



**T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



YÜKSEK LİSANS TEZİ

**KATILIM BANKACILIĞINDA YAPAY ZEKA DESTEKLİ ÜRÜN ÖNERME
MODELİ**

Pelin Nazlı EZBER

**DANIŞMAN
Doç. Dr. Ersin NAMLI**

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği, Tezli Yüksek Lisans Programı

Nisan, 2024

TEZ KABUL VE ONAYI

Pelin Nazlı EZBER tarafından, **Doç. Dr. Ersin NAMLI** danışmanlığında hazırlanan "**KATILIM BANKACILIĞINDA YAPAY ZEKA DESTEKLİ ÜRÜN ÖNERME MODELİ**" başlıklı bu çalışma, jürimiz tarafından **26/04/2024** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

	İmza	Sonuç
DANIŞMAN	Doç. Dr. Ersin NAMLI	☒
	İstanbul Üniversitesi-Cerrahpaşa	Kabul
	Endüstri Mühendisliği Anabilim Dalı	☐ Ret
ÜYE	Doç. Dr. Ramazan ÜNLÜ	☒
	Abdullah Gül Üniversitesi	Kabul
	Endüstri Mühendisliği Anabilim Dalı	☐ Ret
ÜYE	Dr. Öğr. Üyesi Ayşe Nur Adıgüzel	☒
	İstanbul Üniversitesi-Cerrahpaşa	Kabul
	Endüstri Mühendisliği Anabilim Dalı	☐ Ret

İslami Finans'ın gelişimine katkı sunmak isteyen tüm arkadaşlara ithaf ediyorum...

BÜTÇE DESTEKLERİ

KATILIM BANKACILIĞINDA YAPAY ZEKA DESTEKLİ ÜRÜN ÖNERME MODELİ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Desteklerinden dolayı danışman hocam Doç. Dr. Ersin Namlı'ya teşekkür ederim.

Nisan 2024

Pelin Nazlı EZBER



İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI.....	ii
BEYAN	iii
BÜTÇE DESTEKLERİ	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ.....	xi
SİMGE VE KISALTMA LİSTESİ	xii
ÖZET	xiii
ABSTRACT	xiv
1. GİRİŞ.....	1
2. KAVRAMSAL ÇERÇEVE	2
2.1. İSLAMİ FİNANSTA FAİZ KAVRAMI	2
2.1.1. Faiz ile Ticaretin Farkı	3
2.1.2. Faiz Türleri	4
2.2. KATILIM BANKACILIĞI	5
2.2.1. Katılım Bankacılığı Felsefesi ve İlkeleri.....	6
2.2.2. Dünya’da ve Türkiye’de Katılım Bankacılığı	8
2.2.3. Fon Toplama Yöntemleri	15
2.2.4. Fon Kullanırma Yöntemleri	20
2.3. MAKİNE ÖĞRENMESİ	32
2.3.1. Literatür Taraması	34
2.3.2. Kullanım Alanları.....	37
2.3.3. Sınıflandırma	38
2.3.4. Kümeleme	39
2.3.5. Birliktelik Analizi.....	40
2.3.6. Regresyon.....	44
2.3.7. Makine Öğrenmesi Metotları	58

2.4. ÖNERİ SİSTEMLERİ	64
2.4.1. Öneri Sistemleri Literatür Taraması	66
2.4.2. Kullanılan Yöntemler	70
3. YÖNTEM	77
3.1. ÇALIŞMANIN AMACI	77
3.2. VERİ SETİNİN TANITIMI	77
3.3. FP GROWTH ALGORİTMASI PYTHON KODU	84
3.4. AKIŞ ŞEMASI	88
4. BULGULAR	90
4.1. KÜMELEME	90
4.1.1. Genel Çıktılar	90
4.1.2. Oluşturulan Kümelerin İncelenmesi	93
4.2. BİRLİKTELİK ANALİZİ	102
4.2.1. Kümelenen Veriye Uygulanan FP Growth	102
4.2.2. Banka Değer Segmentlerine Uygulanan FP Growth	111
5. TARTIŞMA	115
6. SONUÇ VE ÖNERİLER	117
KAYNAKLAR	119
İNTİHAL RAPORU İLK SAYFASI	123
ETİK KURUL İZİN YAZISI	124
KURUM İZNİ YAZILARI	125
ÖZGEÇMİŞ	126

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Cari Hesap İşleyişi.....	16
Şekil 2.2: Katılım Hesabı İşleyişi.....	19
Şekil 2.3: Murabaha Uygulanma Aşamaları.....	24
Şekil 2.4: Müşareke'nin Genel İşleyişi.....	26
Şekil 2.5: Öneri Sistemlerinde Kullanılan Yöntemler.....	71
Şekil 2.6: İşbirlikçi Filtreleme İşleyişi.....	73
Şekil:3.1: Yaş Dağılımı.....	82
Şekil 3.2: Cinsiyet.....	83
Şekil 3.3: Medeni Durum.....	83
Şekil 3.4: Çocuk Sayısı.....	85
Şekil 3.5: Uygulama Akış Şeması.....	88
Şekil 4.1: Kümeleme Sonucu Müşterilerin Dağılımı.....	90
Şekil 4.2: Heat Map.....	91
Şekil 4.3: Kümelerdeki Baskın Özellikler Genel Görünüm.....	92
Şekil 4.4: Küme 0 Baskın Özellikleri.....	93
Şekil 4.5: Küme 0 Dağılım Detayı Grafiği.....	93
Şekil 4.6: Küme 1 Baskın Özellikleri.....	94
Şekil 4.7: Küme 1 Dağılım Detayı Grafiği.....	94
Şekil 4.8: Küme 2 Baskın Özellikleri.....	95
Şekil 4.9: Küme 2 Dağılım Detayı Grafiği.....	95
Şekil 4.10: Küme 3 Baskın Özellikleri.....	96
Şekil 4.11: Küme 3 Dağılım Detayı Grafiği.....	96
Şekil 4.12: Küme 4 Baskın Özellikleri.....	97

Şekil 4.13: Küme 4 Dağılım Detayı Grafiği.....	97
Şekil 4.14: Küme 5 Baskın Özellikleri.....	98
Şekil 4.15: Küme 5 Dağılım Detayı Grafiği.....	98
Şekil 4.16: Küme 6 Baskın Özellikleri.....	99
Şekil 4.17: Küme 6 Dağılım Detayı Grafiği.....	99
Şekil 4.18: Küme 7 Baskın Özellikleri.....	100
Şekil 4.19: Küme 7 Dağılım Detayı Grafiği.....	100



TABLO LİSTESİ

	Sayfa No
Tablo 2.1: Geleneksel Bankacılık-Katılım Bankacılığı Karşılaştırılması.....	6
Tablo 2.2: Vakıf Katılım Ortaklık Yapısı.....	13
Tablo 2.3: Makine Öğrenmesi Literatür Çalışması.....	34
Tablo 2.4: Apriori & FP Growth Karşılaştırması.....	43
Tablo 2.5: Öneri Sistemleri Literatür Çalışması.....	66
Tablo 3.1: Veri Setinden Örnek Kesit.....	78
Tablo 4.1: Kümeleme Sonucu Müşterilerin Dağılımı.....	90
Tablo 4.2: Kümeleme Performansı Tablosu.....	91

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
TKBB	: Türkiye Katılım Bankaları Birliği
TMSF	: Tasarruf Mevduatı Sigorta Fonu
IIFM	: International Islamic Financial Market
YSA	: Yapay Sinir Ağları
PCA	: Principal Component Analysis
CNN	: Convolutional Neural Networks
RBF	: Radyal Baz Fonksiyon
SPSS	: Statistical Package for the Social Sciences
TOM	: Techology of Money
EFT	: Elektronik Fon Transferi
ATM	: Automated Teller Machine
DBSCAN	: Density Based Spatial Clustering of Applications with Noise
FP Growth	: Frequent Pattern Growth

ÖZET

[YÜKSEK LİSANS TEZİ]

[KATILIM BANKACILIĞINDA YAPAY ZEKÂ DESTEKLİ ÜRÜN ÖNERME MODELİ]

[Pelin Nazlı EZBER]

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği, Tezli Yüksek Lisans Programı

[Danışman: Doç. Dr. Ersin NAMLI]

Her geçen gün yeni çalışmalarla gelişen yapay zekâ özellikle tahminleme çalışmalarıyla belirsizlik içinde yaşadığımız anları aydınlatmaktadır. Öngörünün son derece önemli olduğu finans alanında gelecek durum ve rakamlarla ilgili tahmin yürütebilmek hayati olduğundan dolayı; bankacılık, sektör olarak yapay zekadaki gelişmelerin önde gelen takipçilerinden olmuştur. Konvansiyonel bankacılık sistemi agresif uygulamalara ve alternatiflere açık olsa da katılım bankacılığında İslami prensiplerin oluşturduğu kısıtlarla hareket alanı daralmakta ve aksiyonların en doğru seçenek olması önem kazanmaktadır.

Bu çalışmanın amacı yapay zekâ destekli modellerle katılım bankacılığının gelişimine katkı sunmaktır. Bu amaç doğrultusunda konuyla ilgili detaylı araştırmalara yer verilip analizler yapılmış, uygulama olarak kümeleme ve birliktelik analizi ile yapay zekâ destekli ürün önerme modeli kurulmuştur. Bu modelle her bir müşteriye en doğru ürünün önerilmesiyle müşteri aktifliği ve sadakati arttırılması amaçlanmaktadır.

Nisan 2024 , [126] sayfa.

Anahtar kelimeler: [Katılım Bankacılığı, Makine Öğrenmesi, Ürün Önerme Sistemleri]

ABSTRACT

[M.Sc. THESIS]

[ARTIFICIAL INTELLIGENCE SUPPORTED PRODUCT RECOMMENDATION MODEL IN PARTICIPATION BANKING]

[Pelin Nazlı EZBER]

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Industrial Engineering

Industrial Engineering, Thesis Master's Program

[Supervisor: Assoc. Prof. Dr. Ersin NAMLI]

Artificial intelligence, which develops with new studies every day, illuminates the moments we live in uncertainty, especially with forecasting studies. Since it is vital to be able to make predictions about future situations and figures in the field of finance, where foresight is extremely important, banking has been one of the leading followers of developments in artificial intelligence as a sector. Although it is open to aggressive practices and alternatives in the conventional banking system, the room for maneuver is narrowed by the constraints imposed by Islamic principles in participation banking, and it becomes important that the actions are the most accurate option.

The aim of this study is to contribute to the development of participation banking with artificial intelligence-supported models. For this purpose, detailed research on the subject was included and analyzed, and an artificial intelligence-supported product recommendation model was established with clustering and association analysis as an application. With this model, it is aimed to increase customer activity and loyalty by recommending the most accurate product to each customer.]

April 2024, [126] pages.

Keywords: [Participation Banking, Machine Learning, Recommendation Systems]

1. GİRİŞ

Katılım bankacılığı, tasarruflarını faizsiz esasa göre değerlendirmek isteyen tasarruf sahipleri ile finansman ihtiyaçlarını yine aynı esasa göre sağlamak isteyen iş sahipleri ve girişimciler için mevcut boşluğu dolduran sektör olarak doğmuştur. Bu sektör, hem ülkedeki atıl kaynakların ekonomiye kazandırılmasını sağlamış hem de bankacılığın asli görevi olan fon toplama ve kullandırma işlevlerinde geliştirdiği yeni ürünlerle sektörün çeşitlilik ve derinliğini artırmıştır. Birçok kısıt bulunan katılım bankacılığında işlemler konvansiyonel bankalar kadar esnek değildir. Türkiye Katılım Bankaları Birliği'nin belli esaslarının olmasının yanında Uluslararası İslami Finansal Piyasalar Kurumu da (International Islamic Financial Market – IIFM) İslami enstrümanlara ilişkin anlaşmaları standart hale getirip yayınlamaktadır. Bu kural ve kısıtlar arasında müşteri kazanımı oldukça kritik bir konu haline gelmektedir. Bankaların ilgili departmanlarında bu konuda detaylı çalışmalar yapılırsa da bu tahminleme, makine öğrenmesi ile oldukça kolay yapılabilir. Dahası çok daha isabetli sonuçlar alınabilir. Makine öğrenmesi, insanların öğrenme şekillerini taklit etmek için veri ve algoritmaların kullanımına odaklanıp doğruluğunu kademeli olarak artıran bir yapay zekâ ve bilgisayar bilimi dalıdır. Geçmişteki tecrübeleri veri olarak kaydedip bu verideki döngüsellliği bir algoritmaya oturtarak gelecekteki davranış ile ilgili tahminleme yapılabilir. Müşterileri ediniminden sonra kazanılan müşterileri aktif tutmaksa ancak müşteriye kendisine en uygun ürünleri kaliteli hizmet anlayışıyla sunmakla mümkündür. Bu aksiyon da yine makine öğrenmesi ile en verimli şekilde gerçekleştirilebilir.

Bu çalışmada İslami finans ve makine öğrenmesi ile ilgili yapılan detaylı çalışmanın ardından müşterilerin aktif kalabilmesi ve kendisine en doğru ürünün sunulmasını sağlanması için RapidMiner programı kullanılarak random CRM test verisine önce K-Means algoritmasıyla kümeleme, daha sonra da FP Growth algoritmasıyla birliktelik analizi yapılmıştır.

2. KAVRAMSAL ÇERÇEVE

2.1. İSLAMİ FİNANSTA FAİZ KAVRAMI

İslam finansında faiz yerine Arapça kökenli, fazlalık, çoğalma gibi anlamlara gelen riba ifadesi kullanılmaktadır. En basit haliyle borçlanma işlemlerinde zamana dayalı olarak tutarda ortaya çıkan fazlalık olarak tanımlamak mümkündür. TKBB'nin tanımına göre faiz, rizikoya katılmadan para ticaretinden elde edilen fazlalık veya eksikliklerdir.

Konvansiyonel bankacılık sistemine alışkın ve katılım bankacılığını tanımayan kişiler sıfır faiz ile çalışmanın kazanç sağlanmadığı için yatırım yapılamayan bir ortam ve sıfır ekonomik büyüme ile sonuçlanacağını düşünmektedirler. Bu tamamen kazanç elde etmek ile faizi eş tutan bir düşünce sistemidir. Oysa ticarete getiri ve kazanç mevcut olduğu gibi zarar da mevcuttur ve katılım bankacılığı sistemi bunu da göz önünde bulundurarak işlem sonucu olan çıktının tarafların aldığı riske göre adil bir şekilde paylaşılmasına dayanır.

