

**ORGANOİD, YAPAY ORGAN VE BİYOBASKI
TEKNOLOJİLERİNDE PATENT MADENCİLİĞİ İLE
TEKNOLOJİ TAHMİNİ**

**TECHNOLOGY FORECASTING WITH PATENT MINING
IN ORGANOID, ARTIFICIAL ORGAN AND
BIOPRINTING TECHNOLOGIES**

BATIHAN KONUK

PROF. DR DİYAR AKAY

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Endüstri Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2024

ÖZET

ORGANOİD, YAPAY ORGAN VE BİYOBASKI TEKNOLOJİLERİNDE PATENT MADENCİLİĞİ İLE TEKNOLOJİ TAHMİNİ

Batıhan KONUK

Yüksek Lisans, Endüstri Mühendisliği Bölümü

Tez Danışmanı: Prof. Dr. Diyar AKAY

Mayıs 2024, 67 sayfa

Teknolojik gelişmeleri detaylıca değerlendirmek ve bu gelişmelerin peşinden gitmek, insanlığın ilk zamanlarından beri gelişen teknolojinin hayatı kolaylaştırması, tedavi etmesi, zaman ve maliyetleri düşürmesi açısından çok önemli bir süreçtir. Hem akademik hem de ticari olarak teknolojik gelişmelerin büyük bir rekabetle çalışıldığı günümüzde, doğru teknolojik gelişmenin seçilimi ve yatırımların doğru fikirlere aktarılması da büyük önem kazanmıştır. Bu nedenle işletmeler ve politika yapıcılar, günümüzün hızlı ve rekabetçi pazarında yeni ürünlerin başarılı olma olasılığını değerlendirmek için sıklıkla teknoloji tahmininden yararlanmaktadır. Bu tez kapsamında, teknoloji tahmini yetkinliklerinden birisi olan patent madenciliği yöntemi, sağlık teknolojilerinden büyük pazarlara sahip olan organoid, yapay organ ve biyobaskı teknolojilerinin patent verileri üzerine uygulanıp bu teknolojilere ilişkin hangi alanlara yatırım yapılmalı konusu araştırılmıştır. Burada teknoloji alanlarının seçimi için uluslararası patent sınıflandırma (IPC) kodları kullanılmıştır.

Teknolojiler hem tekil olarak hem de çoklu karşılaştırılmalı olarak çeşitli teknoloji tahmin yöntemleri (teknoloji yaşam döngüsü, teknoloji yayılma hızı, patent gücü ve genişleme

potansiyeli) ile deęerlendirilmiřtir. Bununla birlikte, tez alıřmasında, Python (version 3.12.x) programında yazılmıř bir kod parası ile her bir alt sınıf IPC iin ARIMA model parametreleri (p, d ve q deęerleri), [0, 5] aralıęındaki deęerler kullanılarak denenmiřtir ve dolayısıyla her alt sınıf IPC iin toplamda 216 farklı kombinasyon kullanılarak otomatik olarak test edilmiřtir. Bu sre, her alt sınıf IPC'nin zgn ihtiyalarına gre en iyi model yapılandırmasını belirlemek iin tasarlanmıřtır. Burada farklı parametrelerin test verisi zerinden hesapladıęı ortalama kare hatası karekk (OKHK) gstergeleri ile kıyaslanmıřtır ve otomatik olarak en dřk OKHK deęerini veren parametreler en iyi parametreler olarak atanmıřtır. Bu otomatik seim mekanizması, eřitli IPC'lerin dinamiklerine uygun en iyi tahmin modelinin seilmesini saęlayarak, modelleme srecinde nemli bir verimlilik artıřı ve tahmin doęruluęu saęlamıřtır. Bu yntem, geniř veri kmeleri zerindeki otomasyonu ve modelleme srecindeki etkinlięi artırarak zaman ve kaynak kullanımını optimize etmekte byk rol oynamıřtır.

Bu tez alıřması sonucunda kullanılan yntemlerin; řirketlerin ve bireysel yatırımcıların herhangi bir teknolojik alanına ynelik yatırım kararlarına bilimsel bir temel oluřturmayı hedeflemektedir.

Anahtar Kelimeler: Patent Madencilięi, Teknoloji Tahmini, Teknoloji Yařam Dngs, Teknoloji Yayılma Hızı, Zaman Serisi.

ABSTRACT

TECHNOLOGY FORECASTING WITH PATENT MINING IN ORGANOID, ARTIFICIAL ORGAN AND BIOPRINTING TECHNOLOGIES

Batıhan KONUK

Master of Science, Department of Industrial Engineering

Supervisor: Prof. Dr. Diyar AKAY

May 2024, 67 pages

Evaluating technological developments in detail and pursuing these developments is a critical process in terms of technology that has been developing since the early days of humanity, making life easier, providing treatment, and reducing time and costs. In today's world where technological developments are being studied with great competition both academically and commercially, choosing the right technological development and transferring investments to the right ideas has become of great importance. That's why businesses and policymakers often use technology forecasting to assess the likelihood of new products succeeding in today's fast-paced and competitive market. Within the scope of this thesis, the patent mining method, which is one of the technology forecasting methods, was applied to the patent data of organoid, artificial organ and bioprinting technologies, which have large markets in health technologies, and to decide which areas should be invested in these technologies was investigated. The international patent classification (IPC) codes are used to select technology areas.

Technologies have been evaluated using various technology estimation methods (technology life cycle, technology diffusion rate, patent strength and expansion potential), both individually and in multiple comparatives. In addition, in the thesis study, the ARIMA model parameters (p, d, q values) for each subclass-IPC were tested using values in the range [0, 5] with a piece of code written in the Python (version 3.12.x) program, and therefore each subclass-IPC It was automatically tested using a total of 216 different combinations for the group. This process is designed to determine the best model configuration based on the unique needs of each subclass-IPC. Here, various parameters were compared with the root mean square errors (RMSE) metrics calculated on the test data, and the parameters that automatically gave the lowest RMSE value were assigned as the best parameters. This automatic selection mechanism enabled the selection of the best predictive model suitable for the dynamics of various IPCs, resulting in a significant increase in efficiency and prediction accuracy in the modeling process. This method has played a significant role in optimizing the use of time and resources by increasing automation and efficiency in the modeling process on large data sets.

The methods used as a result of this thesis study; It aims to provide a scientific basis for companies and individual investors in any technological field to make investment decision.

Keywords: Patent Mining, Technology Forecasting, Technology Life Cycle, Technology Diffusion Speed, Time Series.

TEŞEKKÜR

Bu tezin yazımında büyük özveriyle her zaman yanımda olan, hızlı geri dönüşleri ve yönlendirmeleriyle desteğini hiç esirgemeyen Prof. Dr. Diyar AKAY'a,

Yüksek lisans eğitimim boyunca emeği geçen Hacettepe Üniversitesi Endüstri Mühendisliği Bölümü'ndeki tüm hocalarıma,

Görev yaptığım TÜBİTAK'ta, akademik izin dönemlerimde desteklerini hiç esirgemeyen değerli çalışma arkadaşlarıma,

Sabır, anlayış ve sevgileriyle her daim en büyük destekçim olan başta eşim Nur Begüm KONUK, babam Veysel KONUK, annem Şükran KONUK ve kardeşim Dođuhan KONUK'a,

Tüm dostlarıma ve Hacettepe Üniversitesi'ndeki hem lisans hem de lisansüstü akademik eğitimim süresince her zaman yanımda olan sevgili dostum Çađrı GÖLEN'e

sonsuz teşekkür ediyorum.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER.....	vi
ŞEKİLLER DİZİNİ.....	viii
TABLolar DİZİNİ	ix
SİMGELER VE KISALTMALAR.....	x
1. GİRİŞ	1
1.1. Ön Bilgi	1
1.2. Problemin Tanımı.....	1
1.3. Motivasyon.....	3
1.4. Tezin Organizasyonu.....	3
2. İLGİLİ ARKA PLAN	5
2.1. Organoid, Yapay Organ ve Biyobaskı Teknolojisi	5
2.1.1. Organoid Teknolojisi.....	5
2.1.2. Yapay Organ Teknolojisi	7
2.1.3. Biyobaskı Teknolojisi	8
2.2. Teknoloji, Teknoloji Yönetimi ve Teknoloji Tahmininin Önemi.....	9
2.3. Teknoloji Tahmini Yöntemleri.....	12
3. METODOLOJİ.....	17
3.1. Teknoloji Yaşam Döngüsü (TYD).....	20
3.2. Teknoloji Yayılma Hızı (TYH).....	22
3.3. Patent Gücü (PG) ve Genişleme Potansiyeli (GP)	23
3.4. Zaman Serisi Modeli ile Tahmin Yöntemleri	24
4. ANALİZ	28
4.1. Teknoloji Yaşam Döngüsü (TYD).....	28

4.2. Teknoloji Yayılma Hızı (TYH)	30
4.3. Patent Gücü (PG) ve Genişleme Potansiyeli (GP).....	31
4.4. TYD, TYH, PG ve GP Gösterge Skorlarının Değerlendirmesi	33
4.5. Zaman Serisi Modeli Tahmini	35
4.5.1. Organoid Teknolojisi	36
4.5.2. Yapay Organ Teknolojisi	40
4.5.3. Biyobaskı Teknolojisi	44
4.5.4. Konsolide Yatırım Analizi	49
5. SONUÇ VE GELECEK ÇALIŞMALAR	52
6. KAYNAKLAR	53
EKLER.....	58
EK 1 – Organoid Python Kodu	58
EK 2 – Yapay Organ Python Kodu	61
EK 3 – Biyobaskı Python Kodu.....	64

ŞEKİLLER DİZİNİ

Şekil 1. 1. Tez Organizasyonu Şeması	4
Şekil 2. 1. Organoid Teknolojisi ile İlişkili Teknoloji Alanları	6
Şekil 2. 2. Yapay Organ Teknolojisi ile İlişkili Teknoloji Alanları	7
Şekil 2. 3. Biyobaskı Teknolojisi ile İlişkili Teknoloji Alanları	9
Şekil 2. 4. Teknolojinin Değişimi ..	11
Şekil 3. 1. Yöntem Akış Şeması	19
Şekil 3. 2. S-eğrisi	21
Şekil 4. 1. Organoid, Yapay Organ ve Biyobaskı Teknolojilerine İlişkin S-eğrileri	29
Şekil 4. 2. Organoid Teknolojisi Alt Sınıf IPC Kod Patent Sayılarının Yıllara Göre Değişimi	36
Şekil 4. 4. Yapay Organ Teknolojisi Alt Sınıf IPC Kod Patent Sayılarının Yıllara Göre Değişimi	41
Şekil 4. 5. Biyobaskı Teknolojisi Alt Sınıf IPC Kod Patent Sayılarının Yıllara Göre Değişimi	45
Şekil 4. 6. Organoid, Yapay Organ ve Biyobaskı Teknolojilerinin Yatırım Yapılabilirlik Kümesi	50

TABLULAR DİZİNİ

Tablo 4. 1. Teknolojilere İlişkin İstatistikî Patent Verileri	28
Tablo 4. 2. Kriterler Bazında Teknolojilerin Kıyaslanması.....	34
Tablo 4. 3. Organoid Teknolojisi ARIMA Modeli OMYH değerleri	38
Tablo 4. 4. Organoid Teknolojisi Alt Sınıf IPC Kodları Patent Sayıları Tahmin Tablosu	39
Tablo 4. 5. Organoid Teknolojisi İçin Alt Sınıf IPC Kodlarına Göre 2024, 2025 ve 2026 Yılı Patent Sayısı Tahminleri ve Artış Oranları.....	40
Tablo 4. 6. Yapay Organ Teknolojisi ARIMA Modeli OMYH Değerleri	42
Tablo 4. 7. Yapay Organ Teknolojisi Alt Sınıf IPC Kodları Patent Sayıları Tahmin Tablosu.....	43
Tablo 4. 8. Yapay Organ Teknolojisi İçin Alt Sınıf IPC Kodlarına Göre 2024, 2025 ve 2026 Yılı Patent Sayısı Tahminleri ve Artış Oranları.....	44
Tablo 4. 9. Biyobaskı Teknolojisi ARIMA Modeli OMYH Değerleri	47
Tablo 4. 10. Biyobaskı Teknolojisi Alt Sınıf IPC Kodları Patent Sayıları Tahmin Tablosu	48
Tablo 4. 11. Biyobaskı Teknolojisi İçin Alt Sınıf IPC Kodlarına Göre 2024, 2025 ve 2026 Yılı Patent Sayısı Tahminleri ve Artış Oranları.....	49

SİMGELER VE KISALTMALAR

Simgeler

β_i : i dışsal (exogenous) değişkenin katsayısı, bu değişkenler serinin dışından gelen ek bilgileri temsil eder ve modeldeki etkilerini açıklar.

c : Sabit terim, modeldeki kesim noktasını temsil eder.

d : Entegrasyon derecesi, serinin fark alınarak durağan hale getirilmesi gereken kez sayısı.

ε_t : t zamanında rastgele hata terimi.

ϕ_i : i gecikmeli otoregresif terimin katsayısı.

M : Toplam pazar potansiyeli, ürünü veya yeniliği potansiyel olarak benimseyebilecek toplam birey sayısı.

$N(t)$: Zaman tt itibariyle ürünü veya yeniliği benimseyenlerin kümülatif sayısı

θ_j : j gecikmeli hareketli ortalama terimin katsayısı.

p : İnovasyon katsayısı, popülasyondaki bireylerin dış etkilere bağlı olarak yeni ürünü veya yeniliği benimseme oranı,

q : İmitasyon katsayısı, mevcut kullanıcılarla etkileşim yoluyla yeni ürünü veya yeniliği benimseme oranı,

X_t : t zamanında gözlemlenen serinin değeri.

$Z_{i,t}$: i dışsal değişkenin t zamanındaki değeri.

Kısaltmalar

AIC Akaike Bilgi Kriteri (Akaike Information Criterion)

Ar-Ge Araştırma ve Geliştirme

AR Otoregresif (AutoRegressive)

ARIMA Otoregresif Bütünleşik Hareketli Ortalama
(AutoRegressive Integrated Moving Avarage)

ARIMAX	Dış Değişkenli Otoregresif Bütünleşik Hareketli Ortalama (AutoRegressive Integrated Moving Avarage with Exogeneous Variables)
APO	Avrupa Patent Ofisi (European Patent Office)
BIC	Bayesyen Bilgi Kriteri (Bayesian Information Criterion)
BDM	Bass Difüzyon Modeli
ÇEA	Çapraz Etki Analizi (Cross-Impact Analysis)
DDİ	Doğal Dil İşleme
GP	Genişleme Potansiyeli
IPC	Uluslararası Patent Sınıflandırması (International Patent Classification)
İBG	İzmir Biyotıp ve Genom Merkezi
MA	Hareketli Ortalama (Moving Avarage)
OKHK	Ortalama Kareler Hatası Karekökü
OMYH	Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error)
PG	Patent Gücü
RMSE	Ortalama Kareler Hatası (Root Mean Square Errors)
SA	Senaryo Analizi
SD	Sistem Dinamiği
TYH	Teknoloji Yayılma Hızı
TT	Teknoloji Tahmini
TYD	Teknoloji Yaşam Döngüsü
TY	Teknoloji Yönetimi
TNN	Zaman Serisi Sinir Ağları (Time Series Neural Network)
YSA	Yapay Sinir Ağları

1. GİRİŞ

1.1. Ön Bilgi

Organoid teknolojisi, 2012 yılında Gurdon ve Yamanaka tarafından çok potansiyelli kök hücreler çalışmalarıyla Nobel ödülü alınmasıyla insan gelişimi, hastalık ve terapötik potansiyel hakkında paha biçilmez bilgiler sunarak, rejeneratif tıp ve insan biyolojisi anlayışımızı önemli ölçüde geliştirmiştir.

Yapay organ teknolojisi, hastalıklı veya hasar görmüş organların yerine daha sağlam, etkili ve gerçeğe yakın ikameler üretmek amacıyla geliştirilmelerinden ve büyük ölçüde nanoteknoloji, kök hücre araştırmaları ve biyomateryallerdeki gelişmelere bağlı olduğundan uzun yıllardır çalışılan, sağlık alanının en büyük teknoloji alanlarından bir tanesidir.

Biyobaskı teknolojisi ise, organ kıtlığı krizine umut verici bir çözüm olarak görüldüğü ve transplantasyon ve tıbbi araştırmalar için fonksiyonel doku ve organ üretme potansiyeli sunan sağlık alanının yenilikçi teknolojileri arasındadır.

Bu teknolojilerin büyüklüğü, yenilikçiliği ve daha önceki çalışmalarda birbirleri arasında yatırım analizi yapılmamasından dolayı, bu tez kapsamında organoid, yapay organ ve biyobaskı teknolojilerinin patent verilerinden yararlanılarak patent madenciliği yöntemiyle bu teknolojilerin hangi teknoloji alt alanlarına yatırım yapılabilir sorusuna yanıt aranacaktır. Seçilen teknolojiler günümüz şartlarında popüler ve yukarıda bahsedildiği üzere, sağlık alanında yıkıcı teknoloji olarak sayılabilecek teknolojiler olduğu için seçilmiştir. Bu bölümün ilerleyen kısımlarında tez kapsamındaki problemin tanımı, teze ilişkin motivasyon ve tezin organizasyonu yer almaktadır.

1.2. Problemin Tanımı

İşletmeler ve bireysel yatırımcılar, kendi şirketlerinin güçlü ve zayıf yönlerini değerlendirmek ve gelecekteki iş geliştirme için en iyi eylem planını seçmek amacıyla rakiplerinin teknoloji geliştirme çabalarından haberdar olmalıdır. Patent belgeleri rekabet analizi için güvenilir bir kaynak olarak ön plana çıkmaktadır. Bir teknolojinin hem özel olarak kullanılmasını hem de başkalarının onu yaratmasının engellenmesini sağlayan

patentler, arařtırmaya yapılan yatırımların bir sonucu olarak görölmektedir. Uygulama eğilimi, kuruluşun çeřitli teknoloji alanlarını nasıl deęerlendirdiđini göstermektedir ve arařtırma ve geliřtirme (Ar-Ge) harcamaları ile patent trendi arasında yüksek bir korelasyon olduđu da bu sebepten dolayı ařıkardır [1].

Yapılan arařtırmalara göre geliřmekte olan ve nispeten benzer alanlara hizmet eden organoid, yapay organ ve biyobaskı teknolojileri için hangi alanlara daha fazla etki ettiđini görebilmek ve bu alanlara yatırım kararı alabilmek için hem řirketler hem de bireysel yatırımcılar için öngörü oluřturabilecek teknoloji tahmini (TT) yapmak çok kritiktir.

TT için literatürde birçok yöntem (Bass modeli, Delphi yöntemi, sistem dinamiđi, çapraz etki analizi vb.) olmasına rađmen patent verilerinin veri madenciliđi tekniklerini kullanarak iřlenip tahminlerin oluřturulduđu patent madenciliđi yöntemi bu tez kapsamında uygulanacaktır.

Veri madenciliđi uygulamalarındaki veri, patent verilerinden oluřursa buna “patent madenciliđi” denmektedir. Veri madenciliđinde ve patent madenciliđinde iki tür yaklařım vardır. Bu yaklařımlar tahmine dayalı ve tanımlayıcı yaklařımlardır [2]. Patent madenciliđi, patent verilerini inceleyerek gelecek vaat eden teknolojileri tahmin etmeye yönelik metodolojik bir yaklařımdır. Bu süreç, belirli teknolojik alanları belirlemek için patentlerin kümelenmesini ve bu kümelerin ileriye dönük alıntılar ve patent aileleri gibi göstergeler kullanılarak deęerlendirilmesini içerir. Amaç, yenilik ve stratejik Ar-Ge yatırımı için yüksek potansiyele sahip teknolojileri nesnel bir řekilde belirlemek, teknoloji yönetimi ve tahminde veriye dayalı karar almayı kolaylařtırmaktır [3, 4]. Tez kapsamında tahmine dayalı patent madenciliđi tekniđi olan zaman serisi yöntemi kullanılacaktır.

