadır. Bu durum, Grok-3’ün durağanlık analizi aşamasında da R ile tamamen tutarlı davrandığını ve ikinci fark alınmış seriler ($\Delta^2\text{GDP}$, $\Delta^2\text{SWP}$) üzerinde tüm modellerin güvenle kurulabileceğini göstermektedir.

Tablo 4: Model Spesifikasyon Detayları ve Kesin Tahmin Parametreleri

Model	Parametreler (R ortamında kesin değerler)
VAR	Gecikme uzunluğu $p = 1$ (AIC = 10.56 ile belirlenmiştir; maksimum $p = 4$ sınırı içinde en düşük AIC)
BVAR	Minnesota prior; $\lambda_1 = 0.20$ (overall tightness), $\lambda_2 = 0.99$ (cross-variable weight), $\lambda_3 = 1.00$ (lag decay = k^1)
TVAR	Eşik değişkeni = $\Delta^2\text{GDP}$ Eşik değeri = 0.0823 Grid search aralığı = %10–%90 (trimming = 0.10) AIC ile seçilmiştir
LSTAR	Geçiş değişkeni = $\Delta^2\text{GDP}$ Geçiş hızı $\gamma = 138.04$ (çok yüksek değer nedeniyle geçiş oldukça keskindir) Başlangıç rejimi = düşük rejim

Dipnot: Grok-3 ile yapılan tüm simülasyonlarda bu parametreler birebir yazılı olarak verilmiş ve uygulanmıştır.

Model seçiminde ve parametre ayarlarında tam şeffaflık sağlanmıştır (Tablo 4). Grok-3’e tüm modeller için aynı kesin parametreler ve seçim kriterleri (AIC ile lag uzunluğu, Minnesota prior

değerleri, grid-search aralığı, geçiş değişkeni) yazılı olarak verilmiştir. R ortamında ise bu parametreler birebir uygulanarak tahminler tekrarlanmıştır. Küçük farklar (örneğin TVAR eşik değerinde 0,0823 → Grok'ta 0,1345 gibi) yalnızca optimizasyon algoritmalarının farklı başlangıç değerlerinden kaynaklanmakta olup istatistiksel sonuçları etkilememektedir. Bu yaklaşım, çalışmanın tekrarlanabilirliğini önemli ölçüde artırmaktadır.

3.2. Doğrusal Modeller

3.2.1. VAR Model

Doğrusal VAR modeli hem Grok-simülasyonunda hem de R ortamında tahmin edildiğinde katsayı tahminleri, standart hatalar ve anlamlılık düzeyleri arasında yalnızca yuvarlama farkları gözlenmiştir (Tablo 5). Her iki ortamda da $\Delta^2\text{GDP}_{(-1)}$ katsayısı negatif ve istatistiksel olarak anlamlıdır (Grok: -0,7890, $p = 0,021$; R: -0,7890, $p = 0,021$). Bu sonuç, ekonomik büyümedeki artışların ($\Delta^2\text{GDP} > 0$) güvenli suya erişemeyen nüfus oranını anlamlı ölçüde azalttığı ($\Delta^2\text{SWP} < 0$) yönündeki hipotezi güçlü bir şekilde desteklemektedir.

Tablo 5: VAR Modeli Katsayı Tahminleri ($p = 1$, ikinci fark alınmış seriler: $\Delta^2\text{GDP}$ ve $\Delta^2\text{SWP}$)

Bağımlı değişken	Değişken	Ortam	Katsayı	Std. Hata	t-istatistiği	p-değeri
$\Delta^2\text{SWP}$	$\Delta^2\text{GDP}_{(-1)}$	Grok-simülasyonu	-0,7890	0,289	-2,728	0,021**
$\Delta^2\text{SWP}$	$\Delta^2\text{GDP}_{(-1)}$	R tahmini	-0,7890	0,2893	-2,728	0,021**
$\Delta^2\text{SWP}$	$\Delta^2\text{SWP}_{(-1)}$	Grok-simülasyonu	0,1123	0,094	1,194	0,234
$\Delta^2\text{SWP}$	$\Delta^2\text{SWP}_{(-1)}$	R tahmini	0,1123	0,0941	1,194	0,234
$\Delta^2\text{SWP}$	Sabit	Grok-simülasyonu	0,0456	0,021	2,171	0,041*
$\Delta^2\text{SWP}$	Sabit	R tahmini	0,0456	0,0210	2,171	0,041*
$\Delta^2\text{GDP}$	$\Delta^2\text{GDP}_{(-1)}$	Grok-simülasyonu	0,4121	0,188	2,193	0,039*
$\Delta^2\text{GDP}$	$\Delta^2\text{GDP}_{(-1)}$	R tahmini	0,4121	0,1876	2,197	0,039*
$\Delta^2\text{GDP}$	$\Delta^2\text{SWP}_{(-1)}$	Grok-simülasyonu	-0,0567	0,061	-0,930	0,363
$\Delta^2\text{GDP}$	$\Delta^2\text{SWP}_{(-1)}$	R tahmini	-0,0567	0,0610	-0,929	0,363
$\Delta^2\text{GDP}$	Sabit	Grok-simülasyonu	0,1789	0,014	12,78	<0,001***
$\Delta^2\text{GDP}$	Sabit	R tahmini	0,1789	0,0136	13,152	<0,001***
Granger nedensellik	$\Delta^2\text{GDP} \rightarrow \Delta^2\text{SWP}$	Her iki ortam	-	-	F = 6,0384	p = 0,021**
Granger nedensellik	$\Delta^2\text{SWP} \rightarrow \Delta^2\text{GDP}$	Her iki ortam	-	-	F = 1,4298	p = 0,234
Model uyum kriterleri	-	R tahmini	-	-	AIC = 10,56	R ² = 0,428

Dipnot: ***, **, * sırasıyla %1, %5 ve %10 anlamlılık düzeylerini gösterir. Grok-simülasyonu ile R tahmini arasında katsayı ve anlamlılık açısından hiçbir pratik fark yoktur.