Faiz kavramına olan olumsuz tepki insanların zihninde İslami değerlerle eşleşse bu alanda uzman olan kişilerin belirttiklerine göre İncil ve Tevrat'ta da faizin yasak olduğu ile ilgili ifadeler yer almaktadır. Tarihe bakıldığında da aydınlanma döneminden önceki Hristiyanlıkta da faizin günah ve ticarete yasak olduğu görülmektedir. Günümüzde Hristiyan yoğunluklu toplumlarda faizin ne kadar kök saldıgını düşününce bu gerçek şaşırtıcı olsa da uzmanlar Luka İncilinde faizin hem Hristiyanlar arasında hem de bir Hristiyan'ın Hristiyan olmayan birine borç vermesi veya ticaret yapması esnasında yasaklandığını belirtmektedirler. 15. yüzyılda Martin Luther'in başlattığı reform hareketi kilisenin yozlaşmış sistemine duyulan güven ve saygının kırılmasına sebep olmuştur. Tamamen akılcı bir felsefe izleyen akım hızla yayılırken incilin buyruklarını da tarihe karıştırmış, faize olan hassasiyet azalmasıyla neredeyse tamamen faizden beslenen, insan olmanın anlamını unutan büyük ekonomilerin kurulması ile günümüze kadar gelmiştir. Museviliğe bakıldığında Hristiyanlığın aksine Museviler faizin Tevrat'ta sadece Museviler arasında yasak olduğunu söylemektedirler. Faşizmin sınırlarında gezen bir toplumun söz konusu ticaret olunca da kendilerini diğer dinlerden ayrı ve ayrıcalıklı konumlandırması şaşırtıcı değildir. Musevilerin kendi aralarındaki ticarete faizin kesinlikle yasak olduğunu ancak borç verilen veya ticaret yapılan kişi Musevilik dışında bir dine mensup ise istedikleri faizi alabileceklerini düşünmektedirler. Kuran-ı Kerim'e göre ise her iki dinin

kutsal kitabı da bu dinlerin mensupları tarafından tahvil edilmiştir, günümüzdeki halleri gerçeklikten uzaktır.

Biraz daha önceki dönemlere baktığımızda dini değerlerin bulunmadığı zamanlarda bile faiz hoş karşılanmıyordu çünkü etik değildi. Platon’a göre para servet değil servet edinmek için bir araçtır. Bu yüzden servetin kendisi görülerek daha da büyütme amacıyla arttırılmaması, biriktirilmemesi gerekmektedir. Aksi halde paradan para kazanılması ile oluşan faiz sistemi o dönemin tabiriyle “ideal devlet” yapısını bozacaktır. İdeal devlet yapısının bozulması bugünkü toplumsal sıkıntıların ortaya çıkmasıyla eş değerdir. Adaletsizlik, toplumsal gelirde tekelleşme ve tembellik ilk çıktılar olacağı gibi beraberinde birçok sıkıntıyı da getirecektir. Böyle bir ortamda bulunan insanların psikolojileri zarar görecek bu da suç oranını arttırıp güven ortamını yıkacaktır. Yani aslında faiz, alışveriş sırasında alınan küçük bir farktan çok daha fazlasıdır, toplumu zehirleyen, içten çökerten bir tehlikedir. Aristo’nun düşünceleri de Platon’dan farklı değildir. Platona göre para kazanmanın tek doğal yolu üretmektir. Bu senaryoda para kazanmak amaç değil sonuçtur. Hiç üretim yapmadan, sadece para kazanma amacıyla paranın arttırılması olabilecek en kötü para kazanma biçimidir çünkü paranın kullanılmasındaki amaç ticaret esnasında bir tarafın mal verirken öteki tarafın tam olarak o malın değerinde değiştirecek bir şeyi olmaması durumunda ihtiyacına ulaşabilmesi için bir araç olmasıdır. Böyle düşünüldüğünde ihtiyaçları elde etmede kullanılan bir aracın arttırılması kullanım amacı ile çelişmektedir.

2.1.1. Faiz ile Ticaretin Farkı

Mal & hizmet ticaretinde satıcının satış tutarına karını eklemesi ticaretin bir gereğidir ve doğaldır. Paranın (ve benzerlerinin) değerinin üzerinde satılması ise faizdir. Bir diğer deyişle; bir kişinin ürettiği mal veya hizmet karşılığında maliyete karını ekleyerek ürününü satması mubahtır; çünkü ortada bir emek, ürün veya hizmet vardır. Burada eklenen tutar kâr payıdır ve faiz ile karıştırılmaması gerekir. En yalın tabiriyle faiz, paradan para kazanmak olarak tanımlanabilir. Para yerine geçen gereçlerin borçlandırılırken verilen paranın alınan paradan fazla olması ya da vadeli satılması faizdir. Faizin yasaklanmasının en büyük getirisi insanları üretime sevk etmesidir. Ticaret üretime sevk ederken paranın kar eklenerek satılması insanları üretime, çalışmaya ve çalışkanlığa yöneltir. Dinamik, işleyen bir ekonomi bu senaryonun en doğal çıktısıdır. Yani İslami finans; sosyal ve çevresel açıdan duyarlı yatırımlarla sadece insanı değil, ekonomiyi, toplumu ve çevreyi de korur.

Ticaret ile faizin farkını birkaç maddede özetlemek mümkündür:

- Mal & hizmet satışı yapan satıcının kar etme olasılığı olduğu gibi zarar etme olasılığı da vardır.
- Ticarete ürünü almak isteyen ürüne, satıcı ise ürünün karşılığı nakdi değere sahip olur. Böylelikle karşılıklı rıza ile tarafların menfaati adil bir şekilde sağlanır.
- Ticarete ekonomi işler, gelişir. Böylelikle arz ve talep dengesi sağlanır. Faiz ise paranın değerinin üstünde satışıyla enflasyona ve toplumda gelir eşitsizliğine sebep olur. Dolayısıyla toplumda sosyoekonomik yapıyı bozar.
- Ticaret çalışmaya, üretmeye ve faydalı olmaya sevk ederken faiz hiç emek vermeden kazanma felsefesine dayanır, toplumu tembelleştirir. Üretmeden tüketme davranışını ortaya çıkarır.

2.1.2. Faiz Türleri

İslam bakış açısına göre para bir servet değil; servet edinme aracıdır. Buhari'nin rivayetine göre Hz. Peygamber “Altın altınla, gümüş gümüşle, buğday buğdayla, arpa arpayla, hurma hurmayla ve tuz tuzla misli misline, eşit ve peşin şekilde trampa edilir. Farklı cinsler birbiriyle mübadele edilirse, peşin olmak şartıyla dilediğiniz gibi satış yapınız” buyurmuştur. Bu hadis ekonominin gelişmesi ile Fıkıhçılarca “para yerine geçen kıymetlerin” alışverişinde peşin ödeme şartına dönüşmüştür. Örneğin unu peşin 10 TL'ye satarken 3 ay vade ile ayda 40 TL'ye satmak mubahtır. Bu senaryoda bir mal satışı vardır ve satıcı malı satarken kâr payı almaktadır ancak satıcı para yerine geçebilecek bir kıymet olan altın satarken peşin fiyatına satış yapmak zorundadır. Bu şart varken de taksit yapması kendi menfaatine olmayacaktır. Taksitli satışına tutar farkı eklerse bu faiz olacaktır ve İslam'da kesin olarak yasaklanmıştır. 3 çeşit faiz vardır:

2.1.2.1. Cahiliye Faizi

Satış esnasında belirlenen vadenin dolması ve borcun ödenmemesi durumunda borçta artışa gidilmesi şartı ile alıcıya verilen ödeme süresinin arttırılması Cahiliye Faizidir. Modern dünyada karşılığı tam anlamıyla tefeciliktir.

2.1.2.2. Fazlalık Faizi

Farklı çeşit ürünlerin alışverişi sırasında satıcının karını ortaya koymasını ticarettir ancak aynı cinsteki değerlerin birbiriyle değiştirilmesi sırasında taraflardan birinin diğerinden fazla alması fazlalık faizidir. Altınla altının, elmayla elmanın, hurmayla hurmanın değiştirilmesinde birinin diğerinden fazla olması fazlalık faizine örnektir.

2.1.2.3. Nesîe Faizi

Alışveriş sırasında aynı değerlerin takası mevzu bahis ise ve vadeli ödeme karşılığında bahsi geçen değer üzerinden alınan fazlalık nesîe faizidir. 1 ekmeğin 5 gün sonra 3 ekmeğe olarak ödenmesi nesîe faizine örnektir. Bu faiz türü günümüzde altın ticareti yapan kişiler arasında sıklıkla rastlanmaktadır.

2.2. KATILIM BANKACILIĞI

Temel yapısı itibariyle faizsiz bankacılık modeli olarak katılım bankacılığını, parasal işlemlerle mal ve hizmet hareketlerinin birbirine sıkı sıkıya bağlı olduğu, her para hareketinin mutlaka bir ortaklığa veya mal ya da hizmete karşılık geldiği; gelirin ise ortaklık esaslarına göre bölüşüldüğü sistem olarak tanımlamak mümkündür. (Özsoy, 2012) İslami usullere göre faaliyet gösteren Katılım Bankaları sadece fonlama ihtiyaçlarını karşılamak veya fon fazlalarını değerlendirmek için değil aynı zamanda likidite risklerini yönetmek amaçlarıyla sıklıkla organize olmayan para piyasalarında İslami usullere uygun olarak geliştirilmiş para piyasası enstrümanlarını kullanarak işlem yapmaktadırlar.

Paranın zaman değerine ilişkin İslami finansal değerlendirme, ödünç verilebilir işlemlerle değil, yalnızca ertelenmiş takasla ilgilidir. (Shafii ve diğerleri, 2013) Aynı zamanda İslami finans, borç verenin aşırı sömürsünü korumayı amaçlar ve borçlunun anaparaı faiz olarak herhangi bir ek tutar ödemedenden geri ödemesini kabul eder. Bu, toplumun refahını destekleyen gerçek hayırsever kredileri yansıtır. Toplumdaki yoksullar göz önünde bulundurularak, borç verenin kararlaştırılan sürede krediyi geri ödemekte güçlük çekmesi durumunda, borç verenin işletmenin sürekliliği için daha fazla fırsat verebilmesi için kredi süresinin uzatılmasına yönelik bir hüküm vardır. (Hassan ve diğerleri, 2019)

Birçok bakımdan geleneksel bankacılıktan ayrılan katılım bankacılığının farklılıkları şu şekildedir:

Tablo 2.1: Geleneksel Bankacılık-Katılım Bankacılığı Karşılaştırılması

Geleneksel Bankacılık	Fark Yönü	Katılım Bankacılığı
Yasal olan her işlem yapılır.	<i>İşleyiş</i>	İslami finans araçları kullanılır.
Risk bedel gerektirir.	<i>Risk</i>	Risk paylaşım gerektirir.
Paranın zaman değeri vardır ve bu değer her zaman borç verenin lehine artış gösterir.	<i>Ortaklık</i>	Paranın zaman değeri yoktur. Ortaklık yöntemiyle de elde edildiği için değer kaybetmesi kazanması kadar olağandır ve bu durumdan her iki ortak da katkısı kadar etkilenir.
Faiz ile gelir elde edilir.	<i>Faiz</i>	Bir mal veya hizmetin satışı sırasında kar payı ile gelir elde edilir.
Kredi (borç verme) yöntemiyle fon kullanılır.	<i>Fon Kullandırma Araçları</i>	Ticaret veya ortaklık yöntemleriyle fon kullanılır.
Nakdi fon kullanılır.	<i>Fon Kullandırım Şekli</i>	Nakdi fon kullanılmaz, her zaman ürün veya hizmet fonlanır.

2.2.1. Katılım Bankacılığı Felsefesi ve İlkeleri

“Katılım” kelimesinin doğuşundan önce İslami esaslara uygun olarak yürütülen finans işlemlerinin tamamı için “İslam finansı” kavramı kullanılıyordu. Bu durum katılım bankacılığında yerinde sayma ve tembelliğe ortam oluştuyordu çünkü yapılan her geliştirme tek bir tanım ile ifade ediliyordu. Bu tanım oldukça geniş ve kapsayıcı olduğundan çalışmalar bu çatı altında oldukça önemsiz görünüyordu. İslami finans faiz, kumar, aşırı spekülasyon davranışların yasak olduğu sınırlar içerisinde faaliyet göstermektedir. Sosyal ekonomide devletin, kapitalist ekonomide güçlülerin çıkarları esas alındığı gibi İslami ekonomide insanların çatışma içinde olmayan ortak çıkarları ve iyi halde olma durumu esastır. Temelinde insan olduğu için toplumsal, sosyal ve çevresel unsurlar etkileşim halindedir. Eşitlikten ziyade adalet ön plandadır, yardımlaşmaya teşvik eder. Borçlanma durumlarında faizin yasak olması bunun en büyük ispatıdır. İslami esaslara uygun olarak Bankacılık faaliyetleri yürüten

Kurumlar faizsiz banka olarak biliniyor, yurt dışındaki Teminat mektubu işlemlerinde oldukça sıkıntı yaşıyorlardı. Dahası bu kurumların yaptığı hatalar “İslam” ile örtülmeye müsait haldeydi. Tüm bu sebeplerin neticesinde özgün, bütün ve özü tarif eden bir isim bulma süreci başladı ve katılım felsefesi ile katılım bankacılığı kavramları bulundu. Katılım felsefesinin temeli Necm Suresinde insanın ancak emeği ile var olduğu ayeti yatmaktadır. Katılım bankacılığı dinamik bir yapı olup kendi prensiplerinden çıkmadan sürekli gelişme halinde olmalıdır. Katılım felsefesine baktığımızda ise insanın hayata, işe, kâinata katılımının yer aldığını görürüz. Katılım bankalarını konvansiyonel bankalardan ayıran en temel farklardan biri de bu felsefeye uygun olarak ortaklıklarda tarafların kara da zarara da birlikte katılmasıdır. Kar-zarar ortaklığı ile tarafların kazancı ortaya koydukları girdi ile orantılı olarak paylaşılır. Böylelikle tam bir adalet sağlanmış olur. Toplum arasında gelir eşitliği beslenir. Katılım bankacılığının tüm ilkeleri iç içe geçmiş bir şekilde birbiri ile uyum halindedir. Detayları ile aşağıdaki gibidir:

2.2.1.1. Adalet İlkesi

Allah için adaleti ayakta tutun, adalet timsali şahitler olun ve bir topluluğa karşı olan kininiz sizi adaletsizliğe sürüklemesin. Adil davranın... (Maide Suresi, 8) ayeti ile hayatın her alanında adil olunması gerektiğini net bir şekilde belirtmektedir. İslami finansın kaynağı da doğrudan Kur'an olduğundan dolayı adalet katılım bankacılığının da en temel ilkesidir.