Bu tez, organoid, yapay organ ve biyobaskı teknolojilerinin gelecek potansiyellerini deęerlendirerek, bu teknolojilerin teknoloji yařam döngüleri (TYD), teknoloji yayılma hızları (TYH), patent güçleri (PG) ve geniřleme potansiyelleri (GP) açısından karřılařtırmalı bir analiz yapmayı amaçlamaktadır. Ayrıca, patent verileri üzerinden patent madenciliđi ile zaman serisi analizi tekniklerini kullanarak, bu teknolojiler arasındaki patent sınıflandırmaları, patent sayıları ve yayılım hızlarını deęerlendirilecek, teknoloji yařam döngüsü farklılıkları ve yatırım için uygun teknoloji alanlarını belirlemeye çalışılacaktır.

TYD, TYH, PG ve GP göstergeleri literatürde savunma sanayi, blok-zincir, elektrikli araçlar ve özellikle sağlık alanında patent analizi yapmak için kullanılan genel yöntemlerdendir [5-7]. Buna ek olarak patent madenciliğinde de zaman serisi modelleri patent sayılarının ileriye dönük tahminlerinin yapılmasını sağlamaktadır. Bu tez kapsamında bahsedilen dört gösterge bir arada hesaplanarak teknolojiler arasındaki farklardan bahsedilmesinin yanı sıra zaman serisi modelleriyle de yatırım için uygun teknoloji alanlarının belirlenecek olması bu tezin literatürdeki özgünlüğünü yansıtmaktadır.

Bu çalışmanın sonuçları, şirketlerin ve bireysel yatırımcıların bu alanlara yönelik yatırım kararlarına bilimsel bir temel oluşturmayı hedeflemektedir.


1.3. Motivasyon

Literatürde teknoloji tahmini yapılırken problem tanımı bölümünde bahsi geçen göstergelerden bir veya iki tanesi birlikte kullanılarak tahmin yapılmıştır [8-10]. Organoid, yapay organ ve biyobaskı teknolojileri için ortak teknoloji tahmini yapılmamış olması ve bölüm 1.2'de bahsedilen gösterge ve patent madenciliği yönteminin bu tez kapsamında birlikte yapılıyor olması literatürdeki beş farklı yöntemin bir arada kullanılmasını sağlayacaktır ve bu tez kapsamında literatürdeki bu açık giderilecektir.

Ayrıca, yapılan çalışmada yaklaşık 34 bin patent verisi üzerine çalışılacaktır. Yapılan çalışmanın farklı alanlarda da aynı yöntemler uygulanarak şirketlere ve bireysel yatırımcılara yatırım önerisi sunabileceği ve ticari karar verme konusunda önemli bir etki yaratma potansiyeli olması bu tezin en büyük motivasyon kaynaklarından bir tanesidir.

1.4. Tezin Organizasyonu

Bu tez, Şekil 1.1'de görüldüğü üzere, giriş bölümünden sonra tez kapsamındaki çalışmalara ilgili olacak ilgili arka plan çalışmasıyla ikinci bölümde devam edecektir ve üçüncü bölümde kullanılacak yöntemler metodoloji başlığı altında detaylı olarak anlatılacaktır. Dördüncü bölümde anlatılan yöntemler uygulanarak gerekli analizler yapılacak ve beşinci bölümde analiz sonuçları değerlendirilecek ve gelecekte bu alanda yapılabilecek çalışmalar ile ilgili öngörülerden bahsedilecektir.



Şekil 1. 1. Tez Organizasyonu Şeması

2. İLGİLİ ARKA PLAN

2.1. Organoid, Yapay Organ ve Biyobaskı Teknolojisi

2.1.1. Organoid Teknolojisi

Oxford sözlüğünde tanımlandığı şekliyle organoidler, organları taklit eden yapay olarak oluşturulmuş hücre veya doku kütleleridir [11]. Öte yandan insan organlarının son derece ayrıntılı minyatür modelleri olan organoidler, son yıllarda biyomedikal araştırmalarda devrim niteliğinde bir araç olarak ortaya çıkmaktadır.

Bu teknoloji, basit hücre kültürleri kullanarak organ fizyolojisini modellemeye yönelik ilk girişimlerle başlamıştır ve gerçek insan organlarının mimarisini ve işlevini doğru bir şekilde taklit eden karmaşık 3 boyutlu yapılara dönüşmüştür [12].

Geçmiş yıllardan beri organoid benzeri yapılarla ilgili çalışmalar yapılsa da geçtiğimiz 10 yıldır çalışmalar hız kazanmış ve teknoloji gelişimi büyük bir ivme yakalamıştır.

1944 yılında organoid benzeri oluşumların ilk keşiflerine kadar uzanan organoid teknolojisinin evrimi büyüleyici bir bilimsel keşif ve icat hikayesidir. Bu yolculuk, 1907'deki erken teratom araştırmalarıyla başlamıştır; bu araştırmalar, farklı hücre türlerinin karmaşık doku benzeri yapılar oluşturma yeteneğinin anlaşılmasında kritik öneme sahipti. Çeşitli dokuları içerebilen teratomlar, hücre farklılaşma kapasitesini araştırmak için kullanılmıştır [13].

1960 ve 1964 yılları arasında, çok sayıda doku tipini organoid formlarda bir araya getirmek için temel inşa edilmiş ve bu, doku düzenleme ilkelerine dair iç görü sağlamıştır [14].

1981 ve 1987 yılları arasında pluripotent kök hücreler karakterize edilmiştir; bu da rejeneratif tıp ve hücre terapisinde yeni uygulamaların önünü açmıştır. Pluripotent kök hücreler, herhangi bir hücre tipine farklılaşma potansiyeli ile organoidlerin geliştirilmesinin temelini oluşturmuştur. Bununla birlikte, 1998 yılında ilk insan embriyonik kök hücre dizisinin keşfi, gelişimsel biyoloji ve hastalık modellemede yeni bir çağ başlatmıştır. Erken embriyodan üretilen embriyonik kök hücreler, insan gelişimi ve hastalık süreçlerine ilişkin anlayışımızda devrim yaratma potansiyeline sahiptir. Daha sonra, 2000'li yıllardaki gelişmeler, yetişkin bağırsak kök hücrelerinden organoidlerin

oluşturulması ve 2011-2014 yılları arasında farklı organ modellerine ek çeşitlilik sağlanmasıyla, özellikle 2008-2009 yılları arasında 3 boyutlu kültür sistemlerinin değerini ortaya koymuştur. Bu sistemler, in vitro araştırmalar ile in vivo biyoloji arasındaki boşluğu doldurarak, insan gelişimi, hastalık ve terapötik potansiyel hakkında bilgiler sunarak, rejeneratif tıp ve insan biyolojisi anlayışını önemli ölçüde geliştirmiştir [13].

Tez kapsamında toplanan patent verilerinden derlenen ve organoid teknolojisine ilişkin hangi alanları kapsadığını gösteren şema Şekil 2.1’de gösterilmektedir.



Şekil 2. 1. Organoid Teknolojisi ile İlişkili Teknoloji Alanları

Organoid teknolojisinin teknoloji alanlarına bakıldığında kök hücre alanında özellikle nobel almış bir çalışmayı içerisinde barındıran çok potansiyelli kök hücreler (pluripotent stem cells) büyük alan kapsamaktadır. Bunun dışında hücre kültürleri, kanser hücreleri, hastalık tedavi yöntemleri, in vitro yöntemi ve nükleik asit çalışmaları organoid teknolojinin hitap ettiği alanları oluşturmaktadır.

2.1.2. Yapay Organ Teknolojisi

Organoid teknolojisine benzer ama bazı temel farklılıkları bulunan yapay organlar, organoidlere göre daha uzun yıllardır (yaklaşık 40 yıl) aktif olarak çalışılan bir alandır ve teknolojik gelişim ömrünü günümüzde devam ettirmektedir.

Yapay karaciğerler, pankreaslar, kalpler ve akciğerler gibi karmaşık cihazların geliştirilmesiyle yapay organlar alanı muazzam bir büyüme yaşamıştır. Bu ilerlemeler sıklıkla, tüm organların işlemlerini taklit edebilecek sistemler oluşturmak için makine ve kimya mühendisliği, malzeme bilimi, hücre biyolojisi ve diğer alanlardan gelen bilgilerin kullanıldığı çok disiplinli iş birliklerinden kaynaklanmıştır. Yapay organlara yönelik gelecekteki olasılıklar arasında organ reddi olasılığının azaltılması, organların biyoyumluluğunun ve işlevselliğinin artırılması ve vücudun doğal sistemleriyle entegrasyonunun güçlendirilmesi yer almaktadır. Ayrıca, hastalıklı veya hasar görmüş organların yerine daha sağlam, etkili ve gerçeğe yakın ikameler üretmek amacıyla yapay organların geliştirilmesinin büyük ölçüde nanoteknoloji, kök hücre araştırmaları ve biyomateryallerdeki gelişmelere bağlı olacağı öngörülmektedir [15].

Tez kapsamında toplanan patent verilerinden derlenen ve yapay organ teknolojisine ilişkin hangi alanları kapsadığını gösteren şema Şekil 2.2’de gösterilmektedir.



Şekil 2. 2. Yapay Organ Teknolojisi ile İlişkili Teknoloji Alanları

Yapay organ teknoloji alanları incelendiğinde özellikle yapay doku teknoloji alanı büyük bir yer kaplamaktadır. Çünkü yapay organlar, yapay dokular ile ilgili çalışmalar sonucu ortaya çıkmış bir teknolojidir. Bununla birlikte, yapay organ teknolojisi, organoid teknolojisinin de hitap ettiği hücre kültürleri alanı, yüzey teknolojileri, tıbbi cihaz, malzeme bilimi ve hücre büyüme faktörleri alanlarına da hitap etmektedir.

2.1.3. Biyobaskı Teknolojisi


Organoid ve yapay organ teknolojilerine benzer fakat teknolojinin gelişmesiyle daha yeni bir teknoloji olan biyobaskı (bioprinting) teknolojisi de bu alanda değerlendirilmesi gereken bir diğer yıkıcı teknolojidir.

Biyobaskı, hücrelerin, biyomateryallerin ve biyomoleküllerin sınırlı üç boyutlu yapılar içerisine hassas bir şekilde yerleştirilmesine olanak tanıyan, doku mühendisliği alanında doku ve organ yapılarını etkili bir şekilde üreten bir teknolojidir. Mürekkep püskürtmeli, basınç destekli ve lazer destekli biyobaskıyı içeren bu teknoloji, damar sistemi, kalp, kemik ve cilt dokuları gibi ayrıntılı ve işlevsel doku yapıları oluşturmak için biyomateryaller, hücreler veya hücre faktörlerinden oluşan bir "biyo mürekkep" kullanır [16].

Biyobaskılamamanın tarihi, 2000'li yıllardaki ilk yeniliklerden, organ kıtlığı krizine umut verici bir çözüm olarak görüldüğü ve transplantasyon ve tıbbi araştırmalar için fonksiyonel doku ve organ üretme potansiyeli sunan mevcut durumuna kadar uzanmaktadır. Biyobaskı, sağlık hizmetleri ve doku mühendisliğindeki uygulamalarını genişleterek ve yeteneklerini geliştirerek devam eden ilerlemelerle rejeneratif tıpta devrim yaratma ihtimalini taşımaktadır [17].

Biyobaskı, teknolojik gelişmeler ve artan klinik ve ticari ilgiler doğrultusunda günümüzde de gelişmeye devam etmektedir.

Tez kapsamında toplanan patent verilerinden derlenen ve yapay organ teknolojisine ilişkin hangi alanları kapsadığını gösteren şema Şekil 2.3'de gösterilmektedir.



Şekil 2. 3. Biyobaskı Teknolojisi ile İlişkili Teknoloji Alanları

Biyobaskı teknolojisinin etkilendiği ilişkili teknoloji alanları incelendiğinde özellikle 3 boyutlu biyobaskı, biyo mürekkep, 3 boyutlu dokular ve baskı yöntemleri alanları ön plana çıkmaktadır. Biyobaskı teknolojisi, hem organoid hem de yapay organ teknolojilerinin de ilişkili olduğu hücre kültürleri, kök hücre ve doku mühendisliği gibi alanlarla da ilişkilidir.

Yukarıda bahsi geçen üç teknoloji, insan biyolojisini daha iyi anlamak, daha etkili ilaçlar geliştirmek ve organ onarımı veya değişimi için potansiyel olarak yeni çözümler sunmak için farklı yöntemler sağlayarak rejeneratif tıp alanına toplu olarak katkıda bulunmaktadır.

2.2. Teknoloji, Teknoloji Yönetimi ve Teknoloji Tahmininin Önemi

Teknoloji, "technicos" (teknik, yöntemli ve düzenli çalışma) ve "logia" (konuşma, ifade) terimlerinin bir araya gelmesiyle oluşur. Bu kelime sanat yaratmaya veya iş yapmaya yönelik sistematik bir yaklaşımı temsil eder. Günlük yaşamda teknoloji çoğu zaman somut bir bileşen veya araç olarak algılanmaktadır; örneğin bir elektronik cihaz, bir transistör veya bir parça teknolojinin kendisi olarak kabul edilir. Ancak teknoloji, yeni ve değerli ürünlerin üretilmesine katkıda bulunan bir bilgi birikimi olarak anlaşılmalıdır [18]. Ekonomik bir değer olarak da değerlendirilebilecek teknoloji, dünya çapında

ekonomik sonuçlara yol açmaktadır. Sanayi devrimleri, yeni sistemler getirmenin ve belirli teknolojileri geliştirerek ekonomik büyümeyi tetiklemenin en güzel örnekleridir.

Teknolojiyle ilgili en kritik endişelerden biri onun nasıl büyüüp değiştiğidir. Teknolojinin gelişim nedeni bilindiğinde onu tahmin etmek daha kolay olacaktır [19].

Teknolojik gelişmeleri takip etmek için ölçülebilir kriterler kullanıldığında belirli bir modeli takip ettikleri görülmektedir [20]. Teknolojinin fiziksel sınırlarına yaklaştıkça ilerleyişini temsil eden sezgisel bir model, bu eğilimin bir örneğini oluşturan teknoloji yaşam döngüleri tarafından sağlanmaktadır [19].

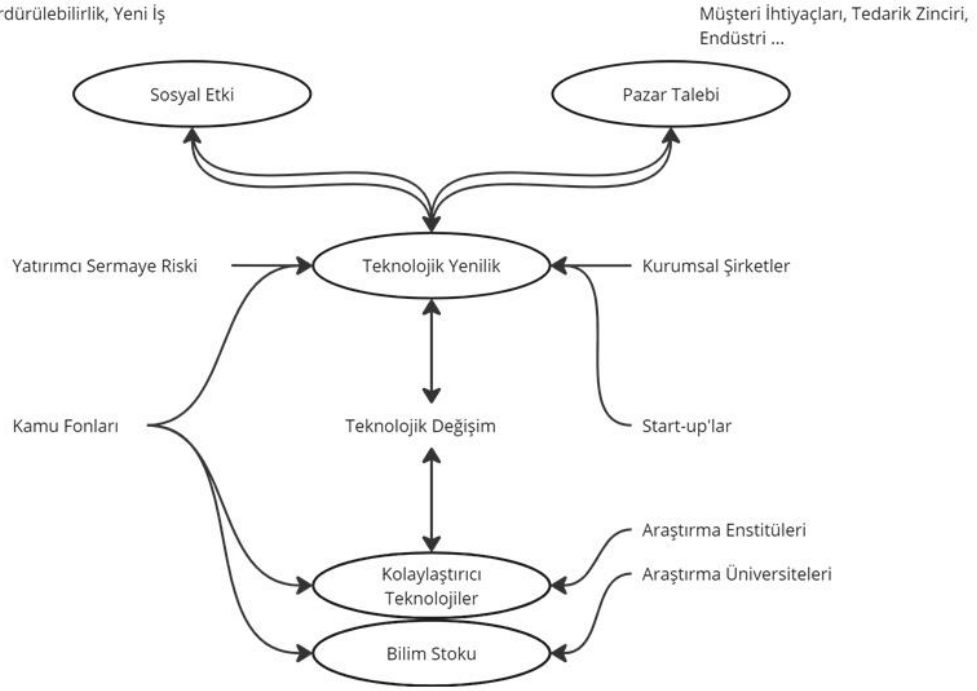
Teknoloji yönetimi (TY), teknolojiyi, karlılığı, üretkenliği ve rekabet gücünü optimize eden mal ve hizmetler üretirken bir organizasyonun operasyonel ve stratejik yeteneklerini oluşturan kurumsal bir kaynak olarak inceler [18]. Teknolojinin keşfedildiği andan itibaren stratejik bir plan dâhilinde yönetilmemesi, ömrünün kısalmasına neden olabilir. Her kısa ömürlü teknoloji kötü yönetimden kaynaklanmadığı gibi, teknoloji yönetiminin önemi de hem teknolojinin uzun ömürlülüğü hem de doğru kullanımı ve gelişen şirketlerin karlılığının artması açısından kritik öneme sahiptir.

Teknolojinin etkin ve verimli kullanımı, yönetimi ve uygulanması, çok disiplinli teknoloji yönetimi disiplininin kapsadığı konulardır. İşletmeler ve hükümetler için teknolojik değişimin seçimini, kullanımını ve yönetimini ele alır. Rekabet avantajı kazanmak, yeniliği teşvik etmek, üretkenliği artırmak ve genel kurumsal hedeflere ulaşmak için teknolojiyi stratejik bir araç olarak kullanmak, teknoloji yönetimi olarak bilinir. Teknoloji yönetimi bir organizasyonun uzun vadeli performansını etkileyen en önemli faktörlerden biridir [21].

Yukarıda tartışılanlara ek olarak teknoloji yönetimi, teknoloji tahmini, politika araştırması, bilgi sistemleri, bilgi ve iletişim teknolojisi, yapay zeka, veri tabanı teknolojisi ve yönetimi, modelleme ve istatistiksel metodoloji gibi işlevlerden oluşur [22].

Şekil 2.4'de teknolojik değişimin merkezinde olduğu ve sosyal etki, pazar talebi, teknolojik yenilik ve bunu mümkün kılan teknolojilerle çevrelendiği dört ana bölüm bulunmaktadır. Sosyal etki; eğitim, etik, istihdam ve sürdürülebilirlik gibi konuları içerir. Pazar talebi ise; müşteri ihtiyaçları, sektör yapısı ve tedarik zinciri gibi faktörlerden etkilenir. Teknolojik yenilik ve değişim, yatırımcıların sermaye riskleri ve kamu fonları gibi finansal kaynaklarla beslenirken, araştırma enstitüleri ve üniversiteler gibi bilimsel kurumların sağladığı bilimsel stoklarla da desteklenmektedir. Bu teknolojik yenilik ve

değişim sürecinde start-up'lar ve köklü kurumsal şirketler önemli roller üstlenirler. Şekil 2.4, teknolojik değişimin karmaşık doğasını ve farklı bileşenler arasındaki etkileşimi vurgulamaktadır. Burada da görüldüğü gibi teknoloji tahmini karmaşık ve zorlu bir süreçtir. Tüm girdileri alarak model oluşturmak zor olduğundan bazı faktörler göz ardı edilerek çeşitli analizler yapılmaktadır [23].



Şekil 2. 4. Teknolojinin Değişimi

Teknoloji tahmini (TT), sağlam bir teknoloji yönetimi planının bir diğer önemli bileşenidir. Gelecekteki teknolojik büyüme modellerini tahmin etmede önemli bir ilk adım, uzun vadeli bilimsel, teknik, ekonomik ve sosyal eğilimleri araştıran teknoloji tahminidir. TT, şirketlere, kullanıcılara ve politika yapıcılara işlerinin çeşitli yönleriyle ilgili olarak, özellikle rekabet gücünü artırarak yararlı bilgiler sunabildiğini göstermiştir [24].

TT, yeniliğin yayılmasıyla ilgilidir. Ayrıca TT, teknolojinin uzun vadeli konumunu ve olası etkilerini değerlendirir. Zamana karşı yeniliği benimseyen nüfusun oranının grafiği, S eğrisi şeklini özelliğini göstermektedir [25]. Ayrıca, talep tahmin tekniklerinin kullanılması teknoloji tahminini makul ölçüde mümkün kılar. Henüz üretilmemiş süreç ve ürünlerin maliyetlerini öngörmesi açısından diğer planlama tekniklerinden farklılık

gösterir. Bu nedenle işletmeler, günümüzün hızlı tempolu pazarında yeni ürünlerin başarılı olma olasılığını değerlendirmek için sıklıkla teknoloji tahmininden yararlanmaktadır [19].