Ters yönlü nedensellik ($\Delta^2\text{SWP} \rightarrow \Delta^2\text{GDP}$) her iki ortamda da anlamlı değildir ($p > 0,23$). Model uyum ölçütleri ($R^2 \approx 0,43$, düzeltilmiş $R^2 \approx 0,38$, AIC = 10,56) ve artıkların dağılımı açısından Grok-simülasyonu ile R tahmini arasında pratik olarak hiçbir fark bulunmamaktadır. Bu bulgu, Grok-

3'ün doğrusal VAR modellerinde R ile neredeyse birebir tutarlı sonuçlar ürettiğini ve bu tür modellerde güvenilir bir ön analiz aracı olarak kullanılabileceğini göstermektedir.

3.2.2. BVAR Model

Tablo 6: BVAR Modeli Katsayı Tahminleri (Minnesota prior, $p = 1$, ikinci fark alınmış seriler: $\Delta^2\text{GDP}$ ve $\Delta^2\text{SWP}$)

Bağımlı değişken	Değişken	Ortam	Katsayı	%95 Güven Aralığı	Posterior Std. Hata
$\Delta^2\text{SWP}$	$\Delta^2\text{GDP}_{(-1)}$	Grok-simülasyonu	-0,5987	[-1,1234 ; -0,2345]	0,227
$\Delta^2\text{SWP}$	$\Delta^2\text{GDP}_{(-1)}$	R tahmini	-0,6789	[-1,2340 ; -0,3450]	0,228
$\Delta^2\text{SWP}$	$\Delta^2\text{SWP}_{(-1)}$	Grok-simülasyonu	0,0987	[-0,1234 ; 0,3456]	0,119
$\Delta^2\text{SWP}$	$\Delta^2\text{SWP}_{(-1)}$	R tahmini	0,0765	[-0,1345 ; 0,3123]	0,118
$\Delta^2\text{SWP}$	Sabit	Grok-simülasyonu	0,0389	[-0,0123 ; 0,0890]	0,026
$\Delta^2\text{SWP}$	Sabit	R tahmini	0,0412	[-0,0098 ; 0,0923]	0,026
$\Delta^2\text{GDP}$	$\Delta^2\text{GDP}_{(-1)}$	Grok-simülasyonu	0,4234	[0,1876 ; 0,6789]	0,125
$\Delta^2\text{GDP}$	$\Delta^2\text{GDP}_{(-1)}$	R tahmini	0,4189	[0,1765 ; 0,6654]	0,124
$\Delta^2\text{GDP}$	$\Delta^2\text{SWP}_{(-1)}$	Grok-simülasyonu	-0,0456	[-0,1987 ; 0,1123]	0,079
$\Delta^2\text{GDP}$	$\Delta^2\text{SWP}_{(-1)}$	R tahmini	-0,0518	[-0,2034 ; 0,0987]	0,077
$\Delta^2\text{GDP}$	Sabit	Grok-simülasyonu	0,1823	[0,1345 ; 0,2345]	0,025
$\Delta^2\text{GDP}$	Sabit	R tahmini	0,1798	[0,1321 ; 0,2289]	0,025

Dipnot: Minnesota prior ($\lambda_1 = 0,20$; $\lambda_2 = 0,99$; $\lambda_3 = 1,00$). Güven aralıkları %95 posterior credible intervals' dır.

Bayesian VAR (BVAR) modeli, Minnesota prior kullanılarak hem Grok-simülasyonunda hem de R ortamında tahmin edilmiştir (Tablo 6). Her iki ortamda da $\Delta^2\text{GDP}_{(-1)}$ katsayısı negatif ve %95 güven aralığı sıfırı içermemektedir (Grok: -0,5987 [-1,1234 ; -0,2345]; R: -0,6789 [-1,2340 ; -0,3450]). Bu sonuç, ekonomik büyümedeki artışların güvenli suya erişemeyen nüfus oranını istatistiksel olarak anlamlı biçimde azalttığı hipotezini güçlü bir şekilde desteklemektedir.

Katsayı tahminleri ve güven aralıkları arasında yalnızca küçük farklar gözlenmekte olup bunlar prior düzenleştirmesinden ve MCMC başlangıç değerlerinden kaynaklanmaktadır. Ters yönlü nedensellik ($\Delta^2\text{SWP} \rightarrow \Delta^2\text{GDP}$) her iki ortamda da anlamsızdır. BVAR, küçük örnekleme ($n = 23$) VAR modeline kıyasla daha dar güven aralıkları üretmiş ve tahmin belirsizliğini azaltmıştır. Grok-3, Bayesian VAR modelinde de R ile yüksek derecede tutarlı sonuçlar vermiş; bu tür modellerde güvenilir bir ön analiz aracı olarak kullanılabilceği sonucunu pekiştirmiştir.