2.2.1.2. Tevhit İlkesi

Tevhit eşitlik içinde bir olma, birlik olma halidir. Katılım bankacılığında da tüm insanların kardeş olduğu fikri yatmaktadır. Bu yüzden de kimse kimseyi mağdur etmemeli, hakkını yememelidir. Menfaatlerin karşılıklı olarak sağlanması gereklidir. Bir Müslümanın yaptığı her işte, girdiği her ortamda ahlaklı olması ve ahlaklı kalması gereklidir. Toplum ancak bu şekilde birlik halinde kalacaktır. Karar alma aşamalarında birliğin sağlanması ise istişareye bağlıdır. İstişare ile insanlar sürece dahil olur, olaylarda söz sahibi olurlar. Yani bir diğer deyişle hayata katılırlar. Bu yüzden katılım felsefesinin olmazsa olmazlarındandır. Tevhit ilkesi ile ilgili bir diğer bahsedilmesi gereken ana unsur akitlerdir. Akit İslam'da her alanda önemli olduğu gibi finans alanında da oldukça önemlidir. Toplumsal alandaki her türlü işte tarafların karşılıklı olarak rızası esastır. Akitler ile yapılan işlerin süreci ve sonucu şeffaftır, işlemler kayıtlı ve hesap verilebilirdir. Özetle; sürdürülebilir bir İslami finans sistemi elde etmek için akitler olmazsa olmazdır.

2.2.1.3. Mizan İlkesi

Mizan ilkesi “Mizanda haddi aşmayın...” (Rahman Suresi, 8) ayetine dayanmaktadır ve farklı açılardan yorumlanabilmektedir. Bu yorumlardan ilki mizanın Arapça ’da terazi anlamına geldiği düşünülürse ticarete dürüst davranmak gerektiğidir. Terazi aynı zamanda eşitliği ve dengeyi de sembolize etmektedir. Dolayısıyla ayetten insanların her alanda dengeli olmaları, aşırıya gitmemeleri gerek gelirden gerekse yaşama biçimlerinde benzer olmaları gerektiği çıkarılmaktadır. İslam’da geliri fazla olanın malının bir kısmını geçinmede zorluk çekenle paylaşımı esasına dayanan zekât adındaki yardımlaşma da mizan ilkesiyle toplumdaki dengeyi sağlamaya yönelik araçlardan biridir.

2.2.1.4. Faiz Yasağı İlkesi

Ticaretin işleminin ve üretim-tüketim dengesinin sağlanmasının yolu üretmekten geçer. Her üretim bir değer ve emek içerir. Emek vermeden kazanmak, üretmeden tüketmek katılım bankacılığının önüne geçmeye çalıştığı senaryolardır. Faiz emeksiz para kazanmanın diğer adıdır ve kesin bir şekilde yasaktır.

2.2.1.5. Risk Ortaklığı İlkesi

Faizsiz finansın temel ilkelerinden olan risk ortaklığı ilkesiyle ortaklıklardaki getiri, en baştan sabit değil işlemin sonucunun belli olmasıyla birlikte paylaşılır. Böylelikle yapılan işlemde adalet sağlanır zira her ticari girişimin kar ile sonuçlanacağı hiçbir koşulda garanti değildir. Konvansiyonel bankacılıkta bu kar paylaşımı tamamen borç vereni yani sermayedarı korumaya yönelikken katılım bankacılığı tarafların menfaatlerini eşit olarak sağlamaya çalışır. Ortaklardan birinin kar etmesi ile diğer ortağın zarar etmesi kabul edilemez bir durumdur. Getiri kar da olsa zarar da risk ortaklığı ilkesi gereği kişilerin aldığı risk kadar ortaklara paylaştırılır. En basit haliyle somutlaştırmak gerekirse; bir ortaklıkta taraflardan biri x, diğeri 2x kadar sermaye ortaya koyduysa x kadar risk alan taraf işlem sonucunda elde edilen karın $\frac{1}{3}$ ’ini alır.

2.2.2. Dünya’da ve Türkiye’de Katılım Bankacılığı

Katılım bankacılığı, detaylarıyla anlatılan İslami finans prensiplerine dayalı ve bu prensiplerin ışığında oluşan yöntemlerle işleyen bir bankacılık modelidir. Dünyadaki faizsiz finans düşüncesi ve katılım bankacılığının ortaya çıkışı ve gelişim süreci, İslam finans prensiplerine dayanmaktadır. Dolayısıyla İslami finans ile katılım bankacılığı iç içe geçmiş girift bir yapıdır ve birbirinden ayrı değerlendirilmesi mümkün değildir. Değerleri açısından, katılım bankacılığı İslam hukukuna uygun olarak faizsiz finansman prensibini benimsemektedir çünkü İslam dini, faiz veya riba olarak bilinen bir finansal faaliyetin haram (İslami olarak yasak) olduğunu belirtir ve bu nedenle faizsiz finans kurumlarının ortaya çıkmasına yol açmıştır. Bu prensip, faizden

kaçınılması ve ekonomik faaliyetlerin adaletli, dürüst ve şeffaf bir şekilde yürütülmesini hedeflemektedir. Katılım bankaları, çalışmada detayları anlatılan yöntemlerle müşterilerine faizsiz kredi, kar paylaşımı, kira sertifikaları gibi alternatif finansman araçları sunmaktadır.

Dünyadaki faizsiz finans düşüncesi ve katılım bankacılığının gelişim süreci oldukça köklü bir geçmişe sahiptir. Katılım bankacılığının Türkiye'ye girişi, gelişimi ve süreçleri ancak diğer ülkelerin tecrübeleri ve etkileşimleriyle birlikte incelendiğinde anlamlı olacaktır. Doğuşuna baktığımızda aslında İslami finansın temelleri sağlam ve geçmişi köklü olmasına rağmen Müslüman ülkelerin teknolojik olarak gelişmişlikte geri sıralarda olması, sömürgeleştirilmesi, sömürge olmasa bile sorgusuz batılılaşma eğiliminde olması katılım bankacılığının temellerinin atılmasını oldukça geciktirmiştir. Özellikle batıda her şeyin en iyisinin yapıldığına olan inanç Müslüman ülkeleri en temel değerlerini unuttur hale getirmiştir zira dünya genelinde genel bir geç kalmışlık olsa da Türkiye olanaklar, teknoloji, bağımsızlık gibi konularda Körfez ülkelerinden çok daha iyi durumda olmasına rağmen Katılım Bankacılığında öncü olamadığı gibi İslami coğrafyada kurulan ilk konvansiyonel banka 1847'de İstanbul Bankası olarak Türkiye'de kurulmuştur.

İslami coğrafyaya bakıldığında ilk faizsiz kurum girişimleri 1940'larda toprak sahipleri ve esnaflara faizsiz fon sağlamak amacıyla Hindistan'da olmuş olsa da modern anlamda faizsiz bankacılık fikrinin 1955 yılında Muhammed Uzeyr ile ortaya çıktığı düşünülmektedir. Bu girişim toprak sahipleri ve esnaflara faizsiz fon sağlamak amacıyla kurulmuştur. Hindistan'ın ardından 1963 yılında Malezya'da hacca gitmek isteyen insanların maddi desteğe ihtiyaç duymaları üzerine faizsiz destek arayışı ortaya çıkmış ve hac fonu kurulmuştur. Bu girişimler katılım bankası sayılmasa da katılım bankacılığının temelini atan önemli adımlardır. İlk modern katılım bankası kabul edilen Mith Ghamr Tasarruf Bankası yine 1963 yılında, Mısır'da Ahmed Al-Najjar tarafından kurulmuştur. 1967 yılında Merkez bankasına devredilen Mith Ghamr Tasarruf Bankası yerine devlet tarafından faizsiz olarak işleyen Nasır Sosyalist Bankası kurulmuştur. 1960'a kadar olan zaman dilimi katılım bankacılığının fikren geliştiği zamanlarken; 1970'lerden sonra Suudi Arabistan, İran, Kuveyt, Birleşik Arap Emirlikleri ve diğer İslam ülkelerinde katılım bankacılığına yönelik faaliyetler hız kazanmıştır. Ayrıca bu ülkelerin dışındaki bazı ülkeler de mevzuat düzenlemeleriyle katılım bankalarının faaliyetlerini desteklemiş ve teşvik etmiştir. 1975 yılında Cidde merkezli İslam Kalkınma Bankası (Islamic Development Bank), İslam ülkeleri arasında iş birliğini teşvik etmek, İslam finans prensiplerine dayalı projeleri finanse etmek ve faizsiz finansı geliştirmek amacıyla kurulmuş olup İslami

finansın uluslararası platformdaki önemli bir temsilcisi olmuştur. Bu girişimin katılım bankacılığının küresel alanda büyümesine ve diğer ülkelerde benzer kurumların kurulmasına öncülük ettiği görülmektedir. 1980'lere gelindiğinde katılım bankaları ve İslami finans kuruluşları dünya genelinde artış göstermiş, faizsiz finansın temel ilkelerini uygulamak üzere özel finans kurumları ve katılım bankaları açılmıştır. 1983'te Bahreyn, katılım bankalarının faaliyetlerini düzenlemek için dünyanın ilk katılım bankacılığı mevzuatını uyguladı. Bu adım, diğer İslam ülkelerinin de katılım bankalarını düzenleyen yasal çerçeveler oluşturmaya ilham verdi. 2000'lerden itibaren katılım bankacılığı, küresel finansal sistemde daha fazla tanınmaya başladı. Birçok İslam ülkesi ve finansal merkez, katılım bankalarının kurulmasını desteklemek için yasal ve düzenleyici çerçeveler oluşturdu. Katılım bankaları, uluslararası finans kuruluşlarıyla iş birliği yaparak, küresel sermaye piyasalarında yer almaya başladı. Günümüzde, katılım bankaları birçok ülkede faaliyet göstermekte ve dünya çapında faizsiz finansın gelişimine katkıda bulunmaktadır.

Türkiye topraklarına bakıldığında ise her anlamda diğer İslami ülkelerden çok daha gelişmiş olsa da katılım bankacılığına geçişinin gecikmesinin önemli bir sebebi Osmanlıdaki faizsiz finansman ihtiyacının birçok farklı araçla karşılanıyor olmasıdır. Osmanlı İmparatorluğu'nda faiz, İslam hukukuna dayanan yasal düzenlemelerle yasaklanmıştı. İslam hukuku, faiz almanın ahlaki ve dini açıdan kabul edilemez olduğunu belirtiyordu. Faiz hassasiyeti nedeniyle Osmanlı İmparatorluğu'nda geleneksel İslami finans prensiplerine uygun olmayan faizli borçlanma yöntemleri yaygınlaşmadı. Bunun yerine, iç ve dış borçlanma ihtiyaçları için alternatif finansal araçlar arandı. Bunun üzerine 1863 yılında Osmanlı İmparatorluğu, Düyun-u Umumiye İdaresi'ni kurarak borçlarını yönetmek ve dış borç ödemelerini düzenlemek amacıyla Batılı devletlerden mali yardım aldı. Düyun-u Umumiye, Osmanlı'nın uluslararası borç ilişkilerinin merkezi bir kurumu oldu. 1888 yılında ise Ziraat Bankası'nı kurarak tarım sektörünü desteklemek için özel bir banka modelini benimsedi. Halkın ticari ve günlük hayatında oluşan finansman ihtiyacı ise vakıflar, ahilik ve lonca sistemi gibi araçlarla sağlanıyordu. Bu araçların detayları şu şekildedir:

- Vakıflar ve İnfak Sistemi: Osmanlı İmparatorluğu'nda vakıflar, toplumsal yardımlaşma ve dayanışma amacıyla faaliyet gösteren önemli kurumlar olarak faizsiz kredi sağlama rolünü üstlenmiştir. Vakıflar, hayırseverlerin bağışlarıyla oluşturulan fonlar aracılığıyla, ihtiyaç sahiplerine düşük veya faizsiz krediler vermiş ve toplumsal refahın artırılmasına katkıda

bulunmuştur. Ayrıca, infak sistemi aracılığıyla zenginlerin fakirlere doğrudan maddi destek sağlaması da faizsiz kredi ihtiyacının bir şekilde karşılanmasına yardımcı olmuştur.


- **İştirak Sistemi:** Osmanlı toplumunda, faizsiz kredi sağlama amacıyla "iştirak" sistemi kullanılmıştır. İştirak, bir grup kişinin bir projede ortaklık kurarak maddi kaynakları paylaşması anlamına gelir. Bu sistemde, bir grup insan bir işe veya ticari girişime birlikte yatırım yapar ve karı ortaklaşa paylaşır. Bu şekilde, faiz ödemedi ortak girişimlerde bulunarak finansal ihtiyaçlarını karşılayabilmişlerdir.
- **Esnaf Loncaları:** Osmanlı İmparatorluğu'nda esnaf loncaları, meslektaşları arasında dayanışmayı ve faizsiz kredi sağlamayı amaçlayan kurumsal yapılar olarak önemli bir rol oynamıştır. Esnaf loncaları, üyelerine faizsiz krediler vererek işlerini geliştirmelerine ve finansal ihtiyaçlarını karşılamalarına yardımcı olmuştur. Loncaların üyeleri arasında dayanışma ve karşılıklı yardım prensipleri, faizsiz kredi ihtiyacının giderilmesinde etkili olmuştur.
- **Ahilik ve Loncalar:** Ahilik, Osmanlı İmparatorluğu'nda faizsiz kredi sağlama amacıyla uygulanan geleneksel bir sistemdir. Ahilik, tüccarlar, zanaatkarlar ve esnaf arasında dayanışmayı teşvik eden bir kurum olarak faaliyet göstermiştir. Ahilik, üyelerine faizsiz krediler ve ticari destek sağlamış, girişimciliği teşvik etmiş ve toplumsal refahın artmasına katkıda bulunmuştur. Bu yöntemlerin yanı sıra, Osmanlı İmparatorluğu'nda bireysel yardımlaşma, sadaka ve sosyal dayanışma da faizsiz kredi ihtiyacının giderilmesinde önemli bir rol oynamıştır. Toplum içinde zenginlerin fakirlere karşılıksız yardım etmesi ve toplumun ihtiyaçlarına yönelik projelerin desteklenmesi, faizsiz kredi taleplerini karşılamada etkili olmuştur.