2.3. Teknoloji Tahmini Yöntemleri

TT için bazı yöntemlerden burada bahsedilmektedir. Bunlar arasında Bass difüzyon modeli, Delphi yöntemi, senaryo analizi, trend analizi, çapraz etki analizi, sistem dinamiği ve patent analizi yer almaktadır. Bunları kısaca özetledikten sonra bu çalışma kapsamında uygulanacak patent madenciliği yöntemine daha detaylı değinilecektir.

TT’de çeşitli yaklaşımlar oluşturulmuştur; bunlar arasında, 1969’da oluşturulan Bass difüzyon modeli (BDM), en sık başvurulan ve karşılaştırılan yöntemdir. Genelleştirilmiş lojistik, Gompertz benzeri ve Richards benzeri modeller gibi diğer büyüme modelleri, inovasyon yayılımlarının olağan “S” şeklindeki kümülatif profillerini açıklamak için ortaya atılmış olsa da, BDM istikrarlı bir şekilde kabul edilen model haline gelmiştir [26].

BDM’nin en temel matematiksel modeli ve açıklaması aşağıda verilmiştir [27].

$$\frac{dN(t)}{dt} = p \cdot (M - N(t)) + q \cdot \frac{N(t) \cdot (M - N(t))}{M} \quad (1)$$

- $N(t)$: Zaman t itibariyle ürünü veya yeniliği benimseyenlerin kümülatif sayısı
- p : İnovasyon katsayısı, popülasyondaki bireylerin dış etkilere bağlı olarak yeni ürünü veya yeniliği benimseme oranı,
- q : İmitasyon katsayısı, mevcut kullanıcılarla etkileşim yoluyla yeni ürünü veya yeniliği benimseme oranı,
- M : Toplam pazar potansiyeli, ürünü veya yeniliği potansiyel olarak benimseyebilecek toplam birey sayısı.

BDM, pazarda benzersiz olan yeni bir ürünün (genel olarak yeni ürünler) benimsenmesini tahmin etmek için değerli bir araçtır. Model, sonuçta kaç müşterinin ürünü benimseyeceğini ve ne zaman benimseyeceklerini tahmin etmeye çalışmaktadır [28]. Model ilk olarak dayanıklı tüketim mallarında test edilmiş ve ürün yaşam döngüsü

boyunca satışların hem zamanlaması hem de büyüklüğü konusunda doğru tahminler sağladığı kanıtlanmıştır [29].

BDM, yeni ürün yayılımını tahmin etmek için kullanılmaktadır ancak sabit parametrelerin kullanılması, bireysel tüketici davranışlarının ve pazar bölümlenmesinin göz ardı edilmesi ve pazarlama stratejileri gibi dış faktörlerin yeterince dikkate alınmaması gibi dezavantajları vardır. Bu sınırlamalar, dinamik piyasa koşullarında modelin etkinliğini azaltabilir. Ayrıca, BDM, ilgilenecek teknolojiye benzer daha eski teknolojilerin satış verilerine ihtiyaç duyduğundan veri toplama açısından dezavantajlı bir yöntemdir.

Delphi yöntemi, alanında uzman kişilerden oluşan geniş uzman katılımını gerektirir ve genellikle uzun vadeli teknolojik tahminler için uygundur. Bu yöntem, kapsamlı bir araştırma sürecini ve çok çeşitli uzmanların görüşlerinin derlenmesini içerir [30]. Bu yaklaşım olağanüstü sonuçlar doğurabilir ancak dezavantajları arasında öznel karakteri ve yüksek maliyeti yer alır. Çünkü bu yöntemle yapılan araştırmalar hem alanında uzman kişileri bulmak hem de mülakat ve anket görüşlerini toplamak açısından uzun zamanlara yayılarak yapılır.

Senaryo analizi (SA) esas olarak belirsiz ve değişken gelecek koşullarında tahmin yapmak için kullanılır. Bu analizde öncelikle analizin odaklanacağı ana konu veya karar alanı belirlenir. Yerel çevrede bu kararı etkileyecek temel güçler ikinci adımda belirlenir. Üçüncü adımda sosyal, ekonomik, politik, çevresel ve teknolojik olmak üzere çeşitli itici güçlerin bir listesi oluşturulmakta ve bu güçlerin stratejik makro-çevresel ve teknolojik etkileri sorgulanmaktadır. Dördüncü adımda, bu temel faktörler ve etkenler önem ve belirsizlik sırasına göre sıralanır. Beşinci adımda senaryoların farklılaştırılmasında temel eksen görevi görececek senaryo mantıkları seçilir. Altıncı adımda, seçilen senaryo mantığı ile senaryoların iskeleti oluşturulmakta ve ardından birinci ve üçüncü adımlarda belirlenen temel faktörlere ve eğilimlere dönülmektedir. Bu sistematik yaklaşım, olası gelecek senaryolarını çok yönlü bir bakış açısıyla ele alır ve derinlemesine bir değerlendirme sunma fırsatı sunmaktadır [31].

Bu nedenle senaryo analizi, uzun vadeli tahminlerde yardımcı olur ve sıklıkla gelecekteki olayların kapsamlı açıklamalarını içerir. Ancak bu yöntemin dezavantajları zaman alıcı, yüksek kalitede ve yüksek maliyetle yapılıyor olmasıdır.

Trend analizi geçmiş zaman serilerine bakar ve gelecekteki potansiyel trendleri tahmin etmek için büyüme modellerini kullanır. Bu yöntem, bir eğilimi etkileyen faktörlerin gelecekte de devam edeceği varsayımıyla geçmiş verilere bir eğri uydurmayı gerektirir. Bu tür eğilim tahminlerinin güvenilirliği, gelecek ufku birkaç yılın ötesine uzatıldığında sıklıkla “basit” (naïve) olarak nitelendirildikleri için azalmaktadır [10].

Bu nedenle trend analizi, tahmin zamanı uzatıldığında eksik ve sınırlı bilgiler verebilir ancak teorik olarak da analizlerde bir başlangıç noktası olarak kullanılabilir.

Trend analizinin dezavantajlarından bahsetmek gerekirse, yöntemin öncelikle geçmiş verilere dayanması ve bu verilerin en iyi model optimizasyonu gibi yöntemlerle seçim yapılmadığı için gelecekteki trendleri doğru şekilde yansıtma yeteneğinin sınırlı olmasıdır. Geçmiş veriler, özellikle dış şoklar veya beklenmedik olaylar olmak üzere gelecekteki değişiklikleri tahmin etmede yetersiz kalabilir. Ek olarak, yukarıda da belirtildiği üzere trend analizi için belirsizliklerin uzun süreler boyunca artması nedeniyle uzun vadeli tahminler daha az güvenilirdir ve bu da geçmiş verilere dayalı modellerin doğruluğunu azaltabilir.

Çapraz etki analizi (ÇEA), bir olayın ortaya çıkmasının veya öngörülmesinin bir dizideki diğer olaylar üzerindeki olası nedensel etkilerini değerlendirmek için kullanılır. Bu yöntem, siyaset, toplum veya teknolojiadaki olayların diğer olayların meydana gelme olasılığını temel olarak nasıl etkilediğini belirlemek için oluşturulmuştur. ÇEA, çeşitli temasları içeren karmaşık durumları yönetme kapasitesi nedeniyle büyük saygı görmektedir. Metodolojinin esnekliği onu en yaygın kullanılan senaryo oluşturma ve analiz yaklaşımlarından biri olarak öne çıkarmaktadır [32].

Bununla birlikte, yaklaşımın bazı dezavantajları da vardır. Özellikle büyük etkinlik grupları için bunu uygulamak zor ve zaman alıcı olabilmektedir. Etki olasılıkları öznel değerlendirmeler kullanılarak tahmin edildiğinde önyargılar ortaya çıkabilmekte ve karmaşık gerçek dünya etkileşimleri yeterince yansıtılamamaktadır. Ayrıca, katılımcıların deneyimi ve bilgisi ÇEA'nın kalitesinde önemli bir role sahiptir; bu da, geniş bir uzman bakış açısı yelpazesinin mevcut olmaması durumunda bir kısıtlama olabilir [32].

Teknoloji tahmininde kullanılan bir diğer yöntem de sistem dinamiği (SD) yöntemidir. Karmaşık sistemlerin zaman içindeki davranışını anlamak ve simüle etmek için kullanılan metodolojik çerçeveye sistem dinamiği adı verilir. Bir sistemin dinamik davranışını doğru

bir şekilde yakalayan bir simülasyon modeli oluşturmak için stokları, akışları, geri bildirim döngülerini ve zaman gecikmelerini kullanmaktadır. Özellikle geleneksel doğrusal tekniklerin bunları çözmede etkili olduğu gösterilmediği takdirde, karmaşık stratejik, politika ve operasyonel konular SD ile ele alınabilmektedir. Karar vericilerin zaman içindeki olası sonuçları incelemesine ve karmaşık ilişkileri ve sistemik gecikmeleri hesaba katarak çözümleri değerlendirmesine olanak tanımaktadır [33].

Yukarıda bahsedilenlere ek olarak, teknolojiyi tahmin etmenin en önemli tekniklerinden bir tanesi de patent analizidir. Çünkü daha önce incelenmiş ve değerlendirilmiş patent verileri, her buluş veya keşif hakkında bibliyografik verilerin yanı sıra teknoloji hakkında da güvenilir bilgi sağlamaktadır. Önceki araştırmalar, patent verilerinin ve bu patentlere yapılan alıntılarının miktarının, patentle ilgili teknolojide gelecekteki gelişmeleri tahmin etmek için kullanılabileceğini göstermiştir. Ayrıca patentlerin hem başvuru hem de tescil süreçlerinde çeşitli özelliklere göre değerlendirilmesi nedeniyle, veri setinde bulunması gereken büyük miktarda ve farklı özellikleri içerisinde barındıran çok çeşitli verinin tekrar değerlendirmesine ihtiyaç duyulmadığından, patent verilerin kullanılması daha az veri kullanarak doğru bulgulara ulaşmaya yardımcı olabilmektedir.

Literatür araştırmalarına göre patent analizi çeşitli sektörlerde çeşitli modifikasyonlarla uygulanmaktadır. Teknoloji alanlarından bazıları bilişim, savunma, sağlık, enerji gibi büyük teknoloji alanlarıdır. En yaygın olarak çalışılan alanların başında da blokzincir, silah endüstrisi, elektrikli araçlar ve yenilenebilir enerji gelmektedir. [6, 7, 9, 34-38].

Ayrıca araştırmacıların incelediği bazı çalışmalarda teknolojinin yayılma hızı, patent gücü, patent puanı vb. analiz ve değerlendirmeler sonucunda patent verileri için çeşitli ve teknolojilerin karşılaştırılabildiği göstergeler oluşturulmaktadır [9]. Bu göstergeler patentlerden oluşturulan yeni göstergeler olduğundan teknoloji tahmini yapılmasına farklı bir bakış açısı sunmaktadır.

Veri madenciliği, büyük veri kümelerindeki değerli, beklenmedik veya ilginç yapıların keşfedilmesini içeren bir süreçtir ve bu disiplinler arası yöntem istatistikten, makine öğreniminden, veri tabanı teknolojisinden ve daha fazlasından yararlanır. Veri madenciliğinde iki tür yaklaşım vardır. Bu yaklaşımlar tahmine dayalı ve tanımlayıcı yaklaşımlardır [2]. Tahmine dayalı yaklaşımlarda teknoloji tahmini yapılırken atıf ve başvuru sayıları gibi verilere bakılarak teknolojinin nereye gittiği incelenerek ilgili teknoloji için trend tahmini yapılabilir. Tanımlayıcı yaklaşımda patent

verilerindeki coğrafi konum, atıf sayısı ve başvuru sayısı gibi özelliklere bakılarak kümeleme yapılabilir. Başka bir deyişle, tanımlayıcı yaklaşımlarla ilgili görevler, verilerin özelliklerini tanımlamaktadır. Ancak tahmine dayalı yaklaşım, geçmiş eğilimlere ve ilişkilere dayanarak gelecekteki sonuçları tahmin etmeye yönelik tahmin modelleri oluşturmaktadır [39].

Veri madenciliği uygulamalarındaki veri, patent verilerinden oluşursa buna “patent madenciliği” denmektedir ve teknoloji yönetimi ve inovasyon stratejisinin önemli bir bileşeni de patent madenciliğidir. Makine öğrenimi algoritmaları ve zaman serisi modelleri, patent verilerinin kapsamlı analizi için sağlam araçlar sağlarken bunların karmaşıklığını ve uygulama zorluklarını dikkate almak önemlidir. Makine öğrenimi ve doğal dil işleme (DDİ) gibi ileri teknolojilerden yararlanılarak bu konuda önemli ilerlemeler kaydedilebilir ancak bunların doğru ve verimli kullanımı dikkatli olmayı gerektirir. Patent madenciliğinde kullanılan yöntemler arasında zaman serisi modelleri, DDİ, kümeleme, yapay sinir ağları (YSA) ve anlamsal analiz gibi makine öğrenmesi teknikleri yer almaktadır ve bu yöntemlerin patent alanında uygulanmasına patent madenciliği adı verilmektedir [4, 40].

Patent madenciliğini alternatif yaklaşımlara göre kullanmanın birçok faydası olduğu söylenebilir. Gerçek inovasyon verilerine dayanan pratik analizler sunarak teknik gelişmelerin ve modellerin yakından gözlemlenmesine olanak tanımaktadır. Delphi yöntemi, Bass difüzyon modeli, çapraz etki analizi, senaryo analizi ve trend analizi gibi geleneksel teknikler uzman görüşüne ve tahminlere dayanırken, patent madenciliği gerçek verilerden elde edilen kesin ve güncel bilgiler sunmaktadır. Karmaşık sistemlerin davranışını simüle etmek için sistem dinamiklerinden de yararlanılsa da, patent madenciliği belirli teknik gelişmelere ve bunların pazarla nasıl etkileşime girdiğine ışık tutabilmektedir. Bu özellikle rekabet analizi, teknolojiye ilerilemenin izlenmesi ve Ar-Ge yönlendirilmesi açısından çok önemlidir.

3. METODOLOJİ

Daha önceki bölümlerde detaylı olarak bahsedildiği üzere teknoloji tahmini yapabilmek, hem devlet hem şirketler hem de bireysel yatırımcılar için politika yapabilmek, maliyetleri düşürmek ve daha fazla kazanç sağlamak için çok kritik bir yetkinliktir.

Bu tez kapsamında patent verileri kullanılarak teknoloji tahmini yapılması amaçlanmaktadır.

Şekil 3.1'deki akış şemasında da görüldüğü üzere, patent verileri sunduğu güçlü sorgulama kapasitesi, patentlere ilişkin veri çeşitliliği ve 10 yıldan uzun süredir piyasada kullanılan bir veri tabanı platformu olan PatSeer'dan toplanmıştır. PatSeer, 150 milyondan fazla patent dokümanını içerisinde barındırmasının yanı sıra patentlere ilişkin patent analizlerinde kullanılabilir birçok istatistiği de kullanıcılarına sunmaktadır.

Bu tez kapsamında ilk olarak organoid, yapay organ ve biyobaskı teknolojilerine ilişkin gerekli olan tüm veriler PatSeer veri tabanından toplanmıştır. Daha sonrasında bu bölümde daha detaylı olarak anlatılacak olan teknoloji yaşam döngüsü (TYD), teknoloji yayılma hızı (TYH), patent gücü (PG) ve genişleme potansiyeli (GP) göstergeleri, verisi toplanan teknolojiler için hesaplanmıştır.

Kümülatif patent tescilleri yoluyla ölçülen teknolojik gelişmenin evrimi, açıklayıcı bir şekilde bir S-eğrisi ile temsil edilen bir TYD'ye bağlıdır [10]. Literatürdeki patent analizlerinin çoğunda teknolojilerin yaşam evrenlerinde nerede olduğu incelenerek yorumlanır.

Patent alıntı analizi, teknolojinin yayılımının düzeyini değerlendirmemizi sağlar ve çeşitli teknolojilerin yayılma hızını tahmin etmenin bir yolu olarak kullanılmaktadır. Bir patente sonraki patentler tarafından atıfta bulunulması, atıfta bulunulan patentin yaygın olduğu, değerli olduğu ve uygulandığı anlamına gelmektedir. TYH hesabı ise, patent başına düşen ileri atıf sayısı olarak yapılır [8].

Bir teknolojiye ilişkin patentlerin PG'si, teknolojinin farklı sektörler arasında daha fazla yayılmasına ve yeni sektörler yaratma şansının daha yüksek olmasına bağlıdır. PG, patent başına düşen toplam IPC kod sayısı olarak tanımlanmaktadır [9].

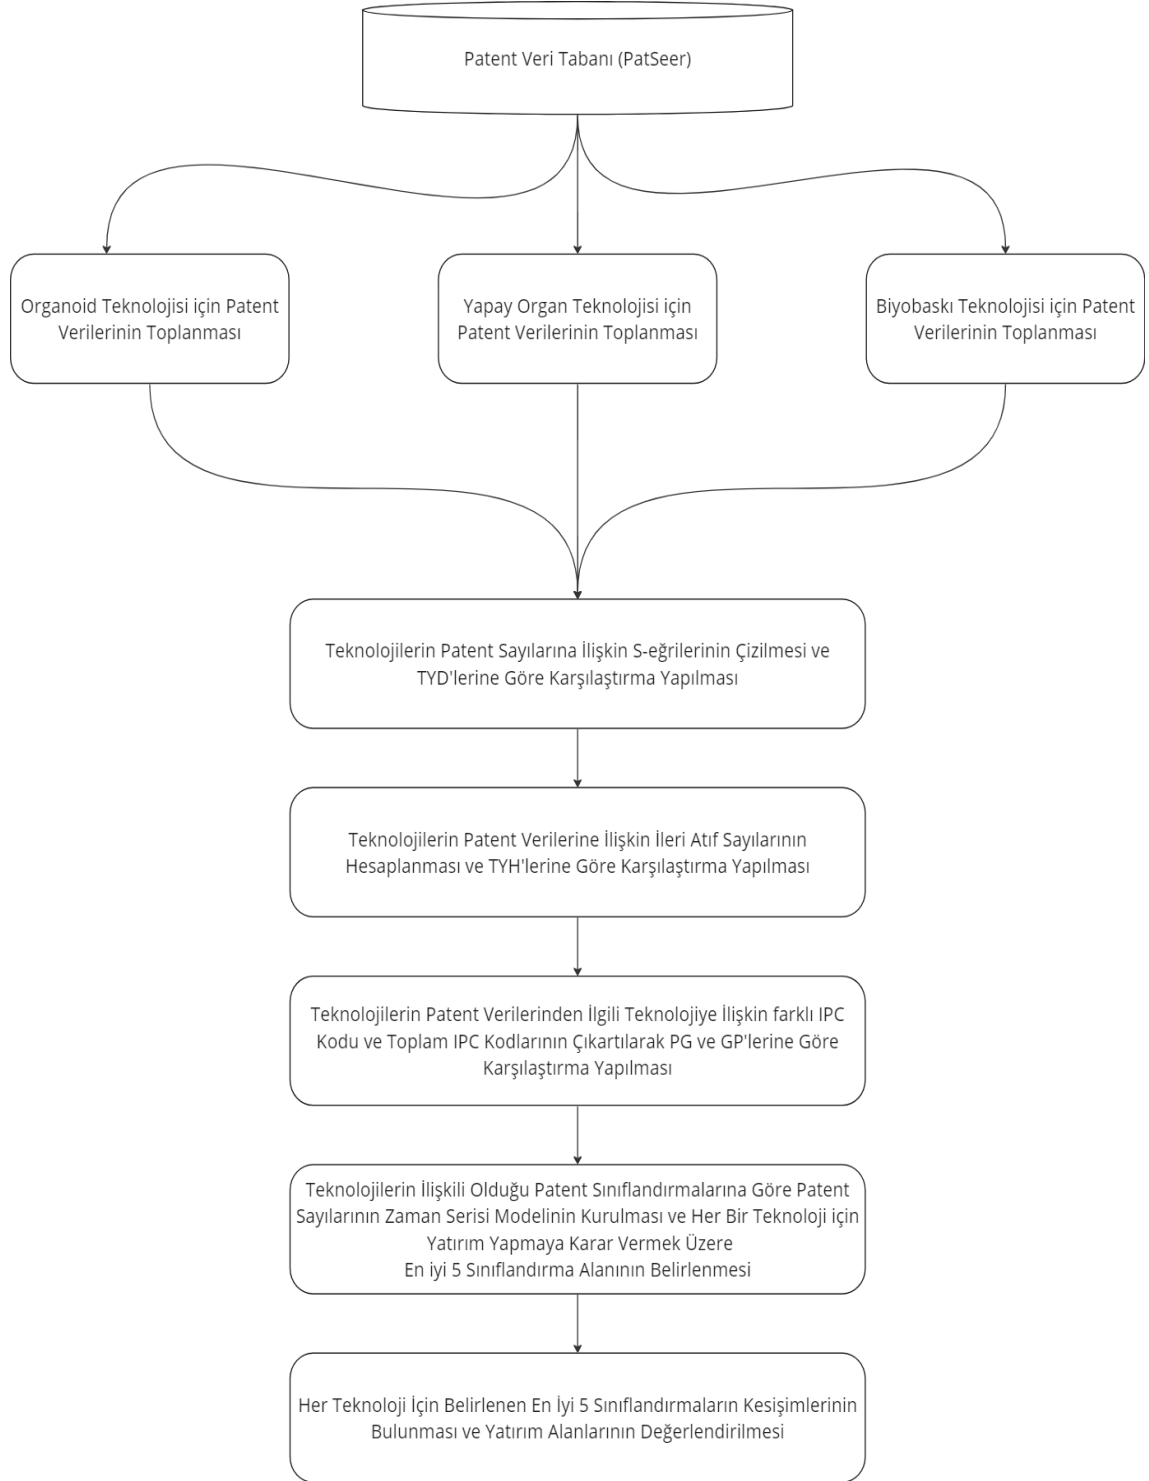
Bir teknolojinin geliştirilmesi, onunla ilişkili teknolojilerin geliştirilmesine yol açar. GP, yatırım yapılan teknolojiyle ilgili teknolojilerin sayısını gösterir [9].