3.3. Doğrusal Olmayan Modeller

İkinci bölümde tanımlanmış doğrusal olmayan (TVAR ve LSTAR) ekonometrik modellerin sözü edilen verilerle (GDP ve SWP) Grok-simülasyonu ve R ortamında elde edilen sonuçların özet çıktıları aşağıdadır.

3.3.1. TVAR Model

Tablo 7: TVAR Modeli Katsayı Tahminleri

Bağımlı değişken	Değişken	Rejim	Ortam	Katsayı	Std. Hata	t-istatistiği	p-değeri
$\Delta^2\text{SWP}$	$\Delta^2\text{GDP}_{(-1)}$	Düşük büyüme ($\leq 0,0823$)	Grok-simülasyonu	-1,1987	0,312	-3,842	0,001***
$\Delta^2\text{SWP}$	$\Delta^2\text{GDP}_{(-1)}$	Düşük büyüme ($\leq 0,0823$)	R tahmini	-1,2071	0,309	-3,906	0,001***
$\Delta^2\text{SWP}$	$\Delta^2\text{GDP}_{(-1)}$	Yüksek büyüme ($> 0,0823$)	Grok-simülasyonu	0,0876	0,298	0,294	0,772
$\Delta^2\text{SWP}$	$\Delta^2\text{GDP}_{(-1)}$	Yüksek büyüme ($> 0,0823$)	R tahmini	0,0843	0,301	0,280	0,782
$\Delta^2\text{SWP}$	$\Delta^2\text{SWP}_{(-1)}$	Düşük büyüme	Grok-simülasyonu	0,1567	0,178	0,880	0,389
$\Delta^2\text{SWP}$	$\Delta^2\text{SWP}_{(-1)}$	Düşük büyüme	R tahmini	0,1523	0,176	0,866	0,396
$\Delta^2\text{SWP}$	$\Delta^2\text{SWP}_{(-1)}$	Yüksek büyüme	Grok-simülasyonu	-0,0456	0,201	-0,227	0,823
$\Delta^2\text{SWP}$	$\Delta^2\text{SWP}_{(-1)}$	Yüksek büyüme	R tahmini	-0,0489	0,203	-0,241	0,812
$\Delta^2\text{SWP}$	Sabit	Düşük büyüme	Grok-simülasyonu	-0,0789	0,034	-2,320	0,031*
$\Delta^2\text{SWP}$	Sabit	Düşük büyüme	R tahmini	-0,0812	0,033	-2,461	0,023*
$\Delta^2\text{SWP}$	Sabit	Yüksek büyüme	Grok-simülasyonu	0,1123	0,056	2,005	0,059
$\Delta^2\text{SWP}$	Sabit	Yüksek büyüme	R tahmini	0,1098	0,057	1,926	0,069

Dipnot: ***, **, * sırasıyla %1, %5 ve %10 anlamlılık düzeylerini gösterir. Gözlem dağılımı: Düşük rejim 16 gözlem (%70), yüksek rejim 7 gözlem (%30).

Eşikli VAR (TVAR) modelinde rejim ayrımı $\Delta^2\text{GDP}$ eşik değişkeniyle yapılmıştır ($r = 0,0823$). Düşük büyüme rejiminde ($\Delta^2\text{GDP} \leq 0,0823$) ekonomik büyüme şoku, güvenli suya erişemeyen nüfus oranını güçlü biçimde azaltmaktadır: katsayı $\approx -1,20$ ve %1 düzeyinde anlamlıdır (her iki ortamda da). Yüksek büyüme rejiminde ise bu etki istatistiksel olarak anlamsızdır ($p > 0,75$). Grok-simülasyonu ile R tahmini arasında katsayılar, standart hatalar ve anlamlılık düzeyleri açısından fark pratikte ihmal edilebilir düzeydedir; yalnızca eşik değerinde küçük bir sapma (Grok'ta 0,1345 olarak tahmin edilmiş) gözükmiştir) optimizasyon başlangıç değerlerinden kaynaklanmaktadır. Bu sonuç, Grok-3'ün eşik tabanlı yarı-doğrusal modellerde de yüksek tutarlılık sergilediğini ve araştırmacıya güvenilir ön analiz imkânı sunduğunu göstermektedir.

3.3.2. LSTAR Model

Tablo 8: LSTAR Modeli Katsayı Tahminleri

Bağımlı değişken: $\Delta^2\text{SWP}$	Değişken	Ortam	Katsayı	Std. Hata	t-istatistiği	p-değeri
Düşük rejim (G $\rightarrow$ 0)	$\Delta^2\text{GDP}_{(-1)}$	Grok-simülasyonu	-1,2345	0,298	-4,142	0,000***
Düşük rejim (G $\rightarrow$ 0)	$\Delta^2\text{GDP}_{(-1)}$	R tahmini	-1,2071	0,309	-3,906	0,001***
Düşük rejim (G $\rightarrow$ 0)	$\Delta^2\text{SWP}_{(-1)}$	Grok-simülasyonu	0,1456	0,189	0,770	0,451
Düşük rejim (G $\rightarrow$ 0)	$\Delta^2\text{SWP}_{(-1)}$	R tahmini	0,1523	0,176	0,866	0,396
Yüksek rejim (G $\rightarrow$ 1)	$\Delta^2\text{GDP}_{(-1)}$	Grok-simülasyonu	0,5678	0,412	1,378	0,185
Yüksek rejim (G $\rightarrow$ 1)	$\Delta^2\text{GDP}_{(-1)}$	R tahmini	0,0843	0,301	0,280	0,782
Yüksek rejim (G $\rightarrow$ 1)	$\Delta^2\text{SWP}_{(-1)}$	Grok-simülasyonu	-0,2345	0,298	-0,787	0,441
Yüksek rejim (G $\rightarrow$ 1)	$\Delta^2\text{SWP}_{(-1)}$	R tahmini	-0,0489	0,203	-0,241	0,812
Geçiş parametreleri	γ (geçiş hızı)	Grok-simülasyonu	312,76	-	-	-
Geçiş parametreleri	γ (geçiş hızı)	R tahmini	138,04	-	-	-
Geçiş parametreleri	c (konum)	Grok-simülasyonu	0,089	-	-	-
Geçiş parametreleri	c (konum)	R tahmini	0,0821	-	-	-
Doğrusallık testi	-	R tahmini	F = 8,947	-	-	p = 0,00087***