Türkiye'deki katılım bankacılığı sektörü, diğer ülkelerin tecrübeleriyle etkileşim içindedir. Özellikle Suudi Arabistan, Birleşik Arap Emirlikleri, Malezya ve Bahreyn gibi İslam ülkeleri, katılım bankacılığı konusunda gelişmiş ve tecrübe sahibi ülkeler olarak öne çıkmaktadır. Bu ülkelerdeki başarı hikayeleri, Türkiye'nin katılım bankacılığı sektörünün gelişiminde önemli bir etkiye sahiptir. Örneğin, Malezya'nın katılım bankacılığı konusundaki tecrübeleri, Türkiye'nin hükümet politikaları ve düzenlemelerinde örnek alınmıştır. Sonuç olarak, katılım bankacılığının Türkiye'ye girişi ve gelişimi, İslami finans prensiplerine dayalı bir bankacılık modelinin benimsenmesi ve uygulanmasını içermektedir. Bu süreçte diğer ülkelerin tecrübeleri, düzenleyici çerçeveler ve başarılı uygulamalar Türkiye'ye ilham kaynağı olmuştur. Türkiye'deki katılım bankacılığı sektörü, önemli bir büyüme potansiyeline sahiptir ve İslami finans değerlerine uygun bir finansal sistem oluşturma hedefine yönelmektedir.

Katılım bankacılığının Türkiye'ye girişi, 1980'li yıllarda başlamıştır. Bu dönemde Türkiye, ekonomik ve finansal reformlar gerçekleştirmeye başlamış ve bu süreçte İslami finans prensiplerini benimseyen bir bankacılık modeline olan talep artmıştır. Türkiye'de katılım bankacılığı, dünyadaki gelişmelere paralel biçimde 1983 yılında başlamıştır. Aynı yıl İslami bankacılığa başlayan Malezya, bu konuya özel bir kanun çıkarırken Türkiye'de bir Bakanlar Kurulu Kararnamesi ile katılım finans kuruluşların faaliyetlerine izin verilmiştir. Bu izinden hemen sonra Albaraka Türk, 1984 yılında kurularak Türkiye kurulan ilk katılım bankası olmuştur. Albaraka Türk'ün kurulmasının hemen ardından katılım bankacılığı gelişimi ivmelenmiş ve 1985 yılında ise daha sonra Faisal Finans Bankası olarak adlandırılan Faysal Finans kurulmuştur. Kuveyt Türk ise 1989 yılında Özel Finans Kurumu olarak faaliyetlerine başlamıştır. 1990'lı yıllara gelindiğinde ise Anadolu Finans ve İhlas Finans kurulmuştur. İhlas finans kuruluşundan sadece 6 yıl sonra büyük bir kriz yaşayarak TMSF'ye devredilmiştir. Katılım bankacılığı sektörünün gelişimi, 2000'li yıllardan itibaren ivme kazanmıştır. 2005 yılında Türkiye Finans Katılım Bankası; Anadolu Finans ile Faisal Finans Kurumu'nun güçlerini birleştirmesiyle %100 yerli sermayeli ilk özel finans kurumu olarak kurulmuştur. Bu dönemlerde bu bankaları İslami yani bir diğer deyiş ile faizsiz finans ilkelerine göre çalışıyor olsa da faizli bankalardan ayırıştırıcı bir isimleri bulunmamaktaydı. Bu durum halk arasında ayırım açısından tereddüte yol açmasının yanında faizsiz işleyen bankalar için de oldukça rahatsız ediciydi. Bunun üzerine faizle çalışan bankalar ile faizsiz çalışan bankaları birbirinden ayırmak için 2005 yılında tüm faizsiz finans kurumları 5411 sayılı Bankacılık Kanunu kapsamına alınmış ve "katılım bankası" olarak adlandırılmıştır. Faizsiz çalışan bankalar için katılım ifadesinin uygun görülmesinin sebebi müşterilerin gerek finansman kullanarak gerek varlığını bankaya yatırarak bankanın yaptığı tüm ticaretlerdeki ve yürüttüğü projelerdeki kara da zarara da ortak olması yani katılım sağlamış olmasıdır. Bu yönüyle katılım bankası müşterileri banka ile yaptığı her işlemde bankanın birer katılımcısı ve iş ortağı rolündedir. Bankanın kazancına ve kaybına ortak olması yönüyle riskini paylaşmaktadır. Yine 2005'te Özel Finans Kurumları kanunu ile birlikte katılım bankaları sadece bir isimle özelleştirilmemiş; aynı zamanda Türkiye'de katılım bankacılığının önündeki engelleri aşmak ve sektörün daha da büyümesini sağlamak amaçlanmıştır. Bu kanunla birlikte, katılım bankalarının yasal statüsü tanınmış ve düzenleyici bir çerçeve oluşturulmuştur. Ayrıca, katılım bankalarının faaliyetlerini daha etkin bir şekilde sürdürebilmeleri için Maliye Bakanlığı tarafından vergisel düzenlemeler yapılmıştır. Türkiye'de katılım bankacılığı sektörünün büyümesini desteklemek amacıyla birçok yenilik yapılmıştır. 2010 yılında "Katılım Bankalarının Yatırım Projelerinin Finansmanı

Hakkında Tebliğ" yayınlanmış ve katılım bankalarının yatırım projelerine finansman sağlama süreçleri düzenlenmiştir. Aynı yıl, Türkiye'nin ilk özel katılım bankası olan Kuveyt Türk'ün halka arzı gerçekleştirilmiştir. Bu halka arz, sektördeki büyümenin ve gelişmenin en önemli bir göstergelerinden biri olarak kabul edilmiştir. 2015'e kadar katılım bankaları sadece özel bankalardan oluşurken 2015 yılında devlet tarafından Bankacılık Düzenleme ve Denetleme Kurulunun denetimi ilk devlet katılım bankaları kurulmuştur. İlk olarak Ziraat Katılım Bankası kurulduktan sonra aynı yıl içinde Vakıf Katılım Bankası kurulup 2016 tarihinde faaliyete geçmiştir. Vakıf Katılım Bankası'nın sermayesinin neredeyse tamamı Vakıflar Genel Müdürlüğüne aitken küçük bir kısmı birkaç vakıfa aittir. Vakıf Katılım 2022 Faaliyet Raporuna göre güncel ortaklık yapısı aşağıdaki gibidir:

Tablo 2.2: Vakıf Katılım Ortaklık Yapısı



Ziraat Katılım ve Vakıf Katılım Bankasının ardından Emlak Katılım Bankası ise 2018 yılında kurulmuş olup 2019 yılında faaliyet izni almıştır.

Mevcutta Türkiye'de bu 6 katılım bankasına ek olarak şubesiz çalışma prensibi ile tüm işlemleri dijital bankacılıkla yürüten Hayat Katılım Bankası, T.O.M. Katılım Bankası ve Adabank adında 3 dijital katılım bankası bulunmaktadır. Katılım bankacılığının dijitale taşınması faizsiz bankacılığın gelişimi, zamana yenilmeyerek her bireye ulaşması açısından oldukça büyük bir öneme sahiptir.

Katılım bankaları dışında İslami finansın tüm araçları küresel finans endüstrisine kıyasla az olup temel olarak gelişmekte olan ülkelerde görünse de geniş kapsamlı ve kapsayıcı hedefiyle gelişmiş ülkelerde de merak uyandırmaktadır. Bölgeler arasında istikrarı barındırabilecek ek düzenlemeler ve standartlar gerektiği ve şeriatteki mevcut hükümler günümüzdeki karmaşık şirket yapıları ve dinamik iş ilişkileri için tam anlamıyla yeterli olmadığı için modern İslami finans kuruluşları ortaya çıkmıştır. Bu kuruluşlar kuran ve sünnet ile ilgili araştırmalar yapıp finans, ekonomi, hukuk, sosyoloji gibi alanlara da çalışarak karmaşık senaryolara İslama uygun çalışma şekilleri ve çözümler ararlar. Ekonomik kalkınmayı amaçlayarak kişi ve firmalara rehberlik görevi üstlenirler.

İslami finans kurumlarının son zamanlardaki büyümesi esneklik, istikrar ve müşteri memnuniyeti ile sağlanan gelişmelerdir. İslami finans sadece Müslüman çoğunluklu ülkelerde değil, aynı zamanda dünyanın diğer birçok yerinde uygulanmak istendiğinden dolayı her toplumun farklı gelenek ve kültüre sahip olduğu düşünülürse finansal düzenlemelerde temel ilkelerden sapmadan esnekliğe yer açmak gerektiğini gösteriyor. Bu nedenle, İslami finans standartlarını belirleyen kuruluşlar, standart ve politikalarını belirlerken Müslüman nüfusunun daha az olduğu ülkelerdeki durumu da göz ardı etmemelidir. Böyle bir ortamda yaşayan bireyler her ne kadar İslami finansı merak ediyor ve uygulamak istiyor olursa olsun tamamıyla katı olan İslami finansı benimsemesi mümkün olmayacak, kendi maddeci ekonomilerini sürdürmeye devam edeceklerdir. Faizli işlemlerin bir bir yok olması, adaletli ve dürüst ekonominin kurulması için esneklik oldukça önemlidir. - İslami finans kurumlar dışlayıcı olmaktan uzak durup, bütünleştirici ve evrensel olmaya özen gösterdiklerinde İslami finans standartlarını benimseme konusunda ülkelerin giderek artan bir şekilde iş birliği arayışı, İslami finansın diğer yargı alanlarına daha fazla nüfuz etmesi için elverişli bir ortam yaratacak dolayısıyla; İslami finans standartlarının diğer uluslararası standartlarla uyumlu hale getirilmesi, İslami finansın yabancı ülkelerde benimsenmesini kolaylaştıracaktır. Bu düzenlemelerin yapılmasını sağlamak için Türkiye Katılım Bankaları Birliği (TKBB) 1985 yılında kuruldu. TKBB'nin kuruluş süreci, Türkiye'deki katılım bankalarının ihtiyaçlarını karşılamak ve sektördeki ortak sorunları çözmek üzere bir araya gelmeleriyle başladı. Kuruluşundaki ana amaç ise katılım bankalarının Türkiye ekonomisine daha fazla katkı sağlamalarını teşvik etmek ve İslami finans prensiplerine dayalı olarak faaliyet gösteren bu kurumların sektördeki gelişmeleri takip etmelerini kolaylaştırmaktır.

TKBB nezdinde yapılan birçok iş olsa da ana faaliyetleri şu şekilde kategorize edilebilir:

Sektör Temsilciliği: TKBB, katılım bankalarını Türkiye ve uluslararası düzeyde temsil eder, böylece sektörün sesini duyurarak katılım bankacılığının tanıtılmasına ve gelişmesine katkı sağlar.

Eğitim ve Araştırma: TKBB, sektördeki personelin eğitimini teşvik eder ve katılım bankacılığı ile ilgili araştırmaları destekler. Bu, sektörün bilgi düzeyini artırmaya ve nitelikli personel yetiştirmeye yardımcı olur.

Sektörün Gelişimini Destekleme: TKBB, katılım bankalarının rekabetçi olmalarını ve büyümelerini teşvik etmek amacıyla sektörün gelişimini destekler. Bu, en iyi uygulamaların paylaşılması ve sektörün sürdürülebilir büyümesine katkıda bulunulması hedeflenir.

Politika ve Düzenlemeler: TKBB, katılım bankalarının yasal ve düzenleyici çerçeve içinde etkili bir şekilde faaliyet gösterebilmeleri için gerekli politika önerilerini sunar ve düzenlemelerle ilgili görüşlerini paylaşır.

İletişim ve Tanıtım: TKBB, katılım bankacılığını tanıtmak ve kamuoyuna açıklamak için iletişim çalışmaları yapar. Bu, katılım bankalarının bilinirliğini artırmaya yöneliktir.

TKBB, Türkiye'deki katılım bankalarının ortak çıkarlarını korumak, sektörün gelişimini teşvik etmek ve finansal istikrarı sağlamak için çalışır.

2.2.3. Fon Toplama Yöntemleri

Bireysel kişi ve kurumların finansman kaynaklarına ulaşması oldukça zor olduğundan dolayı tasarruf sahiplerinin ellerindeki sermayenin toplanıp ihtiyaç sahibi kişi ve şirketlere borç verilmesi geçmişten günümüze devam eden bir kalıptır ve bunun için aracı kurumlara ihtiyaç duyulmaktadır. (Hassan ve diğerleri, 2019) tam olarak bu duruma istinaden katılım bankalarını İslami değerleri dikkate alarak bu rolü yerine getiren ve faizsiz finans açısından çok önemli bir işlevi yerine getiren önemli yapılar olarak tanımlamaktadır. Bu kuruluşlar, bir yandan faiz kaygısı nedeniyle fonlarını ekonomiye kanalize edemeyen tasarruf sahiplerinin helal yollardan gelir elde etmelerini sağlarken, diğer yandan bu tasarrufları ekonomiye kanalize ederek toplumun ihtiyaç duyduğu fonları ulaştırmaktadır. Bu yapı doğru bir şekilde kurulup devletin desteğiyle işletildiği takdirde İslam ülkeleri ekonomilerinin gelişmesinde önemli rol oynamaktadır. Yıllardır potansiyeli yüksek pek çok şirket, faiz kaygısı nedeniyle yatırımlarını genişletememiş, çok küçük sermayeyle ancak ellerinden geldiğince ticaret yapabilmisti. Bu şirketler doğal kaynaklara ve nitelikli iş gücüne sahip olmalarına ve girişimcilik ruhu açısından


büyük bir potansiyele sahip olmalarına rağmen yıllardır beklenen atılımları yapamadılar. Katılım bankaları tam olarak bu sıkıntının çözümü olarak doğmuştur. (Hassan ve diğerleri, 2019)

Katılım bankaları Nakit Kredi kullandırmadığı için genel olarak ortaklık ve yatırım mantığı ile fon kullandırmaktadır. Fon kullandırma yöntemleri ile fon toplama yöntemleri katılım bankasının temel 2 yapı taşıdır ve bir dişlinin çarkları gibi birbirini döndürür. İkisinden birindeki aksaklık tüm banka sisteminin işleyişini etkiler. Toplanan fonlar bir havuzda biriktirilerek kullandırılan fonlar için kaynak sağlar. Kullandırılan fonlardan elde edilen karlar ise belirtilen oranlarda vade sonunda katılım fonuna yatırım yapan müşteriler ile paylaşılır. Eğer kullandırılan fonların müşteri tarafından geri ödemesi sekteye uğrar veya fonlanan projeler beklenen karı getirmez ise banka zarar eder. Katılım bankacılığı prensiplerince karın ortaklığı kadar zararın ortaklığı da esas olduğundan dolayı katılım hesabı müşterilerine yine en baştaki kar -zarar paylaşım oranına ve yatırılan paraya göre zarar yansıtılır. Hesabın hangi değerler cinsinden açılabilceği katılım bankaları açısından farklılık göstermektedir. Hem cari hem de katılım hesapları TL, döviz, Gümüş veya altın cinsinden olabilmektedir. TL dışındaki kıymetler hesaptan çekilirken genelde değerinin TL karşılığı TL olarak da alınmaktadır.