TYD, TYH, PG ve GP göstergeleri teknolojilere ilişkin patent verilerinin incelenebileceđi, teknolojiler arası kıyaslamaların kolaylıkla yapılabileceđi ve literatürde kullanımı çok olan göstergeler olduđu için bu tez kapsamındaki patent analizinde kullanılmıştır. Analizlerin ilk bölümlerinde, organoid, yapay organ ve biyobaskı teknolojileri yukarıda bahsi geçen göstergeler bazında hem tekil olarak deđerlendirilmiş hem de birbirleri arasında karşılaştırılmıştır.

Daha sonrasında organoid, yapay organ ve biyobaskı teknolojilerine ilişkin yıllara ve uluslararası patent sınıflandırmalarına (IPC) ilişkin patent sayıları üzerine TT yöntemlerinden olan zaman serisi modellerinden ARIMA (Otoregresif Birleşik Hareketli Ortalama) yöntemi uygulanmıştır.

Model sonucu ortaya çıkan tahminlere göre en iyi 5 alt sınıf IPC alanı her bir teknoloji için seçildikten sonra teknolojilerin aynı IPC alanlarında olup olmadığı deđerlendirilmiş ve kesişen IPC alanlarına yatırım yapmanın ya da politika oluşturmanın, şirketler ve bireysel yatırımcılar için faydalı olacağı sonucuna varılmıştır.

Bu bölümün devamında yukarıda bahsedilen gösterge ve yöntemlerin nasıl uygulandığına ilişkin bilgiler yer almaktadır.



Şekil 3. 1. Yöntem Akış Şeması

3.1. Teknoloji Yaşam Döngüsü (TYD)

Bir teknolojinin bir yatırım nesnesi olarak çekiciliği, kesin olarak mevcut yaşam döngüsü aşamasına bağlıdır. Patent verilerinin gelişimini gözlemleyerek teknoloji yaşam döngülerini incelemek yaygın bir yaklaşım olarak ön plana çıkmaktadır. İlk olarak patentler, teknolojik bilgi birikimini içerdiğinden bizi teknolojik gelişmenin kendisi hakkında bilgilendirir. İkinci olarak, bir teknolojinin ticari potansiyeli hakkında bizi bilgilendirilebilirler çünkü ticari kullanım olanağı patentlenebilirliğin ön koşullarından biridir. Üçüncüsü ise, patent verilerine ilişkin veriler, teknolojiye dayalı farklı ürünlerin yaşam döngüleri başlamadan önce de teknoloji yaşam döngüsü hakkında bilgi verir. Son olarak patent verileri subjektif bir yaklaşımla uzmanların görüşüne dayalı diğer tekniklerin yanı sıra veri tabanı kullanılarak da kolaylıkla ve objektif olarak ölçülebilir [5]. Bu avantajlardan dolayı, teknoloji yaşam döngüsü tanımlarının temeli olarak patent verilerini, yeni teknolojinin mümkün kıldığı ürünlerin ürettiği birikmiş satış verilerine tercih etmek mantıklı olmaktadır.

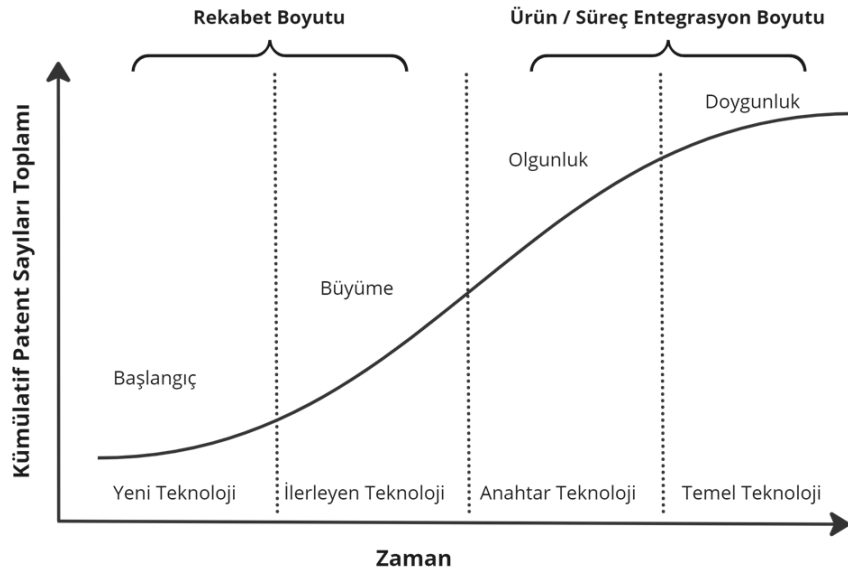
Kümülatif patent tescilleri yoluyla ölçülen teknolojik gelişmenin evrimi, açıklayıcı bir şekilde bir S-eğrisi ile temsil edilen bir TYD'ye bağlıdır [10].

TYD kavramı, iki temel boyutu (rekabet ve ürün/süreçlere entegrasyon) kapsayan teknolojik değişiklikleri ölçmek için kullanılır. Bu model Şekil 3.1'de de görüldüğü üzere dört farklı aşamadan geçerek ilerlemektedir;

1. Teknolojinin ortaya çıktığı ve ilgi kazanmaya başladığı, minimum rekabet etkisine sahip ve ürün veya süreçlerde çok sınırlı entegrasyona sahip yeni bir teknoloji ortaya çıkan "*başlangıç aşaması*",
2. Hızlı benimseme ve artan teknolojik ilerlemelerle karakterize edilen, rekabet gücü yüksek bir ilerleyen teknoloji haline gelir, ancak yeni ürün veya süreçlere dahil edilmeyen "*büyüme aşaması*",
3. İlerleyen teknolojilerden bazıları, yüksek rekabetçi etkilerini korurken ürün veya süreçlere tamamen entegre olan anahtar teknolojilere dönüşür. Buradaki teknolojiler artık süreçlere ve yeni gelişecek teknolojilere yön vermeye başlayan "*olgunluk aşaması*" ve
4. Büyümenin durduğu, teknolojinin zirveye ulaştığı ve rekabetçi etkisini kaybettiğinde, temel teknoloji olarak sınıflandırılır ve bu, yerini daha yeni teknolojilerin alabileceği işaret eden "*doyum aşaması*"

dır.

S-eğrisi çerçevesinin kullanılması, belirli teknolojilerin gelişimsel yörüngesinin kapsamlı bir şekilde anlaşılmasını kolaylaştırmakta ve bu teknolojilerin doyuma ulaşacağı noktanın tahmin edilmesini sağlamaktadır. Bu model yalnızca teknolojik olgunlaşmanın öngörülebilir modellerini vurgulamakla kalmayıp, aynı zamanda gelecekteki eğilimleri tahmin etmek ve teknolojik yatırımlar etrafında organizasyonel stratejiler planlamak için stratejik bir araç olarak da hizmet etmektedir [41].



Şekil 3. 2. S-eğrisi

TYD'yi analiz etmeye yönelik yaygın metodoloji, ağırlıklı olarak teknolojik performansın yörüngesini kronolojik ilerlemeler üzerinden veya Ar-Ge'ye yapılan kümülatif yatırımlarla ilişkili olarak titizlikle izleyen bir S-eğrisi modelini kullanmaktadır. Ancak, teknolojik ilerlemenin kapsamlı dinamiklerini özetlemek için tek bir performans göstergesine özel olarak güvenmek, önemli analitik eksikliklere yol açabilir [10].

Bu nedenle, bu tez kapsamında patent verileri üzerindeki başka performanslara dikkat çeken ve literatürde sıkça geçen göstergeler ve yöntemler kullanılmaktadır.

3.2. Teknoloji Yayılma Hızı (TYH)

Bir yeniliğin sosyal sistem içerisinde belirli yollar boyunca etki etmesi sürecine “yayılma” denir. "Teknolojinin yayılması" ise, sıklıkla patent alıntılarıyla gösterilen bilginin yayılması olarak ifade edilir. Teknolojinin yayılması patentlerle kolaylaştırılmaktadır ve patent alıntılarının sıklığı da bir teknolojinin yayılımını gösterir. Çok sayıda ileri atıf alan bir patentin genellikle yararlı bir teknoloji olduğu, geniş ölçüde kabul edildiği ve pratik olarak kullanıldığı kabul edilir. Yüksek alıntı oranlı teknolojilerin de ekonomik olarak başarılı olma olasılığı genellikle düşük alıntı oranlı teknolojilere göre daha yüksektir. Güçlü bir yayılma potansiyeli olan teknolojiye para yatırmak, daha fazla iş olanağının ve tasarrufun kapısını aralayabilir [42].

Patent alıntı analizi, teknolojinin yayılımının düzeyini değerlendirmemizi sağlar ve çeşitli teknolojilerin yayılma hızını tahmin etmenin bir yolu olarak kullanılmaktadır. Bir patente sonraki patentler tarafından atıfta bulunulması, atıfta bulunulan patentin yaygın olduğu, değerli olduğu ve uygulandığı anlamına gelmektedir [8].

Bununla birlikte, bir patente ilk atıfın genellikle yayınlandıktan dört yıl sonra gerçekleştiği görülmektedir [43].

Teknoloji yayılma hızı (TYH), aşağıdaki formül ile hesaplanmaktadır;

$$TYH = \frac{\text{Toplam İleri Atıf Sayısı}}{\text{Toplam Patent Sayısı}} \quad (2)$$

Günümüzde teknolojik gelişmeler yoktan var olmaz, her zaman başka bir teknolojiden etkilenecek veya başka bir teknolojinin üst versiyonu olarak ortaya çıkarlar. Bu sebepten dolayı, teknolojiler yayılabilir ve yayılma yoluyla farklı şirketler, kurumlar ve ülkeler tarafından kullanılabilirler.

Yayılma potansiyeli yüksek bir teknolojiye yapılan yatırım, daha yüksek bir pazar potansiyeline yol açabilir. Bu sebepten dolayı ilgili teknolojiye ilişkin yayılma hızı hesabını yapmak, yatırımlara ve stratejilere yön verme açısından çok kritiktir.

3.3. Patent Gücü (PG) ve Genişleme Potansiyeli (GP)

Teknolojinin genişleme potansiyeli yüksekse bu, teknolojinin çok sayıda farklı teknolojiyle ilişkisi olduğu anlamına gelir. Patent analizinde çok kullanılan ve en bilindik sınıflandırma türlerinden biri olan IPC, ilgili teknolojide ilgili patentin ilişkili olduğu teknoloji alanlarını temsil eder. IPC kodları kullanılarak patentlerin ne kadar farklı teknolojiyle ilişkisi olup olmadığı rahatlıkla öğrenilebilir.

Bir teknolojiye ilişkin patentlerin patent gücü (PG), teknolojinin farklı sektörler arasında daha fazla yayılmasına ve yeni sektörler yaratma şansının daha yüksek olmasına bağlıdır. Bu, ilgilenilen teknolojinin farklı teknolojilerle daha güçlü bir ilişkiye sahip olduğu ve yeni sektörlerin oluşma potansiyeli olduğu anlamına gelmektedir [9].

$$PG = \frac{\text{Teknolojiye ilişkin patentlerin ilişkili olduğu toplam IPC kod sayısı}}{\text{Toplam patent sayısı}} \quad (3)$$

İlgilenilen teknolojilerle ilgili patent veri tabanındaki farklı IPC kodlarının toplam sayısı, bu teknolojilerin genişleme potansiyelini (GP) göstermektedir. Daha yüksek bir GP, teknolojinin bu IPC kodlarının kapsadığı yeni teknolojilerde kullanılma ihtimalinin daha yüksek olduğu anlamına gelir. Bir teknolojinin geliştirilmesi, onunla ilişkili teknolojilerin geliştirilmesine yol açar. Genişleme potansiyeli, yatırım yapılan teknolojiyle ilgili teknolojilerin sayısını gösterir [9].

$$GP = \text{Teknolojiye ilişkin patentlerin sahip olduğu toplam farklı IPC kod sayısı} \quad (4)$$

Bu tez kapsamında alt sınıf IPC kodları 4 haneli incelenmiştir. Avrupa Patent Ofisi (APO) verilerine göre toplamda 651 alt sınıf IPC kodu bulunmaktadır.

Hem PG hem de GP, teknoloji kapsamını değerlendirmek ve teknolojilerin hangilerinin birbirlerine göre daha potansiyel olduğunu karşılaştırmak için kullanılabilir. Bunlara ek olarak, teknolojilerin diğer teknolojileri etkileme seviyeleri de bu göstergeler kullanarak değerlendirilebilir ve ilgilenilen teknolojiler arasında karşılaştırma yapılabilir.

3.4. Zaman Serisi Modeli ile Tahmin Yöntemleri

Bilim, mühendislik ve ticaret dahil çok sayıda disiplinde değişkenler sıklıkla zamansal olarak sıralı bir şekilde kaydedilmektedir. Örneğin bankalar faiz oranları ve döviz kurlarına ilişkin günlük verileri kayıt altına alır. Benzer şekilde, ulusal istatistik kurumları gayri safi yurtiçi hasılayı yıllık olarak hesaplamaktadır. Ek olarak meteoroloji kurumları, her biri değişen derecelerde zamansal çözünürlüğe sahip çok sayıda lokasyondaki yağış ölçümlerini ve sıcaklık verilerini belgelemektedirler. Bir değişken zaman içinde tutarlı aralıklarla (örnekleme aralığı olarak adlandırılır) art arda ölçüldüğünde, bu veri derlemesi bir “zaman serisi” olarak sınıflandırılır [44].

Zaman serisi analizi, belirli zaman dilimlerinde sıralı olarak toplanan verileri incelemek için tarihsel analizde yaygın olarak uygulanan önemli bir istatistiksel tekniktir. Ekonomi, sağlık, mühendislik ve sosyal bilimlerde de dâhil olmak üzere çeşitli disiplinlerde bu yaklaşım, verilerdeki kalıpların, eğilimlerin, döngülerin ve mevsimsel değişikliklerin nedenlerini tespit edebilme açısından çok değerlidir.

Yüzyıllara dayanan ekonomik verileri analiz etmek için kullanılan esnek bir teknik olan zaman serisi analizi, Hollanda gibi yerlerin geçmişteki ekonomik büyümelerinin incelendiği çalışmalara da temel oluşturmaktadır [45]. Zaman serisi modelleri gelişmiş istatistiksel yaklaşımları kullanarak uygulanmasıyla karmaşık tarihsel eğilimlerin anlaşılmasına olanak tanır ve basit istatistiksel analizin ötesinde, fiyat ve volatilité modelleri gibi önemli tarihsel olayları anlamak için gerekli olan stokastik süreçlerin temelini oluşturur [46]. Rastgele varyasyonların zorluklar yaratabilmesine rağmen, geçmiş verilerden gelecekteki eğilimleri doğru bir şekilde tahmin etme yeteneği, bu modelin tanınmasını sağlamıştır [47]. Yöntem aynı zamanda sosyal ve sağlık hizmetleri alanlarındaki gerçek dünya değerlendirmesinde de kullanımıyla farklı politikaların zaman içinde insanları nasıl etkileyebileceğinin belirlenmesine yardımcı olabilmektedir [48].

Ayrıca, teknoloji tahmininde zaman serisi modelleri, çeşitli koşullar için yararlı sonuçlar üretmek amacıyla patent araştırmasıyla birlikte kullanılmıştır. Örneğin trend eğilimleri, çeşitli teknolojilerin patent modellerini kısa zaman aralıklarında küçük örneklerle tahmin etmek için tasarlanmış bir sinir ağı modeli kullanılarak doğru bir şekilde tahmin edilmiştir [49]. Radar teknolojileri üzerine yapılan bir başka çalışmada, teknolojinin zaman içindeki gelişimini değerlendirmek ve gelecekteki eğilimleri tahmin etmek için ARIMA modeli kullanılmıştır [50]. Ayrıca, patent verileri ile yayınlanmış patent başvuruları

arasındaki bağlantıları analiz ederek teknolojik gelişmedeki kalıpları tahmin etmek için ARIMA modeliyle iki farklı yöntemin kıyaslamasını yapmıştır [51].

Zaman serisi uygulamalarında birçok farklı yöntem kullanılmaktadır. En yaygın olan yöntemler arasında AR, MA, ARIMA, dışsal değişkenli otoregresif bütünleşik hareketli ortalama (ARIMAX) ve diğer makine öğrenmesi algoritmaları (prophet, zaman serisi sinir ağları (TNN) vb.) yer almaktadır [47, 52, 53].

AR modeli bir zaman serisinin geçmiş değerlerinin kendi gelecek değerlerini tahmin etmek için kullanıldığı modeller olarak tanımlanmaktadır. Model, bir serinin mevcut değerinin, bir veya daha fazla önceki değerlerin bir fonksiyonu olduğunu varsayar [53].

Modelin genel formülü şu şekildedir.

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t \quad (5)$$

- X_t : t zamanında gözlemlenen serinin değeri.
- c : Sabit terim, modeldeki kesim noktasını temsil eder.
- ϕ_i : i gecikmeli otoregresif terimin katsayısı, serinin önceki i değerlerinin mevcut değer üzerindeki doğrudan etkisini belirler.
- ε_t : t zamanında rastgele hata terimi, genellikle normal dağılıma sahip beyaz gürültü olarak kabul edilir.

MA modeli, serinin mevcut hata terimlerini ve bir veya daha fazla hata teriminin bir kombinasyonunu kullanarak serinin gelecekteki değerlerini tahmin etmeye yaramaktadır [53].

Modelin genel formülü şu şekildedir.

$$X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (6)$$

- X_t : t zamanında gözlemlenen serinin değeri.

- μ : Genel ortalamadır, bazen modelde kesme noktası olarak kullanılır.
- θ_j : j gecikmeli hareketli ortalama terimin katsayısı, serinin önceki j hata terimlerinin mevcut değer üzerindeki dolaylı etkisini belirler.
- ε_t : t zamanında rastgele hata terimi, genellikle normal dağılıma sahip beyaz gürültü olarak kabul edilir.

ARIMA ve onun varyantı ARIMAX (dışsal değişkenlerle), zaman serisi verilerini tahmin etmek ve anlamak için kullanılan istatistiksel modellerdir.

ARIMA modelleri, dış etkiler olmadan çeşitli veri türlerini modellemek için otoregresif (AR), fark alma (I) ve hareketli ortalama (MA) bileşenlerini entegre eden zaman serisi analizinin temelini oluşturur [54].

Modelin genel formülü şu şekildedir.