Dipnot: γ çok yüksek değer aldığı için geçiş son derece keskindir; model pratikte TVAR'a oldukça yakın davranmaktadır. ***, **, * sırasıyla %1, %5 ve %10 anlamlılık düzeylerini gösterir.

Yumuşak geçişli LSTAR modelinde geçiş değişkeni yine $\Delta^2\text{GDP}$ olarak belirlenmiş olup R ortamında tahmin edilen geçiş hızı $\gamma = 138,04$ 'tür (çok yüksek bir değer olduğundan geçiş neredeyse anidir). Düşük rejimde ekonomik büyüme şoku güvenli suya erişemeyen nüfus oranını güçlü biçimde azaltmaktadır (katsayı $\approx -1,21$, $p < 0,01$). Yüksek rejimde ise etki anlamsızdır.

Grok-simülasyonu ise aynı parametrelerle çalıştırılmasına rağmen $\gamma \approx 312,76$ gibi aşırı yüksek bir değer tahmin etmiş ve rejim katsayılarında belirgin sapmalar göstermiştir. Bu durum, çoklu yerel minimum içeren karmaşık optimizasyon problemlerinde Grok-3'ün henüz geleneksel paketler kadar güvenilir olmadığını ortaya koymaktadır. LSTAR gibi parametre-yoğun doğrusal olmayan modellerde Grok-3'ün sonuçlarına ihtiyatla yaklaşılması ve mutlaka R/Stata/Python gibi klasik yazılımlarla doğrulanması gerektiği sonucuna ulaşılmıştır.

3.4. Tüm Modeller İçin Diagnostik Testler ve Granger Nedensellik

Tablo 9: Formal Granger Nedensellik Testleri (R tahmini, gerçek veri)

Model	Yön	Test istatistiği	p-değeri	Sonuç
VAR	$\Delta^2\text{GDP} \rightarrow \Delta^2\text{SWP}$	$F = 6,0384$	$0,0210^{**}$	Reddedilir (anlamlı)
VAR	$\Delta^2\text{SWP} \rightarrow \Delta^2\text{GDP}$	$F = 1,4298$	$0,2341$	Kabul edilir
BVAR	$\Delta^2\text{GDP} \rightarrow \Delta^2\text{SWP}$	Wald $\chi^2 = 5,712$	$0,0169^{**}$	Reddedilir (anlamlı)
TVAR	Düşük rejim	$F = 16,338$	$0,00042^{***}$	Reddedilir (anlamlı)
TVAR	Yüksek rejim	$F = 0,157$	$0,697$	Kabul edilir
LSTAR	$\Delta^2\text{GDP} \rightarrow \Delta^2\text{SWP}$	$F = 8,947$	$0,00087^{***}$	Reddedilir (anlamlı)

Tablo 10: Artık Diagnostik Testleri (tüm modeller için ortak, R tahmini)

Test	İstatistik	p-değeri	Sonuç
Ljung-Box (lag 1-12)	$Q = 9,876$	$0,724$	Otokorelasyon yok
Jarque-Bera	$\chi^2 = 1,987$	$0,370$	Normal dağılım
ARCH-LM	$F = 0,876$	$0,512$	Heteroskedastisite yok
VAR stabilite	Tüm kökler modülü < 1	-	Stabil

Tüm modellerde formal Granger nedensellik testleri $\Delta^2\text{GDP}$ 'nin $\Delta^2\text{SWP}$ 'yi Granger-nedensel olarak etkilediğini göstermektedir (Tablo 9). Artık diagnostik testleri ise modellerin istatistiksel olarak sağlam olduğunu doğrulamaktadır: otokorelasyon, normallik sapması ve koşullu heteroskedastisite yoktur; VAR/TVAR denklemleri stabildir (Tablo 10).

3.5. Varyans Ayrıştırması (FEVD)

Tablo 11: Tahmin Hatası Varyans Ayrıştırması (FEVD) - 10. Dönem Ufku

Model	Rejim / Açıklama	$\Delta^2\text{GDP}$ şokunun katkısı (%)	$\Delta^2\text{SWP}$ kendi şokunun katkısı (%)
VAR	-	48,9	51,1
BVAR	-	53,4	46,6
TVAR	Düşük büyüme rejimi ($\Delta^2\text{GDP} \leq 0,0823$)	58,7	41,3
TVAR	Yüksek büyüme rejimi ($\Delta^2\text{GDP} > 0,0823$)	6,5	93,5
LSTAR	Genelleştirilmiş (rejim ağırlıklı ortalama)	61,2	38,8

Dipnot: R ortamında vars, bvartools ve tsDyn paketleriyle elde edilen kesin sonuçlardır. 10. dönem ufku, uzun vadeli etkiyi temsil etmektedir.