Cari hesaplar ve katılım hesapları olmak üzere 2 çeşit fon toplama aracı vardır. Bu araçlar detaylarıyla birlikte aşağıdaki gibidir.

2.2.3.1. Cari Hesap

Katılım bankasındaki cari hesap, müşterilere işlem yapma, para yatırma ve çekme, ödemeleri gerçekleştirme gibi finansal işlemler için kullanılan bir hesap türüdür. Cari hesaplar, katılım bankalarının müşterilerine sunduğu en yaygın hizmetlerden biridir. Bu hesaplar, geleneksel bankaların sunduğu mevduat hesaplarına benzerlik gösterir, ancak faiz veya riba içermeyen bir yapıya sahiptir. Katılım bankaları, İslam finans prensiplerine göre çalıştıkları için faizsiz finansal ürünler sunarlar. Cari hesaplar, müşterilerin günlük para yönetimi ihtiyaçlarını karşılamak için kullanılır. Bu hesaplar, müşterilerin nakit akışını takip etmelerine ve kolayca ödemeler yapmalarına olanak sağlar.



Şekil 2.1: Cari Hesap İşleyişi

Cari hesap müşteriler tarafından en sık kullanılan “klasik banka hesabı” olarak kullanılan hesap türüdür. Açılması için herhangi bir limit gerekliliği yoktur, kaba tabirle cüzdan olarak kullanılan hesap türüdür. Müşteriler hesaplarına yatırılan parayı hesabı kartlarına bağlayarak alışverişlerinde kullanabilir, eğer isterlerse Nakit olarak çekebilmektedirler. Herhangi bir getirisi olmaması ile birlikte ana para garantisi vardır. Yani hesaptaki para miktarını değiştiren tek şey Nakit akışlarıdır. Müşteri hesabında ne kadar para yatırırsa zamandan bağımsız parası hesabında statiktir. Cari hesaplar Bireysel müşteriler için açılabilirdiği gibi firmalar için de açılıp ortak sermayelerini bulundurdıkları kasa gibi kullanılabilir. İçindeki bakiye ise istenildiği zaman tamamıyla veya kısmi olarak çekilebilir. Katılım bankalarında cari hesaplar genellikle şu şekilde çalışır:

- Hesap Açma: Müşteriler, katılım bankasının şartlarını karşıladıklarında bir cari hesap açabilirler. Hesap açma süreci, kimlik doğrulama ve gerekli belgelerin sunulması gibi standart prosedürlere tabidir.
- Para Yatırma ve Çekme: Müşteriler, cari hesaplarına nakit para yatırabilir veya hesaptan para çekebilir. Katılım bankaları, genellikle banka şubeleri, ATM'ler, mobil uygulamalar ve çevrimiçi bankacılık gibi çeşitli kanallar aracılığıyla para yatırma ve çekme imkânı sunarlar.
- Ödeme İşlemleri: Cari hesaplar, müşterilerin faturaları ödemeleri, havale ve EFT yapmaları gibi çeşitli ödeme işlemlerini gerçekleştirmek için kullanılabilir. Katılım bankaları, elektronik bankacılık sistemleri aracılığıyla bu ödeme işlemlerini kolaylaştırır.
- Hesap Hareketleri ve Ekstreler: Müşteriler, cari hesaplarındaki para hareketlerini takip etmek ve hesap ekstrelerini incelemek için düzenli olarak banka tarafından sağlanan bilgilendirme mekanizmalarını kullanabilirler. Bu, hesap bakiyesi, işlem detayları ve hesap hareketleriyle ilgili bilgileri içerir.


Örneklerle açıklamak gerekirse, bir müşteri cari hesabına maaşını yatırabilir ve faturalarını bu hesaptan otomatik olarak ödeyebilir. Aynı zamanda, ticari bir müşteri cari hesabından alacaklılarına ödemeler yapabilir ve ticari işlemlerini bu hesap üzerinden gerçekleştirebilir. Bu yönleriyle bakıldığında aslında katılım bankalarındaki cari hesapla mevduat hesabının aynı işlevde olduğu düşünülebilir ancak; katılım bankalarındaki cari hesaplar ile konvansiyonel bankalardaki mevduat hesapları arasında birçok benzerlik bulunsa da tamamen aynı işlevde olmayıp iki hesap türü arasında ciddi farklılıklar bulunmaktadır. İlk olarak, benzerliklere bakacak olursak, her iki hesap türü de müşterilere finansal hizmetler sunmaktadır. Her iki hesap da bankacılık işlemlerinin temelini oluşturur ve müşterilere para yönetimi ve güvenli bir şekilde

fonlarını saklama imkânı sağlar. Hem cari hesaplar hem de mevduat hesapları, müşterilerin para yatırmasını, çekmesini ve elektronik ödemeler yapmasını mümkün kılar. Ayrıca, her iki hesap türü de bankalar tarafından düzenleyici otoriteler tarafından denetlenir ve müşteri fonları belirli bir seviyede korunur ancak; cari hesaplar ile mevduat hesapları arasında bazı önemli farklılıklar da bulunmaktadır. En belirgin farklılık, faiz ve kâr payı uygulamalarında ortaya çıkar. Katılım bankalarındaki cari hesaplar için faiz uygulanmazken, konvansiyonel bankalardaki mevduat hesaplarına faiz oranları belirlenir ve müşteri bu faiz oranı üzerinden kazanç elde eder. Cari hesaplar, İslami finans prensiplerine dayanır ve kâr payı dağıtılırken, mevduat hesapları konvansiyonel bankaların faiz temelinde çalışması nedeniyle faiz kazancı sağlar. Bunun yanı sıra, yatırım ve finansman yaklaşımları da farklılık gösterir. Katılım bankaları, cari hesaplardaki fonları helal yatırımlar ve ticari faaliyetlerle değerlendirir. Bu, müşterilerin paralarının İslami prensiplere uygun projelere yatırılmasını sağlar. Öte yandan, konvansiyonel bankalar, mevduat hesaplarındaki fonları ticari krediler, ipotekler veya diğer yatırım araçları aracılığıyla değerlendirir. Bu da daha geniş bir yatırım yelpazesi sunar, ancak bazı yatırımlar risk içerebilir. Son olarak, düzenlemelerde de farklılıklar görülür. Katılım bankaları, İslami finans prensiplerine uygun olarak faaliyet göstermek için özel düzenlemelere tabidir. Bu düzenlemeler, faizsiz finansmanın uygulanmasını sağlamak amacıyla tasarlanmıştır. Konvansiyonel bankalar ise genellikle merkez bankası ve diğer finansal düzenleyici kurumlar tarafından belirlenen genel finansal düzenlemelere tabidir. Sonuç olarak her iki hesap türü, farklı finansal prensiplere dayanır ve müşterilere farklı avantajlar ve seçenekler sunar. Bireysel tercihler, inançlar, değerler ve finansal hedefler, hangi banka türünün kişiye daha uygun olduğunu belirlemede önemli bir rol oynamaktadır.

2.2.3.2. Katılım Hesapları

Katılım bankalarındaki katılım hesabı, faizsiz bankacılık prensiplerine dayalı, kâr&zarar ortaklığı ilkesi ile bir hesap türüdür. Bu hesap, müşterilerin fonlarını faizsiz bir şekilde yönetmelerini ve kâr payı elde etmelerini sağlar. Katılım hesabı, müşterilerin bankaya emanet ettikleri fonlarının, helal yatırımlar ve ticari faaliyetler aracılığıyla değerlendirilmesini amaçlar. Bu hesap türü, İslami finans prensiplerine uygun olarak faizsiz finansman ve kâr payı ortaklığı esasına dayanır. Müşteri bankanın kâr&zararına ortak olur ve en başta belirtilen oranda kâr&zarar paylaşımı yapılır. Bu oran genellikle %5 müşteri %95 banka veya %10 müşteri %90 banka olmaktadır. Bu hesap türünde vade sonunda müşteriye kar ödenme sözü verilmediği gibi en başta yatırdığı anaparanın ödenmesi garantisi de yoktur çünkü banka kar ettiği gibi zarar da etmiş olabilir.

Katılım hesabının çalışma prensibi, bankanın müşterinin fonlarını etik ve İslami prensiplere uygun şekilde kullanmasıdır. Banka, bu fonları faizsiz finansman projelerine, ticari kredilere veya işletmelere yatırabilir. Müşteri, yatırımlardan elde edilen karın bir kısmını paylaşır. Kâr payı, belirli bir dönemde bankanın elde ettiği kârın, müşterinin hesaptaki payına göre dağıtılmasıyla hesaplanır. Bu şekilde, müşteriler faizsiz bir şekilde gelir elde ederler ve yatırımları İslami finans prensiplerine uygun olarak kullanılır. Toplanan fonların kullanılma yöntemi konvansiyonel bankalar ile katılım bankalarını birbirinden ayıran önemli noktalardan biridir. Faizsizlik ve ortaklık prensipleriyle katılım bankacılığı işleyiş bakımından konvansiyonel bankalarla ciddi farklılık göstermektedir. Ayrışan temel felsefenin ürünlere yansımaları katılım hesaplarını inceleyerek anlamak mümkündür. Konvansiyonel bankalarda en başta para yatırılırken müşteriye vade sonunda ödenecek tutar ve kar oranı bilgilendirmesi yapılır çünkü faiz oranı belirlidir, zaten ödenen para da arka planda Krediler ile kazanılan faizle arttırılmış paralardır. Yani tüm banka sistemi faiz ile işler. Oysa katılım bankacılığında fon sahiplerinden toplanan paraların tümü ile yatırım yapılmış, fabrikalar açılmış, üretime katkı sağlanmış veya ülke ekonomisine katkı sağlayacak herhangi bir ticari faaliyette bulunulmuştur. Bu yönüyle düşünüldüğünde katılım hesaplarında fon kullandırma yöntemlerinde de sıklıkla kullanılan mudarebe yöntemi uygulandığı görülecektir. Fon kullandırma aracı olarak kullanılırken banka bir proje ile gelen ve sermaye sıkıntısı çeken müşterinin projesini fonlayarak sermayedar müşteri ise projeyi ortaya koyarak emektardır. Oysa fon kullandırma yönteminde bu durumun tam tersi olarak müşteri elinde tuttuğu para ile bir girişimi olmaksızın yatırım yapmak istemektedir. Sermayesini katılım hesabına yatırarak banka tarafından fonlanacak projelere kaynak sağlar. Kısacası müşteri sermayedar, banka emektar konumundadır.



Şekil 2.2: Katılım Hesabı İşleyişi

Fon sahibi müşterilerin katılım hesabı müşterilere kar dağıtımını aşağıdaki sıra ile gerçekleştir:

1. Müşterilerden katılım hesabı açanlar banka ile belli bir kâr payı paylaşımı oranında mütabık kalarak sahip oldukları parayı yatırım amaçlı katılım hesabına yatırır. Böylelikle banka fon toplamış olur.

2. Toplanan fonlar banka tarafından belirlenen bir kâr oranı ile finansman olarak müşterilere kullandırılır. Finansman kullandırılması yatırım yapan kişinin parasının ticarete kullanılması demektir çünkü katılım bankaları her zaman ürüne dayalı finansman kullandırır.

3. Kullandırılan fonlar kar payları ile birlikte müşteri tarafından bankaya ödenir.

4. Toplanan karlardan her hesaba düşen kar miktarı hesaplanır. Bu hesapta katılım hesabına yatırılan para tutarı esas alınır. Yatırılan para ile hak edilen kar paraleldir.

5. Hesaplanan hak edişe göre kâr veya zararın katılma hesaplarına tahakkuk eder ve para bölüştürülerek vadesi dolan müşterilerin hesaplarına aktarılır.

6. Sürecin yeni baştan başlayabilmesi için hesabındaki parayı çekmeyip katılımı tutan müşteriler kâr dağıtım havuzuna yeniden dahil edilir.

Örneğin, bir müşteri katılım bankasında bir katılım hesabı açar ve 10.000 TL yatırır. Banka, bu fonu İslami finans prensiplerine uygun bir şekilde kullanır. Örneğin, bu fonları faizsiz bir proje veya işletmeye yatırabilir. Proje veya işletme kar elde ettiğinde, banka bu kârdan pay alır ve müşteriye kâr payı olarak dağıtır. Örneğin, banka bu dönemde elde ettiği kârın %10'unu müşteriye kâr payı olarak verir. Müşteri, hesabındaki 10.000 TL'ye ek olarak 1.000 TL kâr payı alır.