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (7)$$

- X_t : t zamanında gözlemlenen serinin değeri.
- c : Sabit terim, modeldeki kesim noktasını temsil eder.
- ϕ_i : i gecikmeli otoregresif terimin katsayısı.
- d : Entegrasyon derecesi, serinin fark alınarak durağan hale getirilmesi gereken kez sayısı.
- θ_j : j gecikmeli hareketli ortalama terimin katsayısı.
- ε_t : t zamanında rastgele hata terimi.

ARIMAX modeli, dış veya dışsal değişkenleri tahmin denklemine dahil ederek ARIMA'yı genişletir, modelin yanıt değişkenini etkileyebilecek ek değişkenleri dikkate almasına olanak tanır, ekonomik göstergeler veya hava koşulları gibi farklı senaryolarda tahmin doğruluğunu ve uygulanabilirliğini artırır [55].

Modelin genel formülü şu şekildedir.

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \beta_1 Z_{1,t} + \beta_2 Z_{2,t} + \dots + \beta_k Z_{k,t} + \varepsilon_t \quad (8)$$

- X_t : t zamanında gözlemlenen serinin değeri.
- c : Sabit terim, modeldeki kesim noktasını temsil eder.
- ϕ_i : i gecikmeli otoregresif terimin katsayısı.
- d : Entegrasyon derecesi, serinin fark alınarak durağan hale getirilmesi gereken kez sayısı.
- θ_j : j gecikmeli hareketli ortalama terimin katsayısı.
- β_i : i dışsal (exogenous) değişkenin katsayısı, bu değişkenler serinin dışından gelen ek bilgileri temsil eder ve modeldeki etkilerini açıklar.
- $Z_{i,t}$: i dışsal değişkenin t zamanındaki değeri.
- ε_t : t zamanında rastgele hata terimi.

Bu tez kapsamında, yıllık bazda hesaplanmış toplam patent sayıları üzerinden ARIMA modelleri ilgili teknolojilerin etki ettiği en yüksek 15 alt sınıf IPC kodu özelinde kurulmuştur. Verinin doğası gereği veri setinde bağımsız değişken bulunmadığından, ARIMA dışındaki ARIMAX, TNN ve diğer makine öğrenmesi tekniklerinin istenilen tahminleri yeterince yansıtamayacağı ihtimalinden dolayı bu zaman serileri ARIMA modelleriyle tahmin edilmiştir. Bu teknik (ARIMA) sayesinde de AR ve MA modellerinin ayrı olarak kurulmasına gerek kalmamıştır.

4. ANALİZ

Bu bölümde organoid, yapay organ ve biyobaskı teknolojilerinin patent verilerinden yararlanılarak metodoloji bölümünde bahsedilen kriter ve yöntemlerin analiz sonuçları değerlendirilecektir.

Patent verileri 1967-2023 yılları arasındaki verilerden oluşmakta olup, toplamda organoid, yapay organ ve biyobaskı teknolojilerine ait toplam 33.836 patent isimleri, tescil yılları, tescil edilen coğrafi konum, ileri atf sayıları ve IPC kodlarıyla PatSeer uygulamasından alınarak analiz için uygun hale getirilmiştir. Analizler için kullanılacak istatistik veriler aşağıdaki Tablo 4.1’de gösterilmektedir.

Tablo 4. 1. Teknolojilere İlişkin İstatistik Patent Verileri


Teknoloji Adı	Patent sayısı	İleri atf sayısı	IPC kod sayısı	Farklı IPC kod sayısı
Organoid	16.967	70.554	38.138	183
Yapay Organ	13.297	144.329	144.329	245
Biyobaskı	3.572	11.809	11.809	156

4.1. Teknoloji Yaşam Döngüsü (TYD)

Bu bölümde tez kapsamındaki teknolojilere ilişkin teknoloji yaşam döngüleri değerlendirilecektir.

Şekil 4.1’de görüldüğü üzere, organoid teknolojisinin S-eğrisi grafiği yaşam döngüsü aşaması olarak 2017 yılına kadar “başlangıç aşaması”nda olduğu ve bu yıldan sonraki büyük sıçrayışından dolayı “büyüme aşaması”na geçmiştir. Bu durum, teknolojinin rekabet sürecini son yıllarda başarıyla tamamlayacağı ve çalışılan alanlardaki diğer yenilikçi ürünleri ve süreçleri önümüzdeki yıllarda önemli ölçüde etkileyeceği anlamına gelen “ilerleyen teknoloji” olduğunu göstermektedir. Yapay organ teknolojisi ise 1980’li yıllardaki “başlangıç aşaması”ndan 2000’li yılların başında “büyüme aşaması”na geçmiş ve son yıllardaki sabit oranlı fakat halen yüksek bir eğimde olan patent sayılarındaki artış, artık bu teknolojinin “olgunluk aşaması”nda olduğunu göstermektedir. Bu durum

teknolojinin başka teknolojilere etki etme konusunda artık doygunluğa ulaşmasına işaret ederken, yeni gelişecek ürün ve süreçlere temel oluşturacak bir teknolojiye evriminin olacağını da göstermektedir. Biyobaskı teknolojisinin yaşam döngüsünde diğer teknolojilere göre çok daha yeni bir teknoloji olduğu direkt olarak göze çarpmakla birlikte kümülatif patent sayılarındaki artışa bakıldığında kısa süre içerisinde “başlangıç aşaması”ndan “büyüme aşaması”na geçme evresinde olduğu gözlemlenmektedir. Organoid teknolojisi kadar büyük bir ivmeyle artmasa da “olgunluk aşaması”na geçişin biyobaskı teknolojisinde daha uzun sürebileceği varsayımı söylenebilir.



Şekil 4. 1. Organoid, Yapay Organ ve Biyobaskı Teknolojilerine İlişkin S-eğrileri

Organoid, yapay organ ve biyobaskı teknolojilerinin üçünün de kümülatif patent sayıları henüz istikrara kavuşup düşmeye başlamamıştır. Ancak, teknolojilerin başlangıç noktaları ve çalışılmaya başlandıktan sonraki artış hızları bakımından birbirinden farklılık göstermektedirler. Sırasıyla teknolojileri değerlendirecek olursak;

Organoid; 2000’li yıllara kadar patent alma konusunda düşük bir eğilim göstermekle birlikte, 2000-2017 yılları arasında başlangıç seviyesinde olduğunu ve bu alana ilişkin Ar-Ge yatırımlarının arttığını söyleyebiliriz. Teknolojilerin belirli bir benzerlikte ömürleri olsa da her teknolojinin evrimi birbirinden farklıdır. Bu teknoloji temel alındığında, teknolojilerin çok hızlı ve üstel bir fonksiyonla geliştiği günümüz şartlarında yaklaşık 17 yıllık bir başlangıç evresi organoid teknolojisinin sağlam bir gelişme

yaşadığını göstermektedir. Bu sebepten dolayıdır ki, 2017 yılından günümüze gelene kadar ise ilgili teknolojide alınan patent sayılarındaki çok büyük bir sıçrayış vardır ve bu tez kapsamında değerlendirilen ve benzer alanlara hizmet eden diğer iki teknolojiye göre daha yüksek bir ivmeyle büyüdüğü söylenebilir.

Yapay Organ; Şekil 4.1'e bakıldığında bu teknolojinin organoid ve biyobaskı teknolojilerine göre daha eski bir teknoloji olduğu görülmektedir. Çünkü 1980'li yıllardan itibaren bu alanda birçok patent alınmıştır. 1990'lı yılların sonuna kadar başlangıç seviyesinde olduğu değerlendirilirse, yaklaşık 30 yıldır büyüme evresinde olan bir teknoloji olduğu söylenebilir. Ancak, bu teknolojinin son yıllardaki patent sayıları kümülatif olarak artsa da ivmelenme hızı nispeten düştüğünden “olgunluk aşaması”na geçtiği gözlemlenmektedir. Bu durum, yapay organ teknolojisinin rekabet sürecini tamamladığını ve başka teknolojileri etkileme konusunda “anahtar teknoloji” olduğunu gösterir.

Biyobaskı; yıllara göre patent sayılarına bakıldığında 2010 yıllardan itibaren ilgilenilen bir teknoloji olduğu görünmektedir. Bu teknoloji, organoid ve yapay organ teknolojileriyle kıyaslandığında daha yeni bir alan olmasının yanı sıra büyüme evresinin onlara göre daha kısa zaman aldığı patent sayılarındaki ivmelenmenin son yıllarda yüksek oranda artmasından dolayı söylenebilir. Bu durum, biyobaskı teknolojisi için patent sayılarında yakın gelecekte daha hızlı bir yükseliş olacağına işaret etmektedir.

Sonuç olarak, organoid, yapay organ ve biyobaskı teknolojileri yaşam döngülerinde sırasıyla “büyüme”, “olgunluk” ve “başlangıç” aşamasında olmalarına rağmen organoid teknolojisinin ivmesinin yüksek olmasından dolayı bu bölümde daha fazla yatırım yapılabilir teknoloji olarak değerlendirilmektedir. Nispeten daha yeni bir teknoloji olsa da patent sayılarının artışıdaki ivmelenmesi yapay organ teknolojisinden fazla olduğu için biyobaskı teknolojisi bu bölümde ikinci sırada yer almaktadır.

4.2. Teknoloji Yayılma Hızı (TYH)

Bu bölümde tez kapsamındaki teknolojilere ilişkin teknoloji yayılma hızları değerlendirilecektir.

3'üncü bölümdeki metodoloji kısmında anlatıldığı üzere TYH, teknolojilerdeki patent başına düşen ileri atıf sayıları olarak tanımlanmaktadır. Bu tanımdan yola çıkarak organoid, yapay organ ve biyobaskı teknolojilerine ilişkin TYH'ler aşağıda gösterilmektedir.

$$TYH_{Organoid} = \frac{70.554}{16.967} = 4,16$$

$$TYH_{Yapay Organ} = \frac{144.329}{13.297} = 10,85$$

$$TYH_{Biyobaskı} = \frac{11.809}{3.572} = 3,31$$

Yukarıda hesaplanan değerlere bakıldığında TDS seviyelerine göre teknoloji sıralaması

Yapay Organ > Organoid > Biyobaskı

şeklinde çıkmaktadır.

Yapay organ teknolojisinin yayılma hızının diğer teknolojilere göre çok daha yüksek olmasının sebebi yaklaşık 40 yıldır çalışılan ve “olgunluk aşaması”nda olan bir teknoloji olmasıdır. Ayrıca, 40 yıldır yüksek bir ivmeyle büyümeye devam eden bir teknolojinin TYH seviyesinin düşük olmaması bu teknoloji için çok sevindiricidir. Bu durum yapay organ teknolojisinin çağın şartlarına uyum sağladığının da ayrı bir göstergesidir.

Organoid ve biyobaskı teknolojilerinin patent başına düşen ileri atıf sayıları da yapay organ teknolojisi kadar olmasa da bir hayli yüksek çıkmıştır. Özellikle bu iki teknolojinin son birkaç yıldaki sıçrayışı ilerleyen zamanda bu verinin daha da yükselebileceğinin göstergesidir.

Sonuç olarak, bu tez kapsamında benzer teknolojiler seçilmesine rağmen organoid ve biyobaskı teknolojilerinin TYH seviyeleri nispeten benzer çıkmış, uzun yıllardır teknoloji etkisini yitirmeyen yapay organ teknolojisinin TYH'si diğer teknolojileri geride bırakmıştır.

4.3. Patent Gücü (PG) ve Genişleme Potansiyeli (GP)

Bu bölümde tez kapsamındaki teknolojilere ilişkin patent gücü ve teknolojilerin genişleme potansiyelleri değerlendirilecektir.

3'üncü bölümdeki metoloji kısmında anlatıldığı üzere PG, patent başına düşen her bir patentin ilişkili olduğu IPC kod sayısı olarak tanımlanmaktadır. Bu tanımda yola çıkarak organoid, yapay organ ve biyobaskı teknolojileri için Tablo 4.1'de gösterilen verilerle hesaplanan PG değerleri aşağıda gösterilmektedir.

$$PG_{Organoid} = \frac{38.138}{16.297} = 2,25$$

$$PG_{Yapay Organ} = \frac{34.421}{13.297} = 2,59$$

$$PG_{Biyobaskı} = \frac{9.540}{3.572} = 2,67$$

Yukarıda hesaplanan değerlere bakıldığında PG seviyelerine göre teknoloji sıralaması

$$Biyobaskı > Yapay Organ > Organoid$$

şeklinde çıkmaktadır.

Benzer alanlara hitap eden üç teknolojide de çok benzer PG değerleri ortaya çıkmıştır. Bu durum, bu teknolojilerde alınan patentlerin iki veya daha fazla alandaki teknolojilerle iç içe olduğunu ve bu alanlara yatırım yapmak isteyen yatırımcıların tasarruflarını daha yayıcı bir şekilde değerlendirebileceklerini göstermektedir. Bu teknolojilerin patent güçlerinin yüksek olması bu teknolojilerin çok sayıda sektörden beslendiği ve çok sayıda sektöre katkı sağladığını söylemek yanlış olmaz.

Literatürde LCD, USB bellek ve kişisel dijital asistan gibi günlük bazda hayatımızı kolaylaştıran ve daha erişilebilir teknolojilere ilişkin patent verileri için PG değerleri sırasıyla, 1,73, 1,30, 1,38 çıkmıştır [9]. Bu değerlere de bakıldığında bu tez kapsamında ilgilenilen organoid, yapay organ ve biyobaskı teknolojilerinin, daha özel teknolojiler olmasına karşın daha fazla etki alanına sahip olduğu söylenebilmektedir.

3'üncü bölümdeki metodoloji kısmında anlatıldığı üzere GP, teknolojilerin etkilediği alanlarının genişliğini gösteren ve teknolojilere ilişkin patentlerin farklı IPC kod sayısı sahipliklerine bakan bir gösterge olarak tanımlanmaktadır. Burada alt sınıf IPC kodları (4 haneli) incelenmiştir. Avrupa Patent Ofisi (APO) verilerine göre toplamda 651 alt sınıf IPC kodu bulunmaktadır. Bu tanıma göre organoid, yapay organ ve biyobaskı teknolojileri için Tablo 4.1'de gösterilen veriler ışındaki GP değerleri aşağıda gösterilmektedir.

$$GP_{Organoid} = 183$$

$$GP_{Yapay Organ} = 245$$

$$GP_{Biyobaskı} = 156$$

Yukarıdaki gösterilen GP değerleri ışığında teknolojilerin sıralaması aşağıda gösterilmektedir.

Yapay Organ > Organoid > Biyobaskı

Teknolojilere ilişkin PG değerleri ne kadar benzer çıksa da bu teknolojiler nezdinde kaç farklı alana hitap ettikleri bakımında GP sayılarını incelemek önemlidir. Bu aşamada, 245 farklı alandan etkilenen ve etki eden yapay organ teknolojisinin, yaklaşık 40 yıldır çalışılan bir teknoloji olmasına rağmen halen yüksek bir yatırım kapasitesi olduğunun göstergesidir. Organoid teknolojisi bu gösterge özelinde ikinci sırada yer almaktadır ve bu durum, uzun yıllar boyunca sağlık alanındaki teknolojik değişime yön vereceğinin göstergesidir. Benzer durum 156 farklı alandan etkilenen ve etkileyebilen biyobaskı teknolojisi için de geçerlidir.

Genel olarak, 651 alt sınıf IPC kodunun 245'ine etki eden yapay organ teknolojisi, 183'üne etki eden organoid teknolojisi ve 156'sına etki eden biyobaskı teknolojisinin yatırım potansiyellerinin çok yüksek olduğu ve yatırım risklerinin de düşük olduğu söylenebilir.

4.4. TYD, TYH, PG ve GP Gösterge Skorlarının Değerlendirmesi

Bu bölüm yukarıda analiz sonuçlarının paylaşıldığı 4 kriter bazında tez kapsamında çalışılan organoid, yapay organ ve biyo baskı teknolojilerinin genel değerlendirmesini oluşturmaktadır.

Tablo 4.2 kriterler bazında teknolojilerin birbirlerine göre konumunu göstermektedir.

Bölüm 4.1, 4.2 ve 4.3’de de anlatıldığı ve Tablo 4.2’de görüldüğü üzere yapay organ teknolojileri 2 kriterde (TYH ve GP) zirveyi almıştır. Organoid teknolojisi teknoloji yaşam döngüsünde “başlangıç aşaması”nda olduğu için diğer teknolojilerle kıyaslandığında en çok yatırım yapılabilir teknoloji olduğu görülmektedir. Diğer teknolojilere göre daha yeni bir teknoloji olmasına karşın biyobaskı teknolojisi patent gücü başlığında çok az bir farkla birinci sırada yer almıştır.

Tablo 4. 2. Kriterler Bazında Teknolojilerin Kıyaslanması

Teknoloji Yaşam Döngüsü (TYD)	$x > z > y$
Organoid (x)	Büyüme
Yapay Organ (y)	Olgunluk
Biyobaskı (z)	Başlangıç
Teknoloji Yayılma Hızı (TYH)	$y > x > z$
Organoid (x)	4,16
Yapay Organ (y)	10,85
Biyobaskı (z)	3,31
Patent Gücü (PG)	$z > y > x$
Organoid (x)	2,25
Yapay Organ (y)	2,59
Biyobaskı (z)	2,67
Genişleme Potansiyeli (GP)	$y > x > z$
Organoid (x)	183
Yapay Organ (y)	245
Biyobaskı (z)	156

4.5. Zaman Serisi Modeli Tahmini

Yukarıdaki deęerlendirmeler ışığında 3 teknolojinin de farklı özelliklerde yatırım yapılma konusunda farklı avantajları bulunmaktadır. Bu sebepten dolayı, 3 teknoloji için de yıllık bazda hesaplanmış toplam patent sayıları üzerinden zaman serisi modelleri ilgili teknolojilerin etki ettiği en yüksek 15 alt sınıf IPC kodu özelinde kurulmuştur.

Tablo 4.4, 4.7 ve 4.10'daki alt sınıf IPC kodlarına bakıldığında 15 alt sınıf IPC kodunun teknolojiler özelinde seçilmesi uygun görülmüştür. Çünkü bu tablolarda da görüldüğü üzere örneğin organoid teknolojisinde en yüksek IPC kodundan 15'inci sıradaki IPC koduna patent sayıları 2021 yılında 1381'den 33'e, 2023 yılında ise 2162'den 56'ya kadar düşmektedir. Tez kapsamında çalışılan teknolojiler ne kadar çok alana hitap etse de belirli alanlarda daha çok patentleri olduğundan ve tez kapsamında yatırım yapılabilir alanlar seçileceğinden dolayı zaman serisi modellerinin 15 alt sınıf IPC kodu özelinde kurulmasının daha faydalı olacağı düşünülmüştür.


Tez çalışmasında, Python (version 3.12.x) programında yazılmış bir kod parçası ile her bir alt IPC için ARIMA model parametreleri (p,d,q deęerleri) için [0, 5] aralığındaki deęerler denenmiş ve dolayısıyla her alt sınıf IPC kodu için toplamda 216 farklı kombinasyon kullanılarak otomatik olarak test edilmiştir. Bu süreç, her alt sınıf IPC'nin özgün ihtiyaçlarına göre en iyi model yapılandırmasını belirlemek için tasarlanmıştır. Burada farklı parametrelerin test verisi üzerinden hesapladığı ortalama kareler hatası karekökü (OKHK) metrikleri ile kıyaslanmıştır ve otomatik olarak en düşük OKHK deęerini veren parametreler en iyi parametreler olarak atanmıştır. Bu otomatik seçim mekanizması, çeşitli IPC'lerin dinamiklerine uygun en iyi tahmin modelinin seçilmesini sağlayarak, modelleme sürecinde önemli bir verimlilik artışı ve tahmin doğruluğu sağlamıştır. Bu yöntem, geniş veri kümeleri üzerindeki otomasyonu ve modelleme sürecindeki etkinliği artırarak zaman ve kaynak kullanımını optimize etmekte büyük rol oynamıştır. Aynı zamanda başka veri setleri için de aynı metodolojinin uygulanabilirliğini sağlamaktadır.