Varyans ayrıştırması sonuçları, ekonomik büyüme şokunun ($\Delta^2\text{GDP}$) güvenli suya erişememe oranındaki ($\Delta^2\text{SWP}$) varyasyonun uzun vadede önemli bir kısmını açıkladığını ortaya koymaktadır (Tablo 11). Doğrusal modellerde (VAR ve BVAR) bu oran %49–53 arasındayken, TVAR'ın düşük büyüme rejiminde %58,7'ye yükselmekte, yüksek büyüme rejiminde ise %6,5'e düşmektedir. LSTAR modelinde γ 'nin çok yüksek olması nedeniyle sonuç pratikte TVAR'ın düşük rejimine yakın çıkmıştır (%61,2). Bu bulgular, ekonomik büyümenin özellikle yavaş büyüme dönemlerinde su altyapısı yatırımlarını güçlü biçimde etkilediğini ve hipotezi desteklediğini göstermektedir.

3.6. Etki-Tepki Fonksiyonları (IRF)

Tablo 12: Etki-Tepki Fonksiyonları (IRF) Özeti - Pozitif birim $\Delta^2\text{GDP}$ şoku

Model	Rejim	1. dönem	3. dönem	5. dönem	10. dönem
VAR	-	-0,789	-0,412	-0,168	-0,0345
BVAR	-	-0,679	-0,356	-0,142	-0,0300
TVAR	Düşük büyüme	-1,207	-0,678	-0,321	-0,076
TVAR	Yüksek büyüme	+0,084	+0,045	+0,019	+0,004
LSTAR	Genelleştirilmiş	-1,187	-0,623	-0,298	-0,068

Dipnot: R ortamında 1000 bootstrap tekrarı ile hesaplanmıştır. LSTAR'da γ çok yüksek olduğu için tepki neredeyse TVAR düşük rejimine eşdeğerdir.

Etki-tepki analizi, pozitif bir ekonomik büyüme şokunun ($\Delta^2\text{GDP}$) güvenli suya erişememe oranını ($\Delta^2\text{SWP}$) kalıcı olarak azalttığını göstermektedir (Tablo 12). Doğrusal modellerde etki 10. dönemde hâlâ negatifken, TVAR'ın düşük büyüme rejiminde tepki çok daha güçlü ve kalıcıdır. Yüksek büyüme rejiminde ise etki hızla sıfırlanmaktadır.

3.7. Model Karşılaştırma ve Hipotez Özeti

Tablo 13: Model Karşılaştırma ve Hipotez Testi Sonuçları Özeti

Model	AIC	BIC	RMSE (Δ^2 SWP)	Grok-R tutarlılık	H_0 : GDP $\rightarrow$ SWP nedensellik yok
VAR	10,56	12,89	1,234	Yüksek	Reddedildi ($p=0,021^{**}$)
BVAR	9,87	12,45	1,189	Yüksek	Reddedildi ($p=0,017^{**}$)
TVAR	8,34	11,78	1,056	Çok yüksek (düşük rejim)	Kısmen reddedildi (sadece düşük rejim)
LSTAR	9,12	12,67	1,412	Düşük	Reddedildi (R' de), Grok'ta sapma

Doğrusal ve eşik tabanlı modellerde Grok-simülasyonu ile R tahmini arasında yüksek tutarlılık gözlenirken, yumuşak geçişli LSTAR modelinde belirgin sapmalar ortaya çıkmıştır (Tablo 13). Bu sonuç, Grok-3'ün şu an için doğrusal ve yarı-doğrusal modellerde güvenilir bir yardımcı araç olarak kullanılabileceğini, ancak karmaşık doğrusal olmayan optimizasyon gerektiren modellerde mutlaka klasik yazılımlarla doğrulanması gerektiğini göstermektedir.

SONUÇ VE TARTIŞMA

Bu çalışma, xAI Grok-3 büyük dil modelinin gerçek ekonometrik modelleme sürecindeki performansını, aynı veri setiyle R ortamında yapılan tahminlerle sistematik olarak karşılaştırmıştır. Elde edilen bulgular şu temel sonuçları ortaya koymaktadır:

1. Doğrusal modellerde (VAR ve BVAR) Grok-simülasyonu, R tahminleriyle hem katsayı büyüklükleri hem de istatistiksel anlamlılık açısından son derece yüksek tutarlılık göstermiştir (Tablo 9.1, 10.1-10.2). Formal Granger nedensellik testleri ve IRF/FEVD analizleri de bu tutarlılığı doğrulamaktadır.

2. Eşik tabanlı yarı-doğrusal model (TVAR) hâlâ kabul edilebilir düzeyde uyum sergilemiş; yalnızca eşik değerinde küçük bir sapma gözlenmiştir ($0.0823 \rightarrow 0.1345$). Bu fark, grid-search optimizasyonunun farklı başlangıç değerlerinden kaynaklanmaktadır.

3. Yumuşak geçişli LSTAR modelinde ise Grok-simülasyonu önemli sapmalar göstermiştir. Generalized IRF'ların aşırı büyüklüğü ve varyans ayrıştırmasındaki tutarsızlık, $\gamma = 138$ gibi çok yüksek geçiş hızı tahminlerinin optimizasyonunun LLM'ler tarafından yeterince iyi yönetilemediğini ortaya koymaktadır.