2.2.4. Fon Kullandırma Yöntemleri

Modern bankacılık öncesinde nakit ihtiyacı olan Müslümanlar, borçlanma sürecinde farklı çözümler kullanmışlardır. İslami finansın gelişimi ve katılım bankalarının ortaya çıkışı öncesinde, İslam'a uygun faizsiz finansman yöntemlerinin olmaması nedeniyle Müslümanlar, nakit ihtiyaçlarını karşılamak için bazı alternatif yollar bulmuşlardır. İhtiyaç sahipleri arasında yardımlaşma Müslüman topluluklarda, nakit ihtiyacı olan bireyler, aile, akraba, komşular ve toplumun diğer üyeleri arasında temel değer olup insanlar faizsiz çalışan bankaların olmadığı dönemlerde çoğunlukla yardımlaşma ve dayanışma prensiplerine dayalı olarak destek almışlardır. Bu, zekât, sadaka veya karz-ı hasen gibi yardım ve borç verme yöntemlerini içermiştir. Tüccarlar ve tacirlere bakıldığında ise ticaretin yaygın olduğu dönemlerde, Müslümanlar nakit ihtiyaçlarını ticaret yoluyla karşılamışlardır. Tüccarlar ve tacirler, ticaret

işlemleri sırasında borç verme, birinin malını ötekinin borcuna karşılık satın alma gibi faizsiz, ticarete dayalı nakit akıllı yöntemlerini kullanmışlardır. Bu şekilde, nakit ihtiyacı olan bireyler, ticari faaliyetleri ve işletmeleri için ticari krediler veya ticari ortaklıklar aracılığıyla finansman elde etmişlerdir. Bu dönemde ayrıca resmi olmasa da borç verme kurumları bulunmaktaydı. Bazı bölgelerde, nakit ihtiyacı olan Müslümanlar için borç verme kurumları veya dernekleri Müslümanlara faizsiz olarak borç verme hizmeti sunarak nakit ihtiyaçlarını karşılamaya çalışmışlardır. Bu kurumlar, topluluk içindeki birikimlerden oluşan fonları kullanarak borç verme faaliyetlerini yürütmüşlerdir. Bu çözümler, modern bankacılık öncesinde nakit ihtiyacı olan Müslümanların borçlanma sürecinde kullanılan yöntemlerdir. Ancak, bu yöntemlerde bazı sınırlamalar ve riskler bulunmaktaydı. Örneğin, yardımlaşma ve dayanışma prensipleri toplumun dayanışma seviyesine ve bireylerin kaynaklara erişimine bağlıydı. Ticaret ve ticari kredi yöntemleri ise genellikle ticaret yapabilen ve güvenilirliği kanıtlanmış kişilere odaklanmaktaydı.

Modern dönemde ise katılım bankaları ve İslami finans kurumları, nakit ihtiyacı olan Müslümanlara faizsiz finansman imkânı sunarak bu soruna çözüm getirmişlerdir. Bu kurumlar, faizsiz finansman prensiplerine dayalı olarak çeşitli fon kullandırma yöntemleri kullanarak Müslüman bireylerin ve işletmelerin nakit ihtiyaçlarını karşılamaktadır. Katılım bankacılığında toplanan fonlar İslami esaslara ve Türk hukuk sistemine uygun şekilde dağıtılır. Faizsizlik, risk ortaklığı, adalet gibi ilkelere fon kullandırılırken de dikkat edilir. Bankacılık kanununun Bankaların Kredi İşlemlerine İlişkin Yönetmeliği'ne göre kurumsal finansman desteği, katılım bankası ile fon kullanacak kişi arasında akdedilecek sözleşme dahilinde, işletmenin işletmenin ihtiyaç duyduğu her türlü emtia, menkul kıymet, gayrimenkul, hak ve hizmet bedelinin satıcıya ödenmesi koşuluyla işletmenin borçlandırılması işlemidir. Bireysel finansman desteği ise, bireysel ihtiyaçlar için gerçek kişi alıcıların doğrudan satıcılardan aldıkları mal veya hizmet bedelinin katılım bankası tarafından satıcıya ödenmesi koşulu ile alıcının borçlandırılması olarak tanımlanmaktadır. (5411 sayılı bankacılık kanunu, bankaların kredi işlemlerine ilişkin yönetmelik, 19. madde, 2. fıkrası)

İslam ekonomisi ve katılım bankacılığı konularından bahsederken İslam hukuku, Şariat ve hadislerle sıklıkla atıfta bulunulur. Bu sistem, özellikle faizden uzak durarak kar ve zararın paylaşılmasını (mudaraba ve muşaraka) desteklemeyi ve belirli iş türlerine yatırım yapmayı yasaklamayı içerir. Ayrıca kumar (maisir) yoluyla yapılan spekülasyondan ziyade gerçek yatırıma yönlendirme yapmaktadır ve genellikle aşırı risk ve belirsizlik İslami ilkelerle bağdaşmaz olarak kabul edilir.

İslami finansın en çok uygulanma eğiliminde olduğu ülkelere bakıldığında bu ülkelerin Müslüman çoğunluklu gelişmekte olan ülkeler olduğu görülmektedir. Bu durum İslam ekonomisinin bir uygulama kanalı olan katılım bankacılığının önünde uzun bir gelişim yolu olduğunu göstermektedir. Sukuk, finansmanlar, yatırım fonları gibi çeşitli ürünler bulunsa da müşterinin ihtiyacı daha net anlaşılıp ürünler geliştirilmeye devam edilmelidir.

Geleneksel ekonomide arz ile talep dengesindeki en önemli araçlardan biri faiz olarak görülmektedir. Katılım bankacılığında ise en önemli prensip faizsiz çalışmak olduğundan arz ile talep arasındaki dengenin nasıl sağlandığı akıllarda soru işareti oluşturabilir. Cevabı ise basittir: aslında kullandırılan fon müşterinin ihtiyacı olan ürünün satın alınıp müşteriye kâr payının eklenerek satılmasıdır. Faizin fiili karşılığı paradan para kazanmakken banka müşterinin ihtiyacı olan ürünü onun yerine alarak ticaret yapar ve ticarete kâr payı eklemek her tüccarın hakkıdır. Böylelikle kazanç elde ederken müşterisinin de ihtiyacı giderilmiş olur.

Katılım bankalarını konvansiyonel bankalardan ayrıldığı en önemli davranışlardan biri fon kullandırma şekilleridir. Konvansiyonel bankalarda borç verme mantığı işlerken katılım bankacılığında ticaret mantığı işler. Örnekle açıklamak gerekirse bir kişi herhangi bir konvansiyonel bankaya gidip bir araba alacağını ve 10000 TL'ye ihtiyacı olduğunu söylerse banka toplamda %20 faizle 10 aydan kredi verebileceğini belirtir. Kredi sözleşmesi imzalanır. 12000 TL müşteriye anında tek parça olarak verilir. Müşteri ödemeyi satıcıya yaparak kendisi bankaya borçlanır ve 12000 TL'yi ayda 1200 TL olarak bankaya öder. Banka istediği durumda verdiği krediyi geri isteyebilir çünkü kredide borç mantığı vardır ve banka ne zaman isterse verdiği borcu tahsil edebilir. Aynı senaryoyu müşterinin katılım bankası tercih ettiğini varsayarak düşünürsek; müşteri bankaya gidip durumu anlatır. Eğer satıcı ile alıcı arasında herhangi bir sözleşme imzalanmamış ise süreç başlayabilir. Burada müşteri ile satıcı arasında sözleşme imzalanmaması ticaretin ilk olarak satıcı-banka daha sonra banka-müşteri arasında gerçekleşeceği için oldukça önemlidir. Banka 10000 TL'ye aracı satın alır. Araç artık bankanıdır. Müşteriyle imzalanan alım-satım sözleşmesinin imzalanmasının ardından %20 kâr payı ekleyerek müşteriye 12000 TL'den 10 ay vade ile kiralar. Müşteri her ay 1200 TL bankaya taksitini öder. Ödenen son taksit ile birlikte banka müşteriye aracı satmış olur. Konvansiyonel bankalarda olduğu gibi sözleşme tek taraflı fesh edilemez çünkü imzalanan kredi sözleşmesi değil alış&satış'ın olduğu ticari bir sözleşmedir. Sistem de tamamen ticaret mantığı ile işlediği için eğer ortada bir mal veya hizmet yoksa katılım bankası fon kullandıramaz. Kısacası müşterinin ihtiyacı olan mal onun yerine satın alınarak, üstüne kar eklenip müşteriye vadeli satılır.

İslami piyasalar, fon sağlayıcılarını ve kullanıcılarını çeşitli şekillerde tatmin etmek için satış, ticaret ve finansman gibi farklı araçlar sunar. Bunu yaparken kullandığı temel fon kullandırma yöntemleri şu şekildedir: peşin alıp vadeli satış (murabaha), kar paylaşımı (mudarebe), leasing (icare), ortaklık (müşareke) ve vadeli satış (selem), uzmanlaşmış vadeli satış (istisna) ve sukuk. Bu araçlar, çok çeşitli daha karmaşık finansal araçların geliştirilmesi için temel yapı taşları olarak hizmet eder ve İslami finans piyasalarında finansal yenilik ve genişleme için büyük bir potansiyel olarak görülür.

2.2.4.1. Murabaha


Murabaha, kelime olarak Arapçada kar ve kazanç anlamındaki “ribh” kelimesinden gelmektedir. Murabaha sistemi mantık olarak net ve sabit olmakla birlikte işleyiş şekilleri kurumlar arasında değişebilmektedir. Bazı katılım bankalarında nakit finansman kullandırımı üst yönetim ve bilirkişilerle yapılan tartışmalar sonucunda doğru olmadığına kanaat getirilmiş ve İslami hassasiyet gereği yapılmamasına karar verilmiş; bazı katılım bankalarında ise müşteri finansman başvurusunda bulunduğu arka tarafta müşteri adına platin alım satımı yaparak bir ticaret gerçekleştirip müşteriye bu alışveriş sonucunda elde edilen para nakit olarak verilebilmektedir. Bu tamamen bankanın tutumuyla alakalıdır.

Murabahayı kısaca bir malı veya hizmeti üzerine kar ekleyerek satmak olarak tanımlamak mümkündür. Ticarete vadeli satış müşterinin ödemesi için kolaylık sağlamaktadır ancak satıcı parasını peşin almak istiyor ve alıcı ürüne ihtiyacı olmasına rağmen ürünün karşılığı tutara tastamam sahip olmayabilir. Bu gibi durumlarda araya banka girmektedir. Konvansiyonel bankalarda banka müşterisine ihtiyacı olan ürünü alması için nakit kredi verir. Bu nakit müşterinin talep ettiği tutar kadardır. Katılım bankasında ise banka murabaha ile ürünü müşteri yerine satın alır yani ve karını ekleyerek müşteriye vadeli satar. Böylelikle müşteri vade imkanından faydalanmış, satıcı ürünü peşin satmış ve banka kar sağlamış olur. Aynı zamanda her şey kayıt altına alınıp resmi makamlara gerekli bildirimler eksiksiz yapıldığı için katılım bankacılığı sistemi devlete kayıt dışı ekonomiyle mücadelesinde büyük bir katkı sağlamış olmaktadır. (Özsoy, 2012)

İslami finansın genel metodolojisini kavrayabilmek için murabahanın uygulanma şeklini kavramak, geçmişini öğrenmek oldukça önemlidir, zira murabaha İslami finansın ana araçlarından. 1980'ler döneminde başında, Körfez'deki ülkelerde ciddi bir petrol satışı vardı ve bu petrolün dolar karşılığında satılıyordu. Bu bölgedeki İslami hassasiyeti bulunan bankalarda ciddi bir petrol satışıyla elde edilen dolar yani, petrodolar yığılması mevcuttu. Bu sırada Latin Amerika'da ciddi bir kriz olduğundan dolayı da batılı şirketlerin kredi alma


yönelimi Körfez ülkelerine kaymıştı. Bu yönelim murabahanın uygulanması için İslami bankaların en büyük şansı olarak tarihe geçmiştir. İslami bankalar bu dönemde verdikleri anaparayı geri öderken anaparayı faizden ayırmak için batılı şirketlere mülk sattılar. Bu şekilde sadece onlara sadece faizsiz ticaret yapılabileceğini öğretmekle kalmayıp kendi ekonomilerini de kalkındırdılar.

Murabahanın uygulanma aşamaları aşağıdaki gibidir:



Şekil 2.3: Murabaha Uygulanma Aşamaları

Müşteriye verilen vekalet formu, ürünün müşteri tarafından banka adına alınacağı ve müşterinin ürünün seçilmesi, taşınması gibi ürüne ait tüm sorumluluklarla mükellef olduğu ile ilgili mevzuatsal bilgilendirme metni içerir. Bunun dışında ürün, müşteri, satıcı bilgileri ve güncel tarih de bulunur, müşteriye hitaben yazılır. Buna karşılık aynı işlevi gören sipariş formu firmaya hitaben yazılır, isminden de anlaşılacağı üzere bir sipariş için yazılmıştır. Özetle banka olarak detayları belirtilen ürünün satın alındığı, faturası ile birlikte müşteriye teslim edilmesi gerektiği yazmaktadır. Sipariş formuna satıcıdan alınan proforma fatura da eklenebilir. Her iki belgede de bankanın imzası bulunmaktadır.