Burada, 2020 yılı ve öncesi yıllardaki patent sayıları eğitim verisi, 2021, 2022 ve 2023 yıllarındaki patent sayıları ise test verisidir. Bu kapsamda, ilk olarak, aşağıdaki çıktılardan her teknoloji için 2021, 2022 ve 2023 gerçek verileriyle tahmin verileri kıyaslanacaktır. Daha sonrasında, modelde 2024, 2025 ve 2026 yılları için tahmin edilen tahmin deęerleri gösterilecek ve her teknoloji için hem sayısal hem de yüzdesel olarak en yüksek artış

oranlı 5 alt sınıf IPC kodu seçilecektir. Seçilen alt sınıf IPC kodları, her teknoloji için yatırım yapılabilir alanlar olacaktır. Son olarak, seçilen alt sınıf IPC kodlarının teknoloji kesişim kümesi çıkartılacak ve 3 teknoloji için de ortak olan alt sınıf IPC kodları en çok yatırım yapılabilir alanlar olarak belirlenecektir.

4.5.1. Organoid Teknolojisi

Şekil 4.2’de, organoid teknolojisinde alınan patentlerin alt sınıf IPC kodlarının 2002-2023 yılları arasındaki patent sayıları gösterilmektedir. Bu grafiğe göre, organoid teknolojisine ilgili tescil edilen patentler, ürün yaşam döngü seviyelerine bakıldığında hem başlangıç hem de büyüme aşamasında benzer büyüme eğilimleriyle aynı alt sınıf IPC kodlarına, yani teknoloji alanlarına, hitap etmektedir. Bu teknoloji alanları sırasıyla; C12N, A61K, A61P, G01N, C12Q, C07K, C12M, A61L, C07D, B01L, A01K, C12P, A01N, G16B ve A23L’dir.



Şekil 4. 2. Organoid Teknolojisi Alt Sınıf IPC Kod Patent Sayılarının Yıllara Göre Değişimi

Yukarıda belirtilen alt sınıf IPC kodlarının tanımları aşağıdadır;

- **C12N:** Mikroorganizmalar veya Enzimler; Kompozisyonları; Mikroorganizmaların Yetiştirilmesi veya Muhafazası,
- **A61K:** Tıbbi, dişçilik veya tuvalet amaçları için preparatlar,
- **A61P:** Terapötik aktiviteye sahip spesifik aktif tıbbi maddeler,

- **G01N**: Malzemelerin belirlenmesi için yapılan analizler veya deneyler,
- **C12Q**: Mikroorganizmaların veya Enzimlerin kullanımı ile gerçekleştirilen ölçümler veya testler; Biyolojik malzemelerin ölçüm veya test yöntemleri,
- **C12M**: Mikroorganizmalar veya Enzimlerle kullanılmak üzere düzenlenmiş laboratuvar aygıtları,
- **A61L**: Mikroorganizma, hayvan veya bitki hücrelerinin korunması, muhafazası veya sterilizasyonu için metotlar veya aparatlar,
- **C07D**: Heterosiklik bileşikler,
- **B01L**: Laboratuvarlarda, muayene odalarında veya hastanelerde kullanılmak üzere cihazlar,
- **A01K**: Hayvan yetiştiriciliği; Kuş yetiştiriciliği; Balıkçılık; Balık yetiştiriciliği,
- **C12P**: Fermentasyon veya enzim kullanılarak biyosentez yoluyla organik bileşiklerin üretimi,
- **A01N**: Bitki, alga veya liken koruması, bu amaçla kullanılan preparatlar,
- **G16B**: Enformatik alanında biyoteknoloji,
- **A23L**: Gıda veya gıda maddeleri; Onların tedavi, korunma veya stabilizasyonu [56].

Tablo 4.3’de organoid teknolojisinin teknoloji tahmini yapmak için kullanılan ARIMA modelinin en iyi parametre tahminleri, Akaike Bilgi Kriteri (AIC) ve Bayesyen Bilgi Kriteri (BIC) değerleri ve 2021, 2022 ve 2023 tahmin değerlerinin performansına ilişkin ortalama mutlak yüzde hatası (OMYH) değerleri verilmiştir.

Burada en iyi model parametreleri tahminleri (p, d ve q) en düşük OKHK değerine göre seçilmiştir. Modelin iyi olduğu veri yoğunluğu yüksek patent veri setindeki AIC ve BIC değerlerinin makul seviyede çıkmasından anlaşılmaktadır. Fakat model tahmin sonuçlarının performansını değerlendirmek için OMYH değerleri kullanılmıştır.

Bu kapsamda, OMYH değerleri genel anlamda düşük çıkmıştır ve modelin tahmin performansının iyi olduğu söylenebilir. Özellikle 2023 yılındaki OMYH değerleri önceki yıllardaki tahminlere göre iyileştiğinden modelin tahmin performansının zamanla daha doğru hale geldiği gözlemlenmiştir.

Tablo 4. 3. Organoid Teknolojisi ARIMA Modeli OMYH değerleri

Organoid	ARIMA Modeli (p, d, q)	AIC	BIC	OMYH		
				2021	2022	2023
Toplam Patent Sayısı	(1, 1, 3)	472,84	481,87	0.98%	1.16%	0.67%
C12N	(1, 2, 0)	433,80	437,37	2.46%	2.93%	0.05%
A61K	(3, 1, 1)	405,04	414,08	4.07%	0.33%	2.06%
A61P	(0, 5, 3)	370,29	377,14	1.74%	2.55%	0.37%
G01N	(1, 5, 1)	400,38	405,52	4.06%	5.81%	3.41%
C12Q	(0, 3, 1)	367,18	370,70	10.42%	1.08%	0.52%
C07K	(1, 2, 0)	375,02	378,58	3.04%	9.89%	2.51%
C12M	(3, 5, 4)	353,46	367,17	1.36%	5.69%	0.75%
A61L	(0, 1, 3)	301,22	308,45	23.62%	11.33%	10.84%
C07D	(0, 4, 5)	282,28	292,70	11.94%	17.07%	4.00%
B01L	(0, 4, 4)	161,32	170,00	9.52%	8.74%	1.59%
A01K	(5, 2, 5)	254,21	273,84	27.42%	16.92%	6.90%
C12P	(4, 5, 3)	304,71	318,41	5.56%	16.22%	20.51%
A01N	(1, 4, 5)	279,81	291,97	14.63%	2.38%	5.36%
G16B	(0, 2, 0)	277,67	279,46	10.53%	2.70%	12.22%
A23L	(4, 4, 0)	217,45	226,14	21.21%	11.43%	0.00%

Yukarıda bahsedilen model ve tahmin sonuçlarının değerlendirmesine ek olarak, modeldeki hataların bağımsız olup olmadığını incelemek için genişletilmiş Ljung-Box testi yapılmıştır. Özet olarak, C12Q, B01L ve A23L verileri dışındaki tüm değişkenlerdeki hatalar bağımsız çıkmıştır. Dolayısıyla, bu üç IPC kodundaki patent sayılarının tahminin dışındaki modellerde otokorelasyon yoktur yorumu yapılabilir.

Organoid teknolojisi ile ilgili 2021-2023 tarihleri arasındaki gerçek patent sayısı verileri ve zaman serisi modelinin ürettiği tahmini patent sayısı verileri, teknolojinin en çok ilgili olduğu 15 alt sınıf IPC koduna göre Tablo 4.4'te gösterilmektedir. Bu tabloda da görüldüğü üzere kurulan zaman serisi modelinin küçük hata payıyla büyük oranda patent sayılarındaki eğilimi doğru tahmin etmektedir. Modelin tahminlerinin gerçek veriyle kıyaslandığında doğru sonuçlar vermesi, 2026 yılına kadar gerçekleşecek olan patent sayıları tahminlerinin de güvenilir olacağını göstermektedir.

Tablo 4. 4. Organoid Teknolojisi Alt Sınıf IPC Kodları Patent Sayıları Tahmin Tablosu

Organoid	2021		2022		2023	
	Gerçek	Tahmin	Gerçek	Tahmin	Gerçek	Tahmin
Toplam Patent Sayısı	2438	2414	3189	3152	3882	3908
C12N	1381	1415	1842	1788	2162	2161
A61K	934	972	1227	1223	1457	1487
A61P	576	586	822	801	1077	1073
G01N	394	410	465	492	586	566
C12Q	384	344	463	458	577	580
C07K	296	305	435	392	479	467
C12M	295	299	404	381	532	528
A61L	127	157	150	167	203	181
C07D	67	75	123	102	125	130
B01L	63	69	103	94	126	124
A01K	62	45	65	54	58	62
C12P	18	19	37	31	39	31
A01N	41	35	42	41	56	53
G16B	57	51	74	76	90	101
A23L	33	26	35	39	56	56

Tablo 4.5, 2024-2026 yılları arasındaki patent sayılarının alt sınıf IPC kodlarının zaman serisi modelindeki tahmin sonuçlarıdır. Aynı zamanda bu tabloda yıllar arasındaki patent sayılarındaki artış oranları da gösterilmektedir.

Teknoloji yaşam döngüsü evrelerinde organoid teknolojisinin büyüme evresinde olduğu gözlemlenmiştir. Dolayısıyla burada her alan için %100'ün üzerinde bir artış oranı beklenmekte ve gözlemlenmektedir. Bu sebeple, yatırım yapılacak alanların belirlenmesinin ilk adımında 100 veya 100'ün üstünde artış oranına sahip alt sınıf IPC kodları her alan için olduğundan bu aşamada en çok patent sayısına 5 alt sınıf IPC kodu seçilmiştir. Seçilen IPC kodları; C12N, A61K, A61P, G01N ve C12M'dur.

Bu alt sınıf IPC kodları, alan özelinde en iyi yatırım yapılabilecek alanları ifade etmektedir.

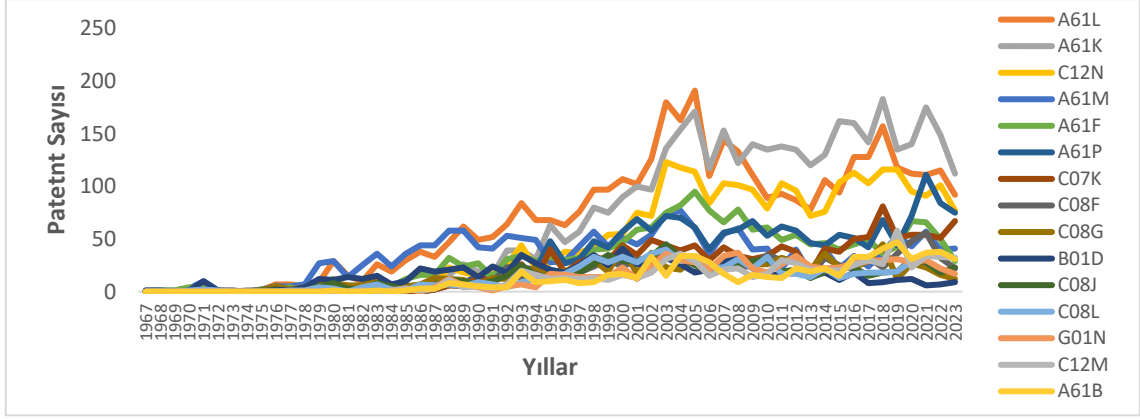
Tablo 4. 5. Organoid Teknolojisi İçin Alt Sınıf IPC Kodlarına Göre 2024, 2025 ve 2026 Yılı Patent Sayısı Tahminleri ve Artış Oranları

Organoid	Tahmin				
	2024	2024-2025 Artış Oranı	2025	2025-2026 Artış Oranı	2026
Toplam Patent Sayısı	4656	115,89%	5396	113,57%	6128
C12N	2535	114,74%	2908	112,85%	3282
A61K	1768	116,46%	2059	114,62%	2360
A61P	1411	129,27%	1824	127,41%	2324
G01N	641	110,14%	706	108,50%	766
C12Q	708	119,07%	843	116,84%	985
C07K	549	114,25%	627	112,75%	707
C12M	682	130,21%	888	123,09%	1093
A61L	181	100,00%	181	100,00%	181
C07D	161	121,74%	196	119,90%	235
B01L	162	127,78%	207	125,60%	260
A01K	80	110,00%	88	117,05%	103
C12P	40	125,00%	50	126,00%	63
A01N	61	121,31%	74	113,51%	84
G16B	126	119,84%	151	116,56%	176
A23L	77	133,77%	103	132,04%	136

4.5.2. Yapay Organ Teknolojisi

Şekil 4.3’de, yapay organ teknolojisinde alınan patentlerin alt sınıf IPC kodlarının 1967-2023 yıllarındaki sayıları gösterilmektedir. Bu grafiğe göre, yapay organ teknolojisiyle ilgili tescil edilen patentler, ürün yaşam döngü seviyelerine bakıldığında, organoid teknolojisinden farklı olarak, başlangıç seviyesindeki alt sınıf IPC kodlarının büyüme seviyesinde aynı kalmadığı görülmektedir. Büyüme seviyesindeki teknoloji alanlarındaki çalışmaların ise olgunluk seviyesine geçiş ve devamında da çalışıldığı görülmektedir.

Yapay organ teknolojisi için alt sınıf IPC kodlarına göre patent sayılarının yıllara göre değişimi incelendiğinde en yüksek patent sayısına sahip olanlar sırasıyla; A61L, A61K, C12N, A61M, A61F, A61P, C07K, C08F, C08G, B01D, C08J, C08L, G01N, C12M ve A61B’dir.



Şekil 4. 3. Yapay Organ Teknolojisi Alt Sınıf IPC Kod Patent Sayılarının Yıllara Göre Değişimi

Yukarıda belirtilen alt sınıf IPC kodlarının tanımları aşağıdadır;

- **A61L**: Mikroorganizma, hayvan veya bitki hücrelerinin korunması, muhafazası veya sterilizasyonu için metotlar veya aparatlar,
- **A61K**: Tıbbi, dişçilik veya tuvalet amaçları için preparatlar,
- **C12N**: Mikroorganizmalar veya Enzimler; Kompozisyonları; Mikroorganizmaların Yetiştirilmesi veya Muhafazası,
- **A61M**: İnsan veya hayvan vücutlarından sıvıların alınması, dahil edilmesi veya dolaştırılması için cihazlar,
- **A61F**: Cerrahi; Tıbbi veya dişçilik amacıyla insan veya hayvan vücudu üzerine uygulanan aletler veya metotlar; Protez; Gözler veya dişler için protez,
- **A61P**: Terapötik aktiviteye sahip spesifik aktif tıbbi maddeler,
- **C07K**: Peptidler,
- **C08F**: Kimyasal olarak tanımlı yüksek moleküler ağırlıklı bileşiklerin sentez veya polimerizasyonu,
- **C08G**: Kimyasal olarak tanımlı yüksek moleküler ağırlıklı bileşiklerin sentez veya polimerizasyonu,
- **B01D**: Sıvı veya gazların ayrıştırılması; Sıvı veya gazların ayırma,
- **C08J**: Kimyasal olarak tanımlı yüksek moleküler ağırlıklı bileşiklerin işlenmesi ve üretimi

- **C08L**: Kimyasal olarak tanımlı yüksek moleküler ağırlıklı bileşiklerin kompozisyonları,
- **G01N**: Malzemelerin belirlenmesi için yapılan analizler veya deneyler,
- **C12M**: Mikroorganizmalar veya Enzimlerle kullanılmak üzere düzenlenmiş laboratuvar aygıtları,
- **A61B**: Cerrahi; Tıbbi teşhis; Tıbbi tedavi; Ortodonti veya dişçilik amacıyla kullanılan aletler [56].

Tablo 4.3’de yapay organ teknolojisinin teknoloji tahmini yapmak için kullanılan ARIMA modelinin en iyi parametre tahminleri, AIC ve BIC değerleri ve 2021, 2022 ve 2023 tahmin değerlerinin performansına ilişkin ortalama mutlak yüzde hata (OMYH) değerleri verilmiştir. Burada en iyi model parametreleri tahminleri (p, d ve q) en düşük OKHK değerine göre seçilmiştir. Modelin iyi olduğu, veri yoğunluğu yüksek patent veri setindeki AIC ve BIC değerlerinin makul seviyede çıkmasından anlaşılmaktadır. Fakat model tahmin sonuçlarının performansını değerlendirmek için OMYH değerleri kullanılmıştır. OMYH değerleri bazı IPC kodlarında yüksek çıkmasına karşın genel anlamda düşük çıkmıştır ve modelin tahmin performansının iyi olduğu söylenebilir.

Tablo 4. 6. Yapay Organ Teknolojisi ARIMA Modeli OMYH Değerleri

Yapay Organ	ARIMA Modeli (p, d, q)	AIC	BIC	OMYH		
				2021	2022	2023
Toplam Patent Sayısı	(0, 5, 5)	931,16	946,23	6.95%	1.57%	15.26%
A61L	(2, 0, 4)	790,38	810,90	0.00%	5.22%	3.26%
A61K	(3, 0, 5)	753,98	779,62	13.71%	8.72%	19.64%
C12N	(4, 5, 5)	725,28	750,39	3.30%	12.87%	1.30%
A61M	(2, 5, 5)	765,41	785,50	14.04%	2.50%	9.76%
A61F	(0, 0, 3)	712,98	725,80	9.09%	22.00%	27.59%
A61P	(5, 3, 5)	655,88	683,74	28.83%	1.19%	26.67%
C07K	(2, 1, 1)	621,85	632,06	12.96%	5.88%	5.97%
C08F	(0, 0, 4)	629,68	645,06	10.71%	37.50%	45.45%
C08G	(5, 5, 5)	622,03	649,65	8.70%	6.25%	25.00%
B01D	(3, 1, 4)	553,79	574,22	16.67%	14.29%	22.22%
C08J	(1, 0, 5)	538,65	559,17	3.57%	38.89%	13.04%
C08L	(5, 4, 5)	546,99	574,73	14.71%	2.94%	9.38%
G01N	(0, 0, 5)	551,95	569,90	3.33%	4.55%	5.88%
C12M	(4, 1, 0)	595,69	608,46	2.94%	0.00%	3.12%
A61B	(5, 0, 5)	590,14	620,91	0.00%	0.00%	9.68%

Yukarıda bahsedilen model ve tahmin sonuçlarının değerlendirmesine ek olarak, modeldeki hataların bağımsız olup olmadığını incelemek için genişletilmiş Ljung-Box testi yapılmıştır. Özet olarak, A61F, A61M, C08F ve G01N verileri dışındaki tüm değişkenlerdeki hatalar bağımsız çıkmıştır. Dolayısıyla, bu dört IPC kodundaki patent sayılarının tahminin dışındaki modellerde otokorelasyon yoktur yorumu yapılabilir.

Yapay organ teknolojisi ile ilgili 2021-2023 tarihleri arasındaki gerçek patent sayısı verileri ve zaman serisi modelinin ürettiği tahmini patent sayısı verileri, teknolojinin en çok ilgili olduğu 15 alt sınıf IPC koduna göre Tablo 4.7’te gösterilmektedir. Bu tabloda da görüldüğü üzere kurulan zaman serisi modelinin küçük hata payıyla da olsa büyük oranda patent sayılarındaki eğilimi doğru tahmin etmektedir. Modelin tahminlerinin gerçek veriyle kıyaslandığında doğru sonuçlar vermesi, 2026 yılına kadar gerçekleşecek olan patent sayıları tahminlerinin de güvenilir olacağını göstermektedir.

Tablo 4. 7. Yapay Organ Teknolojisi Alt Sınıf IPC Kodları Patent Sayıları Tahmin Tablosu

Yapay Organ	2021		2022		2023	
	Gerçek	Tahmin	Gerçek	Tahmin	Gerçek	Tahmin
Toplam Patent Sayısı	547	503	508	496	426	488
A61L	111	111	115	109	92	95
A61K	175	151	149	136	112	134
C12N	91	88	101	88	77	76
A61M	57	49	40	41	41	45
A61F	66	72	50	61	29	37
A61P	111	79	84	83	75	95
C07K	54	61	51	48	67	63
C08F	56	50	32	44	22	32
C08G	23	25	16	15	12	9
B01D	6	7	7	6	9	7
C08J	28	27	18	25	23	21
C08L	34	30	34	35	32	36
G01N	30	29	22	23	17	18
C12M	34	33	33	33	32	31
A61B	37	37	38	38	31	34

Tablo 4.8, 2024-2026 yılları arasındaki patent sayılarının alt sınıf IPC kodlarının zaman serisi modelindeki tahmin sonuçlarıdır. Aynı zamanda bu tabloda yıllar arasındaki patent sayılarındaki artış oranları da gösterilmektedir.