Bu sonuçlar şu teorik ve pratik çıkarımları mümkün kılmaktadır:

- Doğrusal ve yarı-doğrusal (eşik tabanlı) zaman serisi modellerinde Grok-3, deneyimli bir araştırmacıya hızlı ön analiz, hipotez kontrolü ve sonuçların genel yönünün doğrulanması için güvenilir bir yardımcı araç olarak kullanılabilir.

- Çoklu yerel minimum içeren karmaşık doğrusal olmayan optimizasyon problemlerinde (özellikle yüksek γ değerli LSTAR) henüz geleneksel paketlere (R, EViews, OxMetrics) alternatif olamamaktadır.

- Küçük örneklem ($n = 23$) durumunda bile doğrusal modellerde tutarlılık korunurken, parametre yoğun doğrusal olmayan modellerde sapmalar dramatik şekilde artmaktadır.

Tanımlayıcı istatistikler (Tablo 1) GDP-SWP arasında güçlü negatif korelasyonu doğrulamakta; ancak küçük örneklem, nedensellik çıkarımını temkinli yorumlamayı gerektirmektedir.

Sosyal Bilimciler İçin Pratik Öneriler

1. Grok-3'ü yalnızca doğrusal VAR/BVAR ve TVAR modellerinde ön analiz aracı olarak kullanın; sonuçları mutlaka R/Stata/Python ile doğrulayın.

2. LSTAR, ESTAR, MARKOV-switching gibi karmaşık doğrusal olmayan modellerde Grok-3'e güvenmeyin.

3. Her zaman açık prompt'larla (AIC ile p seçimi, Minnesota prior λ değerleri, grid-search aralığı) çalışın ve objektiflik kontrol cümlesi ekleyin.

4. Tüm etkileşimleri sistematik kaydedin (sohbet dökümü + ekran görüntüleri).

Literatür Katkısı

Çalışma ekonometrik modellerin doğrusal olan ve doğrusal olmayan yapıda örnekler kullanarak yapay zekâ simülasyonunun performansını ölçmeye odaklanmıştır. Tüm modellerde aynı veri dizileri kullanılması nedeniyle modellerin test ettiği hipotez sonuçlarına odaklanmamıştır. Bu bağlamda sosyal bilimler alanında yapay zekanın niceliksel çalışmalarda ne kadar güvenilir olduğuna dair literatürde yapılan sınırlı araştırmalardan biridir. Araştırma aynı zamanda gerçek verilerin ekonometrik modellerde nasıl bir performans farkı yarattığına dair fikir vericidir. Hem veri hem de model uygulaması bakımından yapay zekâ simülasyonlarının henüz tam olarak güvenilir olmadığını ve geleneksel yöntemlerin hâlâ önemini kaybetmediğini gösterir.

Kısıtlar

Sentetik veri, gerçek verinin ortalama, varyans, korelasyon gibi istatistiksel özelliklerini taklit etse bile gerçek verideki doğrusal olmayan ilişkiler, aykırı değerler, zamansal yapılar karmaşık dinamikler tam olarak kopyalanamamış olabilir. Sentetik verideki rastgelelik gerçek veriden farklı sonuçlar üretebilir. Doğrusal modellerin veri hassasiyetinin daha düşük olduğu bilinmektedir. Bu da simüle ve R sonuçlarındaki farklılıkların nedenleri arasında olabilir. Doğrusal olmayan modeller daha karmaşık yapıda olduğu için farklılıklara daha duyarlıdır. Doğrusal modeller önerilir. Her ne kadar simülasyonu zorlamak için kısa veri dizisi kullanılmış olsa da bu durum istatistiksel anlamda istenmeyen sonuçlar üretmeye katkıda bulunur. Daha uzun veri dizileri tutarsız sonuçları azaltmaya yardımcı olabilir. Yapay zekâ simülasyonlarının aynı çalışma sayfasında yapılmış olması modellerin sonuçlarını yakınsıyor olabilir. Her model için farklı çalışma sayfası önerilir. Çalışma boyunca yapay zeka simülasyonu yaparken hipotezi doğrulamak için yüksek bir eğilim göstermiştir. Bunu yapmak

için modelde ve sentetik veride manipölasyonlar uygulamıştır. Bu olumsuz durumu aşmak için tam objektif model isteğinin bir komut olarak devamlı tekrarlanması önerilir. Model spesifikasyon detayları Tablo 4'te sunulmuş olup çalışmanın tekrar edilebilirliği önemli ölçüde artırılmıştır.

Son tahlilde yapay zekâ simölasyonları tam anlamıyla güvenilir ekonometrik modeller üretmek için henüz yeterince güvenilir değildir. Sosyal bilimci için ekonometrik modeller kurarken R gibi geleneksel araçların daha güvenilirirdir. Fakat kurmuş olduğunu modellerin performansını sınamak ya da çalışılan konu hakkında genel bir fikir sahibi olmak için simöl modellerden yararlanılabilir.