Şekil 2.3 (devam): Murabaha Uygulanma Aşamaları

Murabaha yapılırken işlemin yurt içinde yapılma zorunluluğu yoktur. Satın alınmak istenen ürün yurt dışında olsa da işlem yapmak mümkündür. Hatta ödemelerin TL ile yapılması gibi bir kural da bulunmamaktadır. Dolar, Euro vb. Herhangi bir döviz kullanılarak ödeme yapmak mümkündür. Bu gibi durumlarda murabaha yapılırken uygun kar oranının belirlenmesi oldukça önemlidir. Bu oranın hesaplanmasındaki en önemli etken bankanın ne kadar kar etmeyi amaçladığıdır. Olması gerekenden daha düşük kar oranı belirlendiği takdirde katılım hesaplarına para yatıran müşterilere dağıtılan kar oranları da düşecektir çünkü müşterilerin

katılım hesaplarından elde ettikleri kar bankanın yaptığı ticaretten elde ettiği karın belirlenen bir kısmıdır. Dolayısıyla katılım hesabı kullanan müşterilerde tatminsizlik ve memnuniyetsizlik oluşacaktır. Olması gerekenin üstünde belirlenen kar oranı ise müşterinin rakip bankaları tercih etmesi ile sonuçlanabilir. Sonuç olarak bu hassas oranın optimum olması banka açısından oldukça önemlidir.¹

Murabaha sırasında yapılan hesaplamaların mantığı basit, formülleri aşağıdaki gibidir;

Bankanın Karı= Ürün Bedeli* Kar Oranı (2.1)

Fon Bedeli= Ürün Bedeli + Bankanın Karı + Resmi Masraflar

2.2.4.2. Mudarebe


Mudarebeyi en yalın haliyle emek ve sermaye ortaklığı olarak tanımlamak mümkündür. Aslında çok eski zamanlardan beri, toplumun birçok alanında tam olarak farkında olunmadan mudarebeye başvurulmaktadır. Bu ortaklıkta bir tarafın parası varken emek verebilecek durumda değil veya bir fikri yoktur. Öteki tarafın ise ortaklığa konu olan durum ile ilgili bilgisi var, emek verebilecek durumda ancak sermayesi yoktur. İşte böyle durumlarda bu 2 taraf bir araya gelir. Biri para öteki emeğini ortaya koyarak bir ortaklığa giderler. Sermaye ortaya koyan kişiye Rabbülmal denirken emek veren kişiye Amil veya mudarib denir. Karın nasıl paylaşılacağı da taraflar arasında en başta kararlaştırılır. Zarar edilmesi durumunda zararın tamamı sermaye sağlayan tarafa yansır zira emek ortaya koyan tarafın zararı da boşa giden emekleridir. Senaryonun katılım bankacılığına uyarlanmış halini irdelenecek olursak sermaye sıkıntısı yaşayan müşteri projesi ile bankaya başvurur. Banka gerekli incelemeleri yapıp uygun görürse bu projeyi fonlar. Proje sonunda elde edilen kar anlaşma aşamasında belirtilen orana göre paylaşılır. Müşteri kendi payını alır, banka da kendi hissesine düşen karı havuzunda biriktirir. Daha sonra yatırımcılara vadeleri dolduğunda yine onlarla da anlaşma aşamasında belirttiği oranda toplanan karlardan dağıtır. Aksi düşünüldüğünde, yani proje hedeflenen başarıya ulaşmayıp kar elde edilemezse banka finansal zararı tamamıyla üstlenir. Havuza para eklenmez, tablolara zarar yazar. Bu yönüyle düşünüldüğünde mudarebe banka için riski yüksek bir üründür. Fonlanacak projeler dikkatle seçilmelidir. Ayrıca projenin yürütülmesi aşamasında da her adım şeffaflıkla atılmalı ve banka tüm süreci dikkatle takip etmelidir. Projenin Yönetimi tamamıyla emek vermekten sorumlu olan girişimciye (mudarip) aittir. Sermayedar (rabbül mal)

¹ Müşteriden alınan masraflara BDDK tarafından kısıtlanmıştır. Bu mevzuatsal yaptırıma göre müşteriden alınan resmi masraflar en fazla ürün bedelinin %0,5'i kadar olmalıdır. Türkiye'de tüm bankalar bu kurala uymak zorundadır.

projenin yönetimine de işleyişine de karışamaz. Firma da her aksiyonda hesap verebilir durumda olmaya özen göstermelidir. Murabahanın en sağlıklı olduğu senaryo katılım bankasının malı alıp mülkiyetine sahip olup daha sonra müşteriye satmasıdır ancak Türkiye’de mülkiyet resmi olarak direkt müşteriye geçmektedir. Banka müşteriden aldığı vekaletle işlem yapar. İslam’da vekaletin oldukça önemli olmasından dolayı bu şekilde yapılan işlemler mülkiyetin 2 kere değişmesinin yerine geçmektedir. Bu da kimi bilir kişilere göre murabahanın tam olarak işlemesine gölge olan, şaibe düşüren bir durumdur.

2.2.4.3. Müşareke

Müşareke, kâr zarar ortaklığı prensibince yapılan ortaklık türlerinden biridir. Kelime anlamı olarak da Arapça ’da ortaklık demektir. Bir yatırıma her iki tarafın da sermaye sağlamasıyla gerçekleşir. Bir ortaklığı müşareke kapsamında değerlendirmek için tarafların tamamının fon sağlaması şart olsa da emek sağlama şartı aranmaz. Zarar paylaşım oranı her bankada aynı şekilde hesaplanmaktadır. Her bir tarafın katkı sunduğu sermayenin toplam sermayeye bölünmesiyle hesaplanır. Bir diğer deyişle kar-zarar ortaklığı prensibince zarar ortaya konulan sermaye ile orantılı olarak paylaştırılır. Kar paylaşımı ise sermaye miktarı ile bağlantılı olmak zorunda değildir, zira işin içinde bir tarafın sağladığı emek de vardır. Kar paylaşım oranı ortaklar arasında ortaklık kurulurken herkesin rızasına uyarak belirlenir. Tarafların sermayeleri aynı olduğu halde kar payları farklı olabilir. Benzer şekilde sermayeler farklıyken kar dağılımı eşit yapılabilir. Bu durumun sebebi ortaklığa katılan bir tarafın sektörde aranan iş bilir kişi olması veya daha fazla emek vermesi olabilir.



Şekil 2.4: Müşareke'nin Genel İşleyişi

Müşarekede her zaman projeyi yöneten proje sahibi olmayabilir. Sadece sermayesi ile katılan taraf da proje yöneticisi olarak görev yapabilir. Bu durumda yöneten taraf aldığı kâr payında artış isteyebilir ancak hem kâr payı alıp hem de yönetim ücreti alması faizsiz bankacılık prensiplerince doğru değildir. Eğer her iki taraf da meşguliyetler veya başka bir sebeple projenin yönetimini üstlenmezlerse sadece proje Yönetimi için üçüncü bir taraf ile anlaşılabilir. Proje yöneticisine ücret olarak elde edilen kardan belli bir oran verilebileceği gibi sabit ücret de verilebilir. Eğer kardan oran verilirse esasen burada murabaha yapılmış olur çünkü yönetici projeye sadece emek sağlayan taraf olarak dahil edilmiş olur ve kar-zarar ortaklığı prensibi işler. Diğer iki taraf ise sermayedar konumundadır. Bu yüzden eğer proje kar etmezse proje yöneticisi ücret almaz. Projenin zarara uğraması durumunda kendi payına düşen zararı boşa giden emeğidir. İkinci senaryodaki gibi proje yöneticisi projenin akıbeti her ne olursa olsun sabit bir ücretle çalışıyorsa burada ücretli vekalet yönteminin uygulandığı söylenebilir. Kar zarar ortaklığı yoktur. Proje yöneticisinin maaşı projenin gideri olarak kaydedilerek kardan düşülür. Daha sonra elde kalan kar ortaklar arasında belirlenen orana göre paylaşılır. Müşarekenin katılım bankacılığındaki işleyişi de bu şekilde gerçekleşir. Projesi ile birlikte bir miktar sermayesi olan müşteri bankaya başvurur. Banka gerekli fonu sağlar ve ortaklık gerçekleşir. Projenin sonunda kar elde edilirse bu kar sözleşmede belirtilen oranda paylaşılır; ancak projenin zarar etmesi halinde ortaya konan sermaye oranında zarar paylaşılır. Bazı durumlar müşteriler kar ettikçe Finansal durumu güçlendirir ve bankanın proje hissesinden parçalar satın alır. Belli aralıklarla aldıkları hisse sonucunda kendi hisseleri gün be gün artar ve sonunda projenin tek sahibi olurlar. Ortaklığın bitmesiyle iş birliği de bitmiş olur. Bu senaryo azalan müşareke olarak adlandırılır.

2.2.4.4. *Selem*

Selemde diğer fon kullandırma yöntemlerinin aksine önce mal teslimi sonra malın ödemesi esası vardır. İslam'ın ilk dönemlerinden beri sıklıkla kullanılmaktadır. Özellikle tarım sektörü en temel kullanım alanıdır. Çiftçiler hasat zamanı elde edecekleri ürünlerini daha ekmeden satarak bu parayla tohum alırlar. Bu işleyiş tam bir selem mantığı ile çalışır. Günümüzdeki aşamaları şu şekildedir:

- İleride elde edeceği ürüne hazırlık aşamasında olan örneğin ekin ekecek ama tohum, gübre, makine gibi ihtiyaçları bulunan çiftçi katılım bankasına başvurur.
- Fiyatta anlaşılır ve gerekli sözleşmeler imzalanır. Böylelikle katılım bankası daha ekilmemiş ürünü müşteriden satın alır. Satıcıya ödeme peşin yapılır. Böylelikle piyasaya

likidite girmiş olur. Bir yandan tohum satan adam peşin ödeme almış olurken çiftçi faizsiz bir şekilde tohuma ulaşmış olur. Ekonomi canlanır.

- İhtiyacı olan ürünü satın alarak teslimini müşterinin adresine yapar. Örneğin ihtiyaç tohum ise tohumu satıcıdan satın alır. Mülkiyeti kendisindedir ancak teslimi müşterinin adresine yaptırır. Bu aşamada satıcıyla detaylı bir anlaşma yapılır. Tohumun cinsi, miktarı, özellikleri net bir şekilde belirlenir. Bu yüzden kıymeti kişiden kişiye göre değişen ürünlerde selem uygulanamaz. Herkesçe Kabul gören ve kıymeti ölçülebilen ürünler selem için uygundur.
- Mal üretildikten sonra anlaşılan değeri bankaya ödenir. Riski en aza indirmek için özellikle bir üretim alanı ile kısıtlama yapılmaz. Örneğin bankaya 1 ton buğday sözü verilir. X tarlasındaki 1 ton buğday denmez çünkü X tarlasında türlü aksilikler çıkabilir ve bu geri ödemenin mazereti değildir.

2.2.4.5. İstisna

İşleyiş bakımından seleme oldukça benzeyen istisnada da selemde olduğu gibi mal ele geçmeden önce ödemesi yapılır. İstisnayı selemde ayıran en önemli özellik selemde ürünün standart olması şartı varken istisnada ürünün benzersiz olma şartı olmasıdır. Tasarım bir ayakkabı, çanta veya özel olarak yaptırılan bir dolap istisnaya konu olan ürünlerden olabilir. Ürünün fabrikasyon olmaması, seri üretim ile üretilmemesi, tamamıyla aynısından bir tane daha bulunmaması gerekmektedir. Türkiye’de inşaat sektörü istisnanın en sık kullanıldığı sektördür. İnsanların çanta için finansmana ihtiyaç duymaması ancak inşaat sektörü fiyatların yüksekliği nedeniyle tercih edilmesi son derece makul bir sebeptir. Bunun yanında henüz bina henüz yapılmadan proje üzerinden fiyatta pazarlık ile ev sahibi olabilmek de müşteri için ayrıca bir avantajdır.

İstisnayı selemde ayıran bir diğer fark Sözleşme aşamasında ödemenin yapılmasının şart olmamasıdır. Selemde ödeme peşin olarak yapılması gerekliken istisnada deme peşin yapılabileceği gibi ürün teslim edilmeden önce herhangi bir zamanda da yapılabilir.

Katılım bankaları selem uygularken hem müşterisiyle hem de müşterisinden bağımsız bir şekilde satıcı ile sözleşme imzalar. Satıcı ürünü üretmese bile satıcıya o ürünü temin etmek sözleşmelerin bağımsız olmasının getirdiği temel bir sorumluluktur. Müşterinin özgün ürün satın alacağı satıcı ile herhangi bir yazılı ön sözleşme yapmadan bankaya başvurması ile birlikte selem süreci başlar. Katılım bankası müşteri ile sözleşme yapar. Ardından Satıcı ile görüşür. Müşterinin arzu ettiği ürün özellikleri, teslim tarihi gibi detayları belirledikten sonra satıcıya ürünü sipariş verir. Zorunluluğu bulunmasa da ödemeyi genellikle peşin olarak yapar. Mal

üretildikten sonra müşteriye teslimi gerçekleştirilir ve müşteri belirtilen vadede vade farkıyla ödemeyi bankasına yapar.

2.2.4.6. Sukuk

Konvansiyonel bankalardaki finansal sertifikaların katılım bankalarındaki benzeri olan sukuk terim olarak Arapçadaki sertifika anlamına gelen saqq kökünden gelmektedir. Bu kelimenin çoğulu olan sukuk ise sertifikalar demektir. En basit haliyle varlığa dayalı menkul kıymet olarak tanımlamak mümkündür. Özellikle tahvil işleyiş bakımından sukuka benzemektedir. İkisini birbirinden ayıran temel fark ise sukukun faizsiz bankacılık prensipleri gereği muhakkak bir mala dayanıyor olmasıdır. Bu yüzden bazı taraflar sukuku faizsiz tahvil olarak yorumlamaktadır. Mehmet Odabaşı'nın tanımına göre ise sukuk, eşit değerlerde ihracı gerçekleştirilen, mal, hizmet veya faydaya dayanan ve bunlar üzerinde mülkiyet hakkı ifade eden sertifikalardır.

Dünyadaki sukuk ihraçlarına bakıldığında özellikle İslami hassasiyeti olan Malezya, Endonezya gibi Körfez ülkelerindeki sermaye piyasalarında kullanılmaktadır. İlk sukuk ihracının 1990'lı yıllarda Malezya'da ortaya çıkmasının ardından 2001 yılında Bahreyn hükümeti ilk Kurumsal sukuk ihracını piyasaya sunmuştur. sukuk piyasası bugün oldukça önemli bir faizsiz fon kullanma aracıdır. Günümüzde ise piyasanın önde gelenleri sırasıyla Malezya, Suudi Arabistan ve Endonezya gelmektedir. Türkiye'nin pazardaki payı küçük gibi görünse de geçmiş yıllara bakıldığında kendi içinde büyümesi oldukça hızlı olduğu, bundan sonra da ciddi bir büyüme potansiyelinin olduğu görülmektedir. Bu durum Türkiye'nin 2010 yılında Kuveyt Türk Katılım Bankasının ilk sukuk ihracını gerçekleştirmesiyle pazarda yerini almaya başlamasıyla açıklanabilir.