Yapay organ teknolojisindeki patent verileri için elde edilen tahmin sonuçları karşılaştırıldığında, diğer alanlardan farklı olarak yapay organ alanının olgunlaşma döneminde olduğu gözlemlenmiştir. Olgunlaşma döneminde artış oranının %100'ün üzerinde çıkma ihtimali genel olarak beklenmeyen bir durumdur. Bu sebeple yatırım yapılacak alanların belirlenmesinin ilk adımında %100 veya %100'e en yakın artış oranına sahip IPC alt kodları tespit edilmiştir. Seçilen IPC kodları; A61L, A61K, A61P, C08L ve C12M'dir.

Bu alt sınıf IPC kodları, alan özelinde en iyi yatırım yapılabilecek alanları ifade etmektedir.

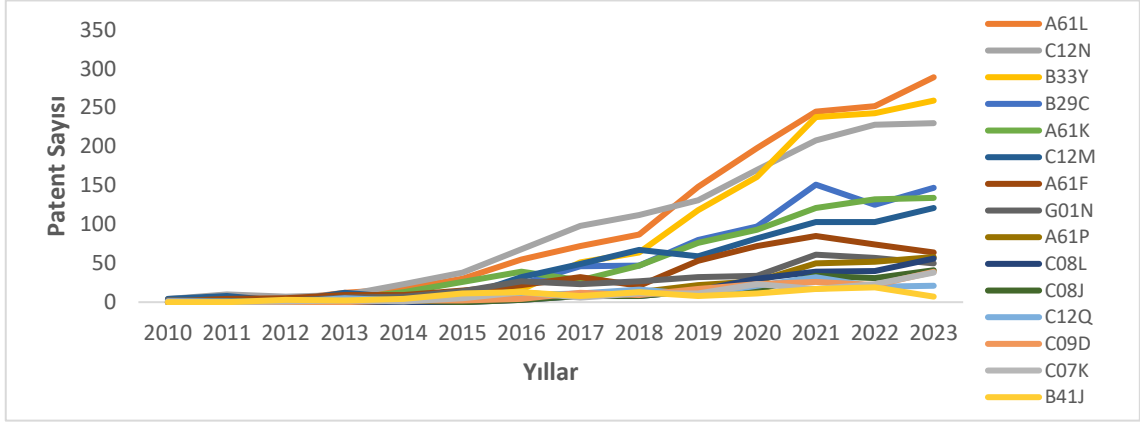
Tablo 4. 8. Yapay Organ Teknolojisi İçin Alt Sınıf IPC Kodlarına Göre 2024, 2025 ve 2026 Yılı Patent Sayısı Tahminleri ve Artış Oranları

Yapay Organ	Tahmin				
	2024	2024-2025 Artış Oranı	2025	2025-2026 Artış Oranı	2026
Toplam Patent Sayısı	479	97,49%	467	97,22%	454
A61L	77	88,31%	68	91,18%	62
A61K	133	95,49%	127	96,85%	123
C12N	56	87,50%	49	79,59%	39
A61M	45	95,04%	43	113,95%	49
A61F	18	100,00%	18	100,00%	18
A61P	114	112,28%	128	111,72%	143
C07K	49	125,32%	61	85,22%	52
C08F	29	34,48%	10	100,00%	10
C08G	14	14,29%	2	250,00%	5
B01D	4	150,00%	6	83,33%	5
C08J	23	108,70%	25	100,00%	25
C08L	43	113,95%	49	106,12%	52
G01N	12	83,33%	10	70,00%	7
C12M	37	86,99%	32	102,52%	33
A61B	34	105,88%	36	94,44%	34

4.5.3. Biyobaskı Teknolojisi

Şekil 4.4'te, biyobaskı teknolojisinde alınan patentlerin alt sınıf IPC kodlarının 2010-2023 yıllarındaki patent sayıları gösterilmektedir. Bu grafiğe göre, biyobaskı teknolojisiyle ilgili tescil edilen patentler, organoid teknolojisine benzer şekilde, ürün yaşam döngü seviyelerine bakıldığında hem başlangıç hem de büyüme aşamasında aynı alt

sınıf IPC kodlarına, yani teknoloji alanlarına, hitap etmektedir. Tabii ki biyobaskı teknolojisinin büyüme evresinin henüz başında olduğunu ve teknoloji alanlarındaki değişimin henüz başlamadığını da unutmamak gerekir. Biyobaskı teknolojisinin en yüksek patent sayısına sahip 15 alt sınıf IPC kodu sırasıyla; A61L, C12N, B33Y, B29C, A61K, C12M, A61F, G01N, A61P, C08L, C08J, C12Q, C09D, C07K ve B41J'dir.



Şekil 4. 4. Biyobaskı Teknolojisi Alt Sınıf IPC Kod Patent Sayılarının Yıllara Göre Değişimi

Yukarıda belirtilen alt sınıf IPC kodlarının tanımları aşağıdadır;

- **A61L**: Mikroorganizma, hayvan veya bitki hücrelerinin korunması, muhafazası veya sterilizasyonu için metotlar veya aparatlar,
- **C12N**: Mikroorganizmalar veya Enzimler; Kompozisyonları; Mikroorganizmaların Yetiştirilmesi veya Muhafazası,
- **B33Y**: Katmanlı imalat; örneğin metal tozundan iş parçaları veya eşyaların 3D baskısı; iş parçaları veya eşyaların son işlemleri,
- **B29C**: Şekillendirme veya döküm; Plastikler için döküm; Lastikler için döküm,
- **A61K**: Tıbbi, dişçilik veya tuvalet amaçları için preparatlar,
- **C12M**: Mikroorganizmalar veya Enzimlerle kullanılmak üzere düzenlenmiş laboratuvar aygıtları,
- **A61F**: Cerrahi; Tıbbi veya dişçilik amacıyla insan veya hayvan vücudu üzerine uygulanan aletler veya metotlar; Protez; Gözler veya dişler için protez,
- **G01N**: Malzemelerin belirlenmesi için yapılan analizler veya deneyler,

- **A61P**: Terapötik aktiviteye sahip spesifik aktif tıbbi maddeler,
- **C08L**: Kimyasal olarak tanımlı yüksek moleküler ağırlıklı bileşiklerin kompozisyonları,
- **C08J**: Kimyasal olarak tanımlı yüksek moleküler ağırlıklı bileşiklerin işlenmesi; Bu tür bileşiklerden mamul ürünlerin üretimi,
- **C12Q**: Mikroorganizmaların veya Enzimlerin kullanımı ile gerçekleştirilen ölçümler veya testler; Biyolojik malzemelerin ölçüm veya test yöntemleri,
- **C09D**: Boyalar, mürekkepler, vernikler veya lake,
- **C07K**: Peptidler,
- **B41J**: Karakter basma; Değişken görüntüler oluşturma, örneğin karakter basma, gerektiğinde görüntü oluşturma için aygıtlar [56].

Tablo 4.3’de biyobaskı teknolojisinin teknoloji tahmini yapmak için kullanılan ARIMA modelinin en iyi parametre tahminleri, AIC ve BIC değerleri ve 2021, 2022 ve 2023 tahmin değerlerinin performansına ilişkin ortalama mutlak yüzde hata (OMYH) değerleri verilmiştir.

Burada en iyi model parametreleri tahminleri (p, d ve q) en düşük OKHK değerine göre seçilmiştir. Modelin iyi olduğu, veri yoğunluğu yüksek patent veri setindeki AIC ve BIC değerlerinin makul seviyede çıkmasından anlaşılmaktadır. Fakat model tahmin sonuçlarının performansını değerlendirmek için OMYH değerleri kullanılmıştır.

Bu kapsamda, biyobaskı teknolojisi için kurulan ARIMA modelinin tahminlerinin OMYH değerleri genel anlamda düşük çıkmıştır ve modelin tahmin performansının iyi olduğu söylenebilir. Özellikle 2023 yılındaki OMYH değerleri önceki yıllardaki tahminlere göre birçok alt sınıf IPC kodunda iyileştiğinden modelin tahmin performansının zamanla daha doğru hale geldiği gözlemlenmiştir.

Tablo 4. 9. Biyobaskı Teknolojisi ARIMA Modeli OMYH Değerleri

Biyobaskı	ARIMA Modeli (p, d, q)	AIC	BIC	OMYH		
				2021	2022	2023
Toplam Patent Sayısı	(2, 1, 3)	652,72	668,04	5.36%	6.24%	4.62%
A61L	(3, 0, 3)	607,28	627,79	3.67%	3.97%	2.42%
C12N	(1, 0, 2)	525,88	538,71	2.40%	0.88%	0.43%
B33Y	(2, 0, 1)	599,21	612,04	15.13%	0.82%	8.11%
B29C	(1, 5, 0)	691,92	696,95	8.61%	12.00%	12.93%
A61K	(4, 0, 1)	547,53	565,48	2.48%	0.76%	9.70%
C12M	(4, 0, 5)	544,51	572,72	5.83%	1.94%	2.48%
A61F	(1, 0, 1)	559,69	569,94	12.94%	1.35%	14.06%
G01N	(4, 2, 2)	348,78	366,58	27.87%	10.53%	4.00%
A61P	(2, 4, 0)	433,87	441,43	26.00%	3.85%	3.45%
C08L	(5, 0, 3)	282,45	308,09	5.13%	0.00%	1.79%
C08J	(2, 5, 5)	261,93	282,01	32.35%	6.45%	9.76%
C12Q	(1, 2, 2)	363,67	373,84	25.00%	20.00%	23.81%
C09D	(2, 4, 4)	208,91	226,57	15.38%	36.36%	7.69%
C07K	(5, 4, 0)	420,70	435,83	0.00%	34.78%	2.63%
B41J	(5, 4, 5)	339,19	366,93	5.88%	26.32%	42.86%

Yukarıda bahsedilen model ve tahmin sonuçlarının değerlendirmesine ek olarak, modeldeki hataların bağımsız olup olmadığını incelemek için genişletilmiş Ljung-Box testi yapılmıştır. Özet olarak, B29C, C12Q ve C07K verileri dışındaki tüm değişkenlerdeki hatalar bağımsız çıkmıştır. Dolayısıyla, bu üç IPC kodundaki patent sayılarının tahminin dışındaki modellerde otokorelasyon yoktur yorumu yapılabilir.

Biyobaskı teknolojisi ile ilgili 2021-2023 tarihleri arasındaki gerçek patent sayısı verileri ve zaman serisi modelinin ürettiği tahmini patent sayısı verileri, teknolojinin en çok ilgili olduğu 15 alt sınıf IPC koduna göre Tablo 4.10'da gösterilmektedir. Bu tabloda da görüldüğü üzere kurulan zaman serisi modelinin küçük hata payıyla da olsa büyük oranda patent sayılarındaki eğilimi doğru tahmin etmektedir. Modelin tahminlerinin gerçek veriyle kıyaslandığında doğru sonuçlar vermesi, 2026 yılına kadar gerçekleşecek olan patent sayıları tahminlerinin de güvenilir olacağını göstermektedir.

Tablo 4. 10. Biyobaskı Teknolojisi Alt Sınıf IPC Kodları Patent Sayıları Tahmin Tablosu

Biyobaskı	2021		2022		2023	
	Gerçek	Tahmin	Gerçek	Tahmin	Gerçek	Tahmin
Toplam Patent Sayısı	616	583	609	647	715	682
A61L	245	236	252	262	289	296
C12N	208	213	228	230	230	229
B33Y	238	202	243	241	259	280
B29C	151	138	125	140	147	128
A61K	121	118	132	131	134	147
C12M	103	97	103	105	121	124
A61F	85	74	74	73	64	73
G01N	61	44	57	51	50	52
A61P	50	37	52	50	58	60
C08L	39	37	40	40	56	55
C08J	34	23	31	29	41	37
C12Q	32	24	20	24	21	26
C09D	26	22	22	30	39	36
C07K	17	17	23	31	38	39
B41J	17	16	19	14	7	10

Bölüm 4.1’de de belirtildiği üzere, biyobaskı teknolojisi başlangıç evresinin sonunda ve büyüme evresine geçiş yapmış bir teknoloji alanıdır. Elde edilen tahmin değerleri ve 2024-2026 yıllarına ilişkin artış oranları Tablo 4.11’deki veriler ışığında incelenmiştir. Bu incelemede %100’ün üzerinde olan IPC alt kodları tespit edilmiştir. Sadece A61F alt sınıf IPC kodu bu teknoloji için yatırım yapılmaması gereken alan olarak belirlenmiştir. Diğer alt sınıf IPC alanlarından en çok patent sayısına sahip ve %100’ün üzerinde olan 5 alan seçilmiştir. Seçilen IPC kodları; A61L, B33Y, A61K, C12M ve A61P’dir.

Bu alt sınıf IPC kodları, alan özelinde en iyi yatırım yapılabilecek alanları ifade etmektedir.

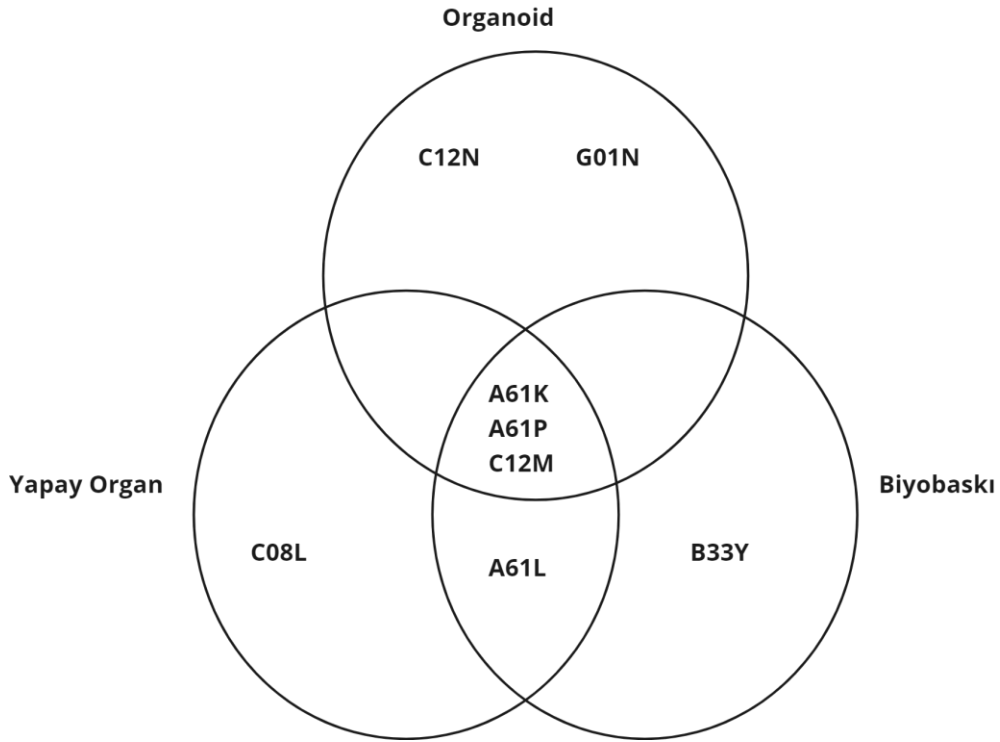
Tablo 4. 11. Biyobaskı Teknolojisi İçin Alt Sınıf IPC Kodlarına Göre 2024, 2025 ve 2026 Yılı Patent Sayısı Tahminleri ve Artış Oranları

Biyobaskı	Tahmin				
	2024	2024-2025 Artış Oranı	2025	2025-2026 Artış Oranı	2026
Toplam Patent Sayısı	687	100,59%	691	99,82%	690
A61L	319	109,09%	348	105,75%	368
C12N	228	99,56%	227	99,56%	226
B33Y	316	110,93%	351	109,69%	385
B29C	115	90,43%	104	91,35%	95
A61K	158	105,70%	167	105,39%	176
C12M	124	112,90%	140	103,57%	145
A61F	72	99,24%	71	99,25%	71
G01N	57	103,51%	59	106,78%	63
A61P	73	120,55%	88	114,77%	101
C08L	69	104,35%	72	109,72%	79
C08J	47	123,40%	58	124,14%	72
C12Q	27	108,40%	29	103,16%	30
C09D	37	124,32%	46	115,22%	53
C07K	57	112,28%	64	142,19%	91
B41J	16	81,25%	13	123,08%	16

4.5.4. Konsolide Yatırım Analizi

Bu bölümde, Bölüm 4.5'in önceki bölümlerinde organoid, yapay organ ve biyobaskı teknolojileri için yatırım yapılabilir olarak tahmin edilen alt sınıf IPC kodlarının teknolojilere göre kesişimleri belirlenecek ve en çok yatırım yapılabilir alanlar ortaya çıkartılacaktır.

Şekil 4.5, tez kapsamında bahsi geçen teknolojiler arasındaki yukarıdaki model tahminlerinde belirlenen yatırım yapılabilir alt sınıf IPC kodlarının 3 teknoloji için de kesişim alanlarını göstermektedir.



Şekil 4. 5. Organoid, Yapay Organ ve Biyobaskı Teknolojilerinin Yatırım Yapılabilirlik Kümesi

Tez çalışması kapsamında çalışılan organoid, yapay organ ve biyobaskı teknolojilerindeki tahmin sonuçlarında belirlenen yatırım yapılabilir alanların; teknolojilerle eşleştirilen alt sınıf IPC kodlarının, literatür ve bilimsel toplantılarda teknolojinin öncüleri tarafından artan bir ivme ile kullanılma durumu ve ticarileşme potansiyeli olan teknolojinin alt alanları ile uyumluluğu konuları değerlendirilmiştir.

Şekil 4.5’de gösterilen IPC kod tanımları aşağıdadır.

- **C12N:** Mikroorganizmalar veya Enzimler; Kompozisyonları; Mikroorganizmaların Yetiştirilmesi veya Muhafazası,
- **A61K:** Tıbbi, dişçilik veya tuvalet amaçları için preparatlar,
- **A61P:** Terapötik aktiviteye sahip spesifik aktif tıbbi maddeler,
- **G01N:** Malzemelerin belirlenmesi için yapılan analizler veya deneyler,
- **C12M:** Mikroorganizmalar veya Enzimlerle kullanılmak üzere düzenlenmiş laboratuvar aygıtları,

- **A61L**: Mikroorganizma, hayvan veya bitki hücrelerinin korunması, muhafazası veya sterilizasyonu için metotlar veya aparatlar
- **B33Y**: Katmanlı imalat; örneğin metal tozundan iş parçaları veya eşyaların 3D baskısı; iş parçaları veya eşyaların son işlemleri,
- **C08L**: Kimyasal olarak tanımlı yüksek moleküler ağırlıklı bileşiklerin kompozisyonları [56].

Buna göre;

- Her teknoloji için belirlenen yatırım yapılabilir beş alt sınıf IPC kodu alanının teknolojilerle ilişkili olduğu ve ticari anlamda yatırım yapılabilir olduğu,
- C12N ve G01N alanlarının özellikle organoid teknolojisiyle ilişkili alanlar olduğu ve sadece organoid teknolojisine yatırım yapmak isteyen şirket veya bireysel yatırımcıların bu alanlara yatırım yapabileceği,
- C08L alanının spesifik olarak bu üç teknoloji arasında en çok yapay organ teknolojisiyle ilişkili olduğu ve sadece yapay organ teknolojisine yatırım yapmak isteyen şirket veya bireysel yatırımcıların bu alana yatırım yapabileceği,
- B33Y alanının direkt olarak biyobaskı teknolojisinin ilgi alanı olduğu ve sadece biyobaskı teknolojisine yatırım yapmak isteyen şirket veya bireysel yatırımcıların bu alana yatırım yapabileceği,
- Yapay organ ve biyobaskı teknolojilerinin ortak alanlarının A61L alanı olduğu ve bu iki teknolojiye yatırım yapmak isteyen şirket veya bireysel yatırımcıların bu alana yatırım yapabileceği,
- Organoid, yapay organ ve biyobaskı teknolojilerinin kesişim noktalarındaki A61K, A61P ve C12M alt sınıf IPC kodlarının üç teknolojiyi kapsayan teknoloji alanları olduğu ve bu üç teknolojiye birlikte yatırım yapmak isteyen şirketler veya bireysel yatırımcıların A61K, A61P ve C12M alanlarına yatırım yapabileceği

değerlendirilmiştir.