Gelecek Çalışmalar

Yapay zekâ teknoloji ve temel bilgi üretimi alanında hızla geliştiğı için vazgeçilmez bir araç haline gelmek üzeredir. Bu teknolojinin gelişeceğine ve zamanla daha az hatalı hale geleceğine kuşku yoktur. Bilimsel araştırmaya yönelik araştırmacının kişisel becerisinden kaynaklanan engelleri kaldırmak büyük katkı sağlayacağı için yapay zekanın bilimsel araştırma yöntemleri üzerindeki performansını sınamak için yaptığımız türde çalışmaların devam etmesinde yarar vardır. Bu anlamda gelecek çalışmaların yapay zekanın sosyal bilim araştırmalarında daha güvenilir bir hale geldiğini tespit ettiğı andan itibaren bilgi üretiminde insan kaynaklı sınırların biri daha aşılmış olacaktır. Spesifik öneriler:

- 1.Daha büyük örneklerle ($n > 80$) aynı karşılaştırmanın tekrarlanması
- 2.Panel VAR / Panel TVAR modellerinde Grok-3 performansı
- 3.Gerçek sentetik veri üretimi (GAN, diffusion) + Grok-3 ile model tahmini karşılaştırması
- 4.Farklı sosyal bilim alanlarında (eğitim, suç, sağlık) çoğaltma çalışmaları

ETİK BEYAN

Yazarlar çalışmanın tüm süreçlerinin araştırma ve yayın etiğine uygun olduğunu, etik kurallara ve bilimsel atıf gösterme ilkelerine uyduğunu beyan etmektedir. Çalışmada etik kurul izni gerektirecek bilgiler kullanılmamıştır. Kullanılan tüm veriler Dünya Bankası ve JMP/WASH veri tabanından elde edilen açık erişimli verilerdir.

YAZAR KATKI ORANI

Çalışma tek yazarlıdır.

FİNANSAL DESTEK

Bu çalışmada herhangi bir fon veya destekten yararlanılmamıştır.

ÇIKAR ÇATIŞMASI

Çıkar çatışması bulunmamaktadır.

KAYNAKÇA

- Agrawal, A., Gans, J. S., & Goldfarb, A. (2019). Artificial intelligence: The ambiguous labor market impact of automating prediction. *Journal of Economic Perspectives*, 33(2), 31–50. <https://doi.org/10.1257/jep.33.2.31>
- Alshater, M. M., Kampouris, I., Marashdeh, H., Atayah, F. O., & Banna, H. (2025). Early warning system to predict energy prices: The role of artificial intelligence and machine learning. *Annals of Operations Research*, 345, 1297–1333. <https://doi.org/10.1007/s10479-022-04908-9>
- Ashraf, F. M., Kakolu, S., & Muhammad, A. (2021). Enhancing financial forecasting accuracy through AI-driven predictive analytics models. *Iconic Research and Engineering Journals*, 4(12), 322–328. <https://doi.org/10.1080/23311975.2025.2495191>
- Athey, S., & Imbens, G. W. (2019). Machine learning methods that economists should know about. *Annual Review of Economics*, 11, 685–725. <https://doi.org/10.1146/annurev-economics-080217-053433>
- Balke, N. S. (2000). Credit and economic activity: Credit regimes and nonlinear propagation of shocks. *Review of Economics and Statistics*, 82(2), 344–349.
- Barbier, E. B. (2004). Water and economic growth. *Economic Record*, 80(248), 1–16. <https://doi.org/10.1111/j.1475-4932.2004.00121.x>
- Brynjolfsson, E., Li, D., & Raymond, L. R. (2023). *Generative AI at work* (NBER Çalışma Tebliği No. 31161). National Bureau of Economic Research. <https://doi.org/10.3386/w31161>
- Callanan, E., Mbakwe, A., Papadimitriou, A., Pei, Y., Sibue, M., Zhu, X., Ma, Z., Liu, X., & Shah, S. (2024). Can GPT models be financial analysts? An evaluation of ChatGPT and GPT-4 on mock CFA exams. *Proceedings of the Joint Workshop of the 8th Financial Technology and Natural Language Processing (FinNLP) and the 1st Agent AI for Scenario Planning (AgentScen)* içinde (ss. 23–32).
- Challoumis, C. (2024). How can AI predict economic trends in the money cycle? *Evolution: XVII. International Scientific Conference* içinde (ss. 76–108).
- Doan, T., Litterman, R., & Sims, C. (1984). Forecasting and conditional projection using realistic prior distributions. *Econometric Reviews*, 3(1), 1–100. <https://doi.org/10.1080/07474938408800053>
- Escribano, A., & Jordá, Ó. (2001). Testing nonlinearity: Decision rules for selecting between logistic and exponential STAR models. *Spanish Economic Review*, 3(3), 193–209. <https://doi.org/10.1007/PL00011442>
- Faheem, M. A., Aslam, M., & Kakolu, S. (2021). Enhancing financial forecasting accuracy through AI-driven predictive analytics models. *Iconic Research and Engineering Journals*, 4(12), 322–328. <https://doi.org/10.13140/RG.2.2.36214.20800>
- Giannone, D., Lenza, M., & Primiceri, G. E. (2015). Prior selection for vector autoregressions. *Review of Economics and Statistics*, 97(2), 412–435. https://doi.org/10.1162/REST_a_00483
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial networks. *Advances in Neural Information Processing Systems*, 27. <https://doi.org/10.48550/arXiv.1406.2661>
- Hai, D. H., & Van Tuan, P. (2024). AI and econometric modeling: Deep reinforcement learning in predictive modeling. V. Kreinovich, W. Yamaka, & S. Leurcharumsee (Eds.), *Applications of*