2011 yılındaki vergisel istisnaların ardından 2012 yılında Kira Sertifikaları Tebliği kanun düzeyinde düzenlendi. Ardından 2013 yılında Sermaye Piyasası Kurulu Malezya ve Ortadoğu'daki sukuk yapılarını harmanlayıp Türkiye'ye uygun hale getirdi. Böylelikle 5 farklı sukuk modelinin önü açıldı. 2016 yılına gelindiğinde ise özel şirketlerin sukuk ihracındaki tüm vergiler kaldırıldı. Bu düzenleme ile sukuk şirketlerin fon ihtiyaçlarında faizli araçlar yerine başvurabilecekleri çok parlak bir seçenek halini aldı. Enerji, telekomünikasyon gibi birçok sektörden şirket özel sektör sukuku ihraç etmeye başladı. Günümüze kadar hem katılım bankalarının hem Hazine Müsteşarlığının katkılarıyla sukuk sistemi gelişmeye devam etmektedir.

2.2.4.7. Murabaha Sukuk

Murabaha sukuk, murabaha sözleşmesine bağlı olarak ortak sahipleri olan mülklerin sabit getiri oranı hakkı sağladığı menkul kıymetlerdir. (Pireh, 2008)

Murabaha sukuk, İslami finans prensiplerine uygun olarak çıkarılan bir finansal enstrümandır. Sukuk, İslami tahvil veya borç senedi olarak da adlandırılır ve İslam'a uygun finansman ihtiyaçlarını karşılamak için kullanılır. Murabaha sukuk, özellikle varlık temelli finansman sağlamak amacıyla geliştirilmiştir ve temel olarak murabaha finansman yöntemine dayanır. Murabaha, bir malın banka tarafından satın alınması ve ardından müşteriye kâr payı eklenerek müşteriye satılmasıdır. Bu yöntem, katılım bankalarının müşterilere mal veya hizmet satın almak için finansman sağlamak amacıyla kullandığı bir yöntemdir. Murabaha sukuk ise Murabaha işlemiyle elde edilen alacakların belirli bir yapıda ihraç edilmesini sağlar.

Murabaha sukuk'un ortaya çıkışı, İslami finansın gelişimi ve katılım bankalarının ihtiyaçlarını karşılamak için yeni finansal enstrümanlar geliştirmesiyle ilişkilidir. Sukuk piyasası, İslami finans kurumlarının faizsiz finansman ihtiyaçlarını karşılamak için gelişmiş ve büyümüştür. Murabaha sukuk, bu çerçevede varlık temelli finansmanın sağlanması ve katılım bankalarının likidite ihtiyaçlarını karşılamak için önemli bir araç haline gelmiştir. İşleyişine bakıldığında ilk olarak, bir şirket veya kuruluş, belirli bir varlık veya proje için finansman ihtiyacı duyar. Katılım bankası, bu finansmanı sağlamak için Murabaha sukuk ihraç eder. Murabaha sukuk sahipleri, ihraç edilen sukukları satın alır ve bankaya karşılığında yatırım yaparlar. Banka, bu fonları kullanarak varlık veya proje için gerekli mal veya hizmeti satın alır ve kâr payı ekleyerek sukuk sahiplerine satar. Sukuk sahipleri, kâr payını sukuk tutarına göre paylaşırlar. Bu şekilde, varlık temelli finansman elde edilmiş olur ve sukuk sahipleri kâr payını elde eder. Örneğin, bir enerji şirketi, bir enerji projesi için finansman ihtiyacı duyar. Katılım bankası, bu projenin finansmanını Murabaha sukuk ihraç ederek sağlar. Murabaha sukuk sahipleri, ihraç edilen sukukları satın alarak şirkete finansman sağlar. Banka, bu fonları kullanarak enerji projesi için gerekli ekipmanları veya malzemeleri satın alır ve sukuk sahiplerine kâr payı ekleyerek satar. Sukuk sahipleri, proje başarılı olduğunda kâr payını elde eder.

2.2.4.8. İcare

İcare Arapçada kiralama demektir. Konvansiyonel bankalarda leasing olarak adlandırılan yöntem icareye oldukça benzemektedir. Nitekim temel prensibi de aynıdır. Katılım bankacılığında icare, İslam hukukuna uygun olan ürünlerin banka tarafından yine İslami esaslara göre sahip olduktan sonra fon elde etme amacıyla müşterilere kiralanması olarak

özetlenebilir. Bu ürünler bir yerden bir yere taşınabilir olan menkul kıymetlerden oluşabileceği gibi taşınamaz olan gayrimenkullerden de oluşabilir. Müşteriye kiralanmadan önce ürünün banka tarafından kiralanarak veya satın alınarak sahip olunması oldukça hassas bir konudur. İcare esnasında söz konusu olan malın ne kadar süreliğine ve ne kadara kiralanacağı taraflar arasında belirlenir. Anlaşmaya varılması ile kira sözleşmesinin yanında iş ve hizmet sözleşmeleri de imzalanarak süreç başlar. Bundan sonra banka mal sahibi, müşteri bankaya periyodik olarak fon sağlayan bir kiracı konumundadır. Bankacılık Denetleme ve Düzenleme Kurumunun hükmüne göre müşterinin kira periyodunun sonunda kiraladığı ürünü satın alma hakkı vardır. Eğer müşteri isterse ya temsili ücret karşılığında malı satın alır ya da banka ürünü müşteriye hibe eder. Bazı durumlarda müşterinin almak isteyip alım gücü yetmediği bir malı müşteri yerine satın alarak normal şartlardaki kira değerinin üstünde müşteriye kiralar, bu da icaredir. Müşteri satıcı ile bir ön sözleşme yaparak alma niyetini beyan eder. Daha sonra bir katılım bankasına giderek müracaat eder ve kabulüyle banka malı satın alır. Ödemesini peşin olarak satıcıya yaptıktan sonra müşteriye kiralar. Mülkiyet bankada olmasına rağmen kira karşılığında ürünü müşteri kullanır. Aslında buradaki her kira o malın müşteriye satış bedelinin vadeleridir. Aldığı son kira ile birlikte de mülkiyetini devreder. Bu yönüyle düşünüldüğünde murabahadan farksız görünebilir ancak murabahada risk çok daha yüksektir çünkü İslam finansı ilkelerine göre bir mal ister vadeli ister peşin satılmış olsun mülkiyeti alıcıdadır. Alıcı malın mülkiyetini aldıktan sonra ödemelerini aksatabilir. Sattığı malın hem mülkiyeti devreden hem tahsis yapamayan satıcı taraf için büyük bir risktir; oysa icarede böyle bir risk yoktur. En başta yapılan sözleşme kira sözleşmesidir ve kira dönemi boyunca mülkiyet satıcıdadır. Alıcı periyodik ödemelerini aksatması durumunda satıcının sözleşme esaslarına göre aksiyon alma hakkı vardır. Her şey yolunda gider de ödemeler tamamlanırsa son ödeme ile birlikte malın mülkiyeti satıcıya geçer. Sonuç olarak icare (leasing) murabahaya göre çok daha az riskle çalışan bir araçtır.

Yapılan anlaşma ve imzalanan sözleşmelerin dışında bir işlemin icare sayılabilmesi için belli şartlar vardır. Aşağıda yer alan bu şartlardan birinin sağlanması yeterlidir:

1. Kira sözleşmesinde vade sonunda malın mülkiyetinin alıcıya devredilmesinin şartı ile ilgili madde bulunması
2. Kira sözleşmesinde vade sonunda malın o zamanki piyasa değerinin altında alıcıya satılması şartı ile ilgili madde bulunması

3. Alıcının kira ödediği dönemin ilgili ürünün ömrünün en az %75'ine eşit olması ve toplam kira ödemelerinin ürünün kira sözleşmesinin yapıldığı tarihteki piyasa değerinin en az %90'ına eşit olması

2.3. MAKİNE ÖĞRENMESİ

Makine öğrenmesinin temelini oluşturan yapay zekâ, en yalın tanımı ile bilgisayar sistemlerine insan benzeri zekâ ve öğrenme yetenekleri kazandırmayı amaçlayan bir disiplindir, birçok farklı bakış açısına göre farklı şekillerde yorumlanmış ve birçok farklı alanda gelişim göstermiştir. Gelişen teknolojiler ve yeni yaklaşımlarla yapay zekâ alanı sürekli olarak ilerlemektedir. Düşünsel yetenekler açısından tanımlayan yaklaşıma göre yapay zekâ bilgisayar; sistemlerinin düşünme, problem çözme, mantık yürütme, karar verme ve dil anlama gibi becerilere sahip olmasını hedefler. Bu tanımlama, bilgisayar sistemlerinin insan benzeri zihinsel faaliyetleri gerçekleştirebilme kabiliyetine odaklanır. Davranışsal yetenekler açısından tanımlayan yaklaşım ise bilgisayar sistemlerinin gözlemlene, algılama, hareket etme ve etkileşim kurma gibi fiziksel ve çevresel etkileşimlerde bulunabilme yeteneklerini vurgular. Bu tanımlama, sistemlerin çevreleriyle etkileşime geçebilme ve adaptif davranabilme yeteneklerini hedefler. Bilgisayar sistemlerinin bilgi işleme, öğrenme, anlama, hatırlama ve akıl yürütme gibi bilişsel faaliyetleri gerçekleştirebilme yeteneklerini ön plana çıkarıp bilgisayar sistemlerinin bilgiyi işleme ve akıl yürütme süreçlerinde insan benzeri kapasiteleri elde etmesini amaçlayan yaklaşım ise yapay zekâyı daha çok bilişsel yetenekler açısından değerlendirip gelişmesinin önünü açan bir yaklaşımdır. Bilişsel yeteneklerdeki bakış açısı ile sıklıkla karıştırılsa da planlama, problem çözme, sezgi, yaratıcılık ve adaptasyon gibi zekâ benzeri davranışları sergileme yeteneklerini vurgulayan tanımlamalara göre yapay zekânın temel işlevi zekâ benzeri davranışlar sergilemesidir çünkü yapay zekâ karmaşık ve zorlu görevleri gerçekleştirme kapasitesine sahiptir. Son olarak yapay zekâyı makine öğrenmesi ve veri analitiği açısından tanımlayan yaklaşıma göre yapay zekâ bilgisayar sistemlerinin büyük veri setlerini analiz etme, desenleri tespit etme, tahmin yapma ve kendilerini optimize etme yeteneklerini vurgular. Bu tanımlama, sistemlerin verilerden öğrenme ve karar verme yeteneklerini hedefler.

Yapay zekânın oluşum ve gelişim süreci, birçok düşünce akımı ve olayın etkisiyle şekillenmiştir. Yapay zekâ kavramı, ilk olarak 1956 yılında, bilim insanlarını bir araya getirerek makine zekâsı alanında çalışmalar yapmayı amaçlayan Dartmouth Konferansı'nda ortaya atılmıştır. Bu dönemde kullanılan makine zekâsı ifadesi daha çok zihinsel güç gerektiren işlerin

yükünün insan üzerinde olması fiziksel işlerde kullanılan makinelerin daha kullanışlı ve kullanıcıyı yormayan niteliklere sahip olabileceği ihtimalinin ne kadar gerçek olabileceğinin sorgulanmasına dayanıyordu. Dolayısıyla bu konferansta ifade olarak benzese de tam olarak makine öğrenmesine varılamamış olsa da yapay zekâ alanının temelleri atılmış ve bilgisayarların insan benzeri zekâyâ sahip olabileceği fikri doğmuştur. Süreçsel gelişim incelendiğinde yapay zekâ araştırmalarının hız kazandığı 1960'lar ve 1970'lerde sembolik yapay zekâ yaklaşımı öne çıkmıştır. Bu yaklaşımla birlikte, insan zekâsını taklit etmek amacıyla semboller ve mantık temelli algoritmalar kullanılmıştır. John McCarthy, Marvin Minsky, Allen Newell ve Herbert Simon gibi isimler bu dönemde yapay zekâ alanında önemli çalışmalara imza atmışlardır; ancak, sembolik yaklaşımın sınırlamaları ve başarıdan uzak kalması, 1980'lerde ve 1990'larda bağlamsal yapay zekâ ve makine öğrenmesi alanlarının gelişimine yol açmıştır. Bağlamsal yapay zekâ, dil anlama, uzman sistemler ve uzamsal çıkarım gibi konulara odaklanmış, makine öğrenmesi ise bilgisayarların verilerden öğrenme yeteneği kazanmasıyla ilgilenmiştir. İstatistiksel modeller, yapay sinir ağları ve genetik algoritma gibi teknikler, makine öğrenmesinin temelini oluşturmuştur. Bu dönemde yapay zekâ alanında düşünce akımlarının yanı sıra önemli olaylar da etkili olmuştur. 1997'de IBM'in Deep Blue adlı bilgisayarı, dünya satranç şampiyonu Garry Kasparov'u yenebilmiştir. Bu olay, yapay zekânın insanları yenme potansiyeline sahip olduğunu gösteren bir dönüm noktası olmuştur. 2011'de IBM'in Watson adlı bilgisayarı, Jeopardy adlı Amerikan televizyon yarışmasında insan rakiplerini yenmiş ve geniş çapta ilgi uyandırmıştır. 21. Yüzyıla gelindiğinde büyük veri ve hesaplama gücündeki artışla öne çıkan yapay zekâ büyük veri analitiği ve derin öğrenme teknikleri, yapay zekânın uygulama alanlarını genişletmiştir. Görüntü ve ses tanıma, doğal dil işleme, otonom araçlar, sağlık hizmetleri ve finans gibi birçok alanda yapay zekâ kullanımı artmıştır. Bu noktada sürekli gelişen ve ilerlemeye devam eden yapay zekânın önündeki en büyük engel aşılamayan bazı felsefi tartışmalardır. Çalışmalarda veri gizliliğinin ihlal edilme ihtimali, otomasyonun işgücüne etki ederek işsizlik oranındaki artışa sebep olabilmesi gibi etik konular toplum içinde değerlerle çelişmesinden dolayı yapay zekâ bazı senaryolarda tam bir vicdan rahatlığı ile kabul edilememektedir. Bu durum ilerlemesinde hızını kısıtlayan en önemli engeldir.

Makine öğrenmesine bakıldığında yapay zekâ ile makine öğrenmesi arasında yakın bir ilişki vardır ve aralarındaki bağ karıştırılabilmektedir. Makine öğrenmesi, yapay zekânın bir alt alanı olarak kabul edilir ve yapay zekânın temel bir bileşenidir. En temel tanımı ile bilgisayar sistemlerinin verilerden öğrenme yeteneği kazanmasını sağlar. Makine öğrenmesi, veri analitiği

ve istatistiksel yöntemleri kullanarak bilgisayar sistemlerine örüntüleri tanıma, tahmin yapma, karar verme gibi