5. SONUÇ VE GELECEK ÇALIŞMALAR

Tez kapsamında, daha önce ortak olarak patent madenciliği yapılmamış organoid, yapay organ ve biyobaskı teknolojileri için TYD, TYH, PG ve GP göstergelerinde ve yıllara göre patent verileri kullanılarak zaman serisi modeliyle teknolojilerin yatırım yapılabilme ve politika geliştirilebilme yönünden uluslararası patent sınıflandırma alanlarına ilişkin teknoloji tahmini yapılmıştır.

Benzer teknolojik altyapılara sahip olmalarına rağmen bu üç teknolojinin yaşam döngüsü evreleri birbirinden farklı çıkmıştır, yayılma hızları arasında biyobaskı ve organoid teknolojileri benzer çıksa da uzun yıllardır çalışılan yapay organ teknolojisini olgunluk evresinde olmasına rağmen yayılma hızı birçok alandan etkilendiğinden ve birçok alana etki ettiğinden dolayı bir hayli yüksektir. Patent güçleri kıyaslandığında, benzer seviyede olan bu teknolojilerin, genişleme potansiyellerine bakıldığında ise toplam alt sınıf IPC kod sayısının yaklaşık %20'sinden fazlasına etki ettikleri görülmüştür. Bu dört kritere göre yatırım yapma konusunda teknolojiler arasında çok belirgin bir farklılığı olmadığı ortaya çıkmıştır. Bu sebepten dolayı, teknolojilerin etki ettiği alt sınıf IPC kodlarındaki yıllara bağlı patent verileri zaman serisi modeline sokulmuş ve her teknoloji için yatırım yapılabilir en iyi beş alan belirlenmiştir. Sonrasında özellikle yatırımcıların risklerini azaltabilmeleri açısından her teknoloji için belirlenen en iyi beş alanın kesişim kümesi oluşturulmuş ve üç teknolojinin de ortaklaşa etki ettiği iki alan en çok yatırım yapılabilir alanlar olarak belirlenmiştir. Sadece yatırımın aksine, politika yapımcıların da bu alanlardaki gelişmeleri hızlandırabilmek için bu alanlara daha çok teşvik vererek bu teknolojilerdeki gelişmeleri destekleyebilirler.

Sonuç olarak tez kapsamında kullanılan ARIMA modeli gerçek verilere yakın tahmin değerleri ürettiğinden gelecekteki çalışmalarda da başka teknolojilerin tahmini yapılırken kullanılabilecek iyi yöntemlerden bir tanesidir. Çalışma kapsamı geliştirilerek, zaman serisi dışındaki diğer makine öğrenmesi algoritmaları (ANN, rassal orman, karar ağaçları vb.) da bu kapsamda patent verilerine uygulanırsa daha iyi sonuçların da çıkması kaçınılmaz olacaktır. Ancak, bu algoritmaların modele eklenebilmesi için patent sayılarının dışında da patent tescillerini etkileyen dış faktörlerinde modellere katılması gerekmektedir.

6. KAYNAKLAR

1. Iino Y, Hirokawa S, editors. Time series analysis of R&D team using patent information. International Conference on Knowledge-Based and Intelligent Information and Engineering Systems; **2009**: Springer.
2. Boo YL, Stirling D, Chi L, Liu L, Ong K-L, Williams G. Data Mining: 15th Australasian Conference, AusDM 2017, Melbourne, VIC, Australia, August 19-20, 2017, Revised Selected Papers: Springer; **2018**.
3. Kim G, Bae J. A novel approach to forecast promising technology through patent analysis. Technological Forecasting and Social Change. **2017**;117:228-37.
4. Zhang L, Li L, Li T. Patent mining: a survey. ACM Sigkdd Explorations Newsletter. **2015**;16(2):1-19.
5. Haupt R, Kloyer M, Lange M. Patent indicators for the technology life cycle development. Research Policy. **2007**;36(3):387-98.
6. Bamakan SMH, Babaei Bondarti A, Babaei Bondarti P, Qu Q. Blockchain technology forecasting by patent analytics and text mining. Blockchain: Research and Applications. **2021**;2(2).
7. Altuntas S, Dereli T. A regression-based “patent data analysis” approach: a case study for “weapon technology” evaluation process. IEEE Transactions on Engineering Management. **2022**;69(6):3874-86.
8. Chang S-B, Lai K-K, Chang S-M. Exploring technology diffusion and classification of business methods: Using the patent citation network. Technological Forecasting and Social Change. **2009**;76(1):107-17.
9. Altuntas S, Dereli T, Kusiak A. Forecasting technology success based on patent data. Technological Forecasting and Social Change. **2015**;96:202-14.
10. Gao L, Porter AL, Wang J, Fang S, Zhang X, Ma T, et al. Technology life cycle analysis method based on patent documents. Technological Forecasting and Social Change. **2013**;80(3):398-407.

11. Oxford English Dictionary 2024, <https://www.oed.com/> (Erişim Tarihi: **04.03.2024**).
12. Kim J, Koo BK, Knoblich JA. Human organoids: model systems for human biology and medicine. *Nat Rev Mol Cell Biol.* **2020**;21(10):571-84.
13. Lancaster MA, Knoblich JA. Organogenesis in a dish: modeling development and disease using organoid technologies. *Science.* **2014**;345(6194):1247125.
14. Locke M. Cellular membranes in development: Elsevier; **2012**.
15. Stamatialis DF, Papenburg BJ, Gironés M, Saiful S, Bettahalli SNM, Schmitmeier S, Wessling M. Medical applications of membranes: Drug delivery, artificial organs and tissue engineering. *Journal of Membrane Science.* 2008;308(1-2):1-34.
16. Li J, Chen M, Fan X, Zhou H. Recent advances in bioprinting techniques: approaches, applications and future prospects. *J Transl Med.* **2016**;14:271.
17. Thayer P, Martinez H, Gatenholm E. History and trends of 3D bioprinting. *methods Mol Biol.* **2020**;2140:3-18.
18. Dereli DD. Technology management in global competition and competitive advantage. *PressAcademia Procedia.* **2017**;4(1):313-318.
19. İntepe G. Teknoloji tahmini için yeni bir model önerisi, Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü; **2016**.
20. Tushman ML, Anderson P. Technological discontinuities and organizational environments. *Administrative Science Quarterly.* **1986**;31(3).
21. Erensal YC, Öncan T, Demircan ML. Determining key capabilities in technology management using fuzzy analytic hierarchy process: A case study of Turkey. *Information Sciences.* **2006**;176(18):2755-70.
22. Liao S-h. Technology management methodologies and applications. *Technovation.* **2005**;25(4):381-93.
23. Calleja-Sanz G, Olivella-Nadal J, Solé-Parellada F. Technology forecasting: recent trends and new methods. *research methodology in management and industrial engineering. Management and Industrial Engineering.* **2020**. p. 45-69.

24. Feng L, Wang Q, Wang J, Lin KY. A review of technological forecasting from the perspective of complex systems. *Entropy (Basel)*. **2022**;24(6).
25. Meade N, Islam T. Technological forecasting model selection, model stability, and combining models. *Management Science*. **1998**;44(8):1115-30.
26. Guidolin M, Manfredi P. Innovation Diffusion processes: concepts, models, and predictions. *Annual Review of Statistics and Its Application*. **2023**;10(1):451-73.
27. Bass FM, Krishnan TV, Jain DC. Why the Bass model fits without decision variables. *Marketing science*. **1994**;13(3):203-23.
28. Lilien GL, Rangaswamy A, De Bruyn A. Principles of marketing engineering: DecisionPro; **2013**.
29. Wu SD, Kempf KG, Atan MO, Aytac B, Shirodkar SA, Mishra A. Improving new-product forecasting at intel corporation. *Interfaces*. **2010**;40(5):385-96.
30. Grupp H, Linstone HA. National technology foresight activities around the globe. *Technological Forecasting and Social Change*. **1999**;60(1):85-94.
31. Mietzner D, Reger G. Advantages and disadvantages of scenario approaches for strategic foresight. *International Journal of Technology Intelligence and Planning*. **2005**;1(2):220-39.
32. Bañuls VA, Turoff M. Scenario construction via Delphi and cross-impact analysis. *Technological Forecasting and Social Change*. **2011**;78(9):1579-602.
33. Daim TU, Rueda G, Martin H, Gerdtsri P. Forecasting emerging technologies: Use of bibliometrics and patent analysis. *Technological Forecasting and Social Change*. **2006**;73(8):981-1012.
34. Altuntas S, Erdogan Z, Dereli T. A clustering-based approach for the evaluation of candidate emerging technologies. *Scientometrics*. **2020**;124(2):1157-77.
35. Han X, Zhu D, Lei M, Daim T. R&D trend analysis based on patent mining: An integrated use of patent applications and invalidation data. *Technological Forecasting and Social Change*. **2021**;167.

36. Han X, Zhu D, Wang X, Daim T, Qiao Y. Discovering technology opportunities based on the linkage between technology and business areas: matching patents and trademarks. *Technology Analysis & Strategic Management*. **2021**;35(10):1324-40.
37. Altuntas S, Sezer M. A Novel technology intelligence tool based on utility mining. *IEEE Transactions on Engineering Management*. **2023**;70(7):2480-92.
38. Moshari A, Aslani A, Zolfaghari Z, Malekli M, Zahedi R. Forecasting and gap analysis of renewable energy integration in zero energy-carbon buildings: a comprehensive bibliometric and machine learning approach. *Environ Sci Pollut Res Int*. **2023**;30(40):91729-45.
39. Han J, Pei J, Tong H. *Data mining: concepts and techniques*: Morgan kaufmann; **2022**.
40. Abbas A, Zhang L, Khan SU. A literature review on the state-of-the-art in patent analysis. *World Patent Information*. **2014**;37:3-13.
41. Liu C-Y, Wang J-C. Forecasting the development of the biped robot walking technique in Japan through S-curve model analysis. *Scientometrics*. **2010**;82(1):21-36.
42. Sinigaglia T, Eduardo Santos Martins M, Cezar Mairesse Siluk J. Technological evolution of internal combustion engine vehicle: A patent data analysis. *Applied Energy*. **2022**;306.
43. Gay C, Le Bas C, Patel P, Touach K. The determinants of patent citations: an empirical analysis of French and British patents in the US. *Economics of Innovation and New Technology*. **2005**;14(5):339-50.
44. Cowpertwait PS, Metcalfe AV. *Introductory time series with R*: Springer Science & Business Media; **2009**.
45. Jacobs JP, Smits J-P. *Historical time series analysis: an introduction and some applications*. *Jahrbuch für Wirtschaftsgeschichte/Economic History Yearbook*. **2006**;47(2):163-74.
46. Deutsch H-P, Beinker MW, Deutsch H-P, Beinker MW. Time series modeling. derivatives and internal models. *Modern Risk Management*. **2019**:753-76.

47. Anderson TW. The statistical analysis of time series: John Wiley & Sons; **2011**.
48. Veney JE. Evaluation applications of regression analysis with time-series data. Evaluation Practice. **1993**;14(3):259-74.
49. Zexi X, Haiyang Z, Yue M, editors. Long-term trend prediction algorithm based on neural network for short time series. 2019 IEEE Intl Conf on Parallel & Distributed Processing with Applications, Big Data & Cloud Computing, Sustainable Computing & Communications, Social Computing & Networking (ISPA/BDCLOUD/SocialCom/SustainCom); **2019**: IEEE.
50. Sökmen N, Petrov AE, editors. Forecasting of radar technologies using patent information. 2021 IEEE 15th International Conference on Application of Information and Communication Technologies (AICT); **2021**: IEEE.
51. Chen D-Z, Lin C-P, Huang M-H, Chan Y-T. Technology forecasting via published patent applications and patent grants. Journal of Marine Science and Technology. **2012**;20(4):1.
52. Akgül I. Zaman serisi analizi ve öngörü modelleri. Öneri Dergisi. **1994**;1(1):52-69.
53. Box GE, Jenkins GM, Reinsel GC, Ljung GM. Time series analysis: forecasting and control: John Wiley & Sons; **2015**.
54. Grillenzoni C. ARIMA processes with ARIMA parameters. Journal of Business & Economic Statistics. **1993**;11(2):235-50.
55. Hamilton JD. Time series analysis: Princeton university press; **2020**.
56. IPC Publication, <https://ipcpub.wipo.int/> (Erişim Tarihi: **30.04.2024**).

EKLER

EK 1 – Organoid Python Kodu

```
import pandas as pd

from statsmodels.tsa.arima.model import ARIMA

from sklearn.metrics import mean_squared_error

from math import sqrt

import itertools

# Load the dataset

df = pd.read_csv("Publication_Year_IPC_Organoid.csv")

# Set 'Publication Year' as the index and sort it

df['Publication Year'] = df['Publication Year'].astype(int)

df.set_index('Publication Year', inplace=True)

df.sort_index(inplace=True)

# Define the train-test split

train = df.loc[:2020]

test = df.loc[2021:2023]

# Define the p, d, and q parameters to take any value between 0 and 5

p = d = q = range(0, 6)

# Generate all different combinations of p, d, and q triplets

pdq = list(itertools.product(p, d, q))

# Dictionary to store models, metrics, and forecast results for each column

models_metrics_forecasts = {}

# Total steps to forecast (including 2024, 2025, 2026)

total_forecast_steps = len(test) + 3 # Adding 3 years for 2024-2026

# Grid search for ARIMA parameters

for column in train.columns:
```



```

best_mse = float("inf")

best_order = None

best_model = None

best_forecast = None

best_train_rmse = None

# Grid search

for param in pdq:

    try:

        # Fit the ARIMA model

        model = ARIMA(train[column], order=param)

        model_fit = model.fit()

        # Forecast including additional years

        forecast = model_fit.forecast(steps=total_forecast_steps)

        # Calculate MSE only for the test period to select the best model

        mse = mean_squared_error(test[column], forecast[:len(test)]) # Only considering
the forecast length up to the test data

        # Compare with the best MSE so far

        if mse < best_mse:

            best_mse = mse

            best_order = param

            best_model = model_fit

            best_forecast = forecast

            # Calculate the train RMSE for the best model

            train_predictions = model_fit.predict(start=train.index[0], end=train.index[-1])

            best_train_rmse = sqrt(mean_squared_error(train[column], train_predictions))

    except:

```

```

        continue

# Calculate RMSE for the test period
best_rmse = sqrt(best_mse)

# Store the best model, metrics, and forecasts
models_metrics_forecasts[column] = {
    'model': best_model,
    'order': best_order,
    'mse': best_mse,
    'train_rmse': best_train_rmse,
    'rmse': best_rmse,
    'forecast': best_forecast
}

# Print the forecast and metrics for each model
for column, details in models_metrics_forecasts.items():
    print(f"Best ARIMA model for '{column}': order {details['order']}")
    print(f"Train RMSE: {details['train_rmse']}")
    print(f"Test RMSE: {details['rmse']}")
    print(f"Forecasted values for years {test.index.tolist()} + 2024-2026:")
    print(details['forecast'].tolist())
    print(f"MSE: {details['mse']}")
    print('-----')

```

EK 2 – Yapay Organ Python Kodu

```
import pandas as pd

from statsmodels.tsa.arima.model import ARIMA

from sklearn.metrics import mean_squared_error

from math import sqrt

import itertools

# Load the dataset

df = pd.read_csv("Publication_Year_IPC_AO.csv")

# Set 'Publication Year' as the index and sort it

df['Publication Year'] = df['Publication Year'].astype(int)

df.set_index('Publication Year', inplace=True)

df.sort_index(inplace=True)

# Define the train-test split

train = df.loc[:2020]

test = df.loc[2021:2023]

# Define the p, d, and q parameters to take any value between 0 and 5

p = d = q = range(0, 6)

# Generate all different combinations of p, d, and q triplets

pdq = list(itertools.product(p, d, q))

# Dictionary to store models, metrics, and forecast results for each column

models_metrics_forecasts = {}

# Total steps to forecast (including 2024, 2025, 2026)

total_forecast_steps = len(test) + 3 # Adding 3 years for 2024-2026

# Grid search for ARIMA parameters

for column in train.columns:

    best_mse = float("inf")
```

```

best_order = None

best_model = None

best_forecast = None

best_train_rmse = None

# Grid search

for param in pdq:

    try:

        # Fit the ARIMA model

        model = ARIMA(train[column], order=param)

        model_fit = model.fit()

        # Forecast including additional years

        forecast = model_fit.forecast(steps=total_forecast_steps)

        # Calculate MSE only for the test period to select the best model

        mse = mean_squared_error(test[column], forecast[:len(test)]) # Only considering
the forecast length up to the test data

        # Compare with the best MSE so far

        if mse < best_mse:

            best_mse = mse

            best_order = param

            best_model = model_fit

            best_forecast = forecast

            # Calculate the train RMSE for the best model

            train_predictions = model_fit.predict(start=train.index[0], end=train.index[-1])

            best_train_rmse = sqrt(mean_squared_error(train[column], train_predictions))

    except:

        continue

```

```

# Calculate RMSE for the test period

best_rmse = sqrt(best_mse)

# Store the best model, metrics, and forecasts

models_metrics_forecasts[column] = {

    'model': best_model,

    'order': best_order,

    'mse': best_mse,

    'train_rmse': best_train_rmse,

    'rmse': best_rmse,

    'forecast': best_forecast

}

# Print the forecast and metrics for each model

for column, details in models_metrics_forecasts.items():

    print(f"Best ARIMA model for '{column}': order {details['order']}")

    print(f"Train RMSE: {details['train_rmse']}")

    print(f"Test RMSE: {details['rmse']}")

    print(f"Forecasted values for years {test.index.tolist()} + 2024-2026:")

    print(details['forecast'].tolist())

    print(f"MSE: {details['mse']}")

    print('-----')

```

EK 3 – Biyobaskı Python Kodu

```
import pandas as pd

from statsmodels.tsa.arima.model import ARIMA

from sklearn.metrics import mean_squared_error

from math import sqrt

import itertools

# Load the dataset

df = pd.read_csv("Publication_Year_IPC_B.csv")

# Set 'Publication Year' as the index and sort it

df['Publication Year'] = df['Publication Year'].astype(int)

df.set_index('Publication Year', inplace=True)

df.sort_index(inplace=True)

# Define the train-test split

train = df.loc[:2020]

test = df.loc[2021:2023]

# Define the p, d, and q parameters to take any value between 0 and 5

p = d = q = range(0, 6)

# Generate all different combinations of p, d, and q triplets

pdq = list(itertools.product(p, d, q))

# Dictionary to store models, metrics, and forecast results for each column

models_metrics_forecasts = {}

# Total steps to forecast (including 2024, 2025, 2026)

total_forecast_steps = len(test) + 3 # Adding 3 years for 2024-2026

# Grid search for ARIMA parameters

for column in train.columns:

    best_mse = float("inf")
```

```

best_order = None

best_model = None

best_forecast = None

best_train_rmse = None

# Grid search

for param in pdq:

    try:

        # Fit the ARIMA model

        model = ARIMA(train[column], order=param)

        model_fit = model.fit()

        # Forecast including additional years

        forecast = model_fit.forecast(steps=total_forecast_steps)

        # Calculate MSE only for the test period to select the best model

        mse = mean_squared_error(test[column], forecast[:len(test)]) # Only considering
the forecast length up to the test data

        # Compare with the best MSE so far

        if mse < best_mse:

            best_mse = mse

            best_order = param

            best_model = model_fit

            best_forecast = forecast

            # Calculate the train RMSE for the best model

            train_predictions = model_fit.predict(start=train.index[0], end=train.index[-1])

            best_train_rmse = sqrt(mean_squared_error(train[column], train_predictions))

    except:

        continue

```

```

# Calculate RMSE for the test period

best_rmse = sqrt(best_mse)

# Store the best model, metrics, and forecasts

models_metrics_forecasts[column] = {

    'model': best_model,

    'order': best_order,

    'mse': best_mse,

    'train_rmse': best_train_rmse,

    'rmse': best_rmse,

    'forecast': best_forecast

}

# Print the forecast and metrics for each model

for column, details in models_metrics_forecasts.items():

    print(f"Best ARIMA model for '{column}': order {details['order']}")

    print(f"Train RMSE: {details['train_rmse']}")

    print(f"Test RMSE: {details['rmse']}")

    print(f"Forecasted values for years {test.index.tolist()} + 2024-2026:")

    print(details['forecast'].tolist())

    print(f"MSE: {details['mse']}")

    print('-----')

```