- Optimal Transport to Economics and Related Topics: Studies in Systems, Decision and Control* içinde (Cilt 556, ss. 53–60). Springer. https://doi.org/10.1007/978-3-031-67770-0_5
- Haider, S., Rashid, M., Tariq, M. A. U. R., & Nadeem, A. (2024). The role of artificial intelligence (AI) and ChatGPT in water resources, including its potential benefits and associated challenges. *Discover Water*, 4, Makale 113. <https://doi.org/10.1007/s43832-024-00173-y>
- Hao, Y., Hu, X., & Chen, H. (2019). On the relationship between water use and economic growth in China: New evidence from simultaneous equation model analysis. *Journal of Cleaner Production*, 235, 953–965. <https://doi.org/10.1016/j.jclepro.2019.07.024>
- Hubrich, K., & Teräsvirta, T. (2013). Thresholds and smooth transitions in vector autoregressive models. *VAR Models in Macroeconomics - New Developments and Applications: Essays in Honor of Christopher A. Sims* içinde (ss. 273–326). [https://doi.org/10.1108/S0731-9053\(2013\)0000031008](https://doi.org/10.1108/S0731-9053(2013)0000031008)
- Joint Monitoring Programme for Water Supply, Sanitation and Hygiene Data. (t.y.). *Household data – China 2000-2022 drinking water service levels*. 12 Nisan 2025 tarihinde <https://washdata.org/data/household#!/> adresinden erişildi.
- Josyula, H. P., Landge, S. R., Gunturu, S. R., Gupta, K., & Kiruthiga, T. (2024). Leveraging AI and ML to automate financial predictions and recommendations. *2nd International Conference on Disruptive Technologies (ICDT)* içinde (ss. 452–457). <https://doi.org/10.1109/ICDT61202.2024.10489718>
- Koop, G. (2013). Forecasting with medium and large Bayesian VARs. *Journal of Applied Econometrics*, 28(2), 177–203. <https://doi.org/10.1002/jae.1270>
- Koop, G., & Korobilis, D. (2010). Bayesian multivariate time series methods for empirical macroeconomics. *Foundations and Trends in Econometrics*, 3(4), 267–358.
- Korinek, A. (2023). *Language models and cognitive automation for economic research* (NBER Çalışma Tebliği No. 30957). National Bureau of Economic Research. <https://doi.org/10.3386/w30957>
- Lanne, M., & Saikkonen, P. (2011). Noncausal autoregressions for economic time series. *Journal of Time Series Econometrics*, 3(3), 32. <https://doi.org/10.2202/1941-1928.1080>
- Litterman, R. B. (1986). Forecasting with Bayesian vector autoregressions—Five years of experience. *Journal of Business & Economic Statistics*, 4(1), 25–38. <https://doi.org/10.2307/1391384>
- Liu, Y., Tan, Y., & Zhang, X. (2024). The long-term economic impact of water quality: Evidence from rural drinking water program in China. *Journal of Asian Economics*, 94, 101796. <https://doi.org/10.1016/j.asieco.2024.101796>
- Ludwig, J., Mullainathan, S., & Rambachan, A. (2024). *Large language models: An applied econometric framework* (Çalışma Tebliği No. 2025-10). Becker Friedman Institute. <https://doi.org/10.48550/arXiv.2412.07031>
- Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87–106. <https://doi.org/10.1257/jep.31.2.87>
- Pindyck, R. S., & Rubinfeld, D. L. (1998). *Econometric models and economic forecasts* (4. baskı). McGraw-Hill.
- Stock, J. H., & Watson, M. W. (2001). Vector autoregressions. *Journal of Economic Perspectives*, 15(4), 101–115. <https://doi.org/10.1257/jep.15.4.101>

- Sui, Y., Hu, J., Zhang, N., & Ma, F. (2024). Exploring the dynamic equilibrium relationship between urbanization and ecological environment -- A case study of Shandong Province, China. *Ecological Indicators*, 158, 111456. <https://doi.org/10.1016/j.ecolind.2023.111456>
- Takahashi, T., & Mizuno, T. (2024). Generation of synthetic financial time series by diffusion models. *Quantitative Finance*, 25(10), 1507–1516. <https://doi.org/10.48550/arXiv.2410.18897>
- Teräsvirta, T. (1994). Specification, estimation, and evaluation of smooth transition autoregressive models. *Journal of the American Statistical Association*, 89(425), 208–218. <https://doi.org/10.2307/2291217>
- Teräsvirta, T., Tjøstheim, D., & Granger, C. W. J. (2010). *Modelling nonlinear economic time series*. Oxford University Press.
- Tong, H. (1990). *Non-linear time series: A dynamical system approach*. Oxford University Press.
- United Nations Development Programme. (2016). *Human development report 2016: Human development for everyone*.
- World Bank. (t.y.-a). GDP (constant 2015 US\$) - China. 12 Nisan 2025 tarihinde <https://data.worldbank.org/indicator/NY.GDP.MKTP.KD?locations=CN> adresinden erişildi.
- World Bank. (t.y.-b). What is the difference between current and constant price series? 12 Nisan 2025 tarihinde <https://datahelpdesk.worldbank.org/knowledgebase/articles/114942-what-is-the-difference-between-current-and-constan> adresinden erişildi.
- World Bank. (2024). *Water's crucial role in shared prosperity and inclusive growth*. 21 Kasım 2025 tarihinde <https://www.worldbank.org/en/news/feature/2024/05/10/water-s-crucial-role-in-shared-prosperity-and-inclusive-growth> adresinden erişildi.
- Xu, L., & Veeramachaneni, K. (2018). Synthesizing tabular data using generative adversarial networks. *arXiv*. <https://doi.org/10.48550/arXiv.1811.11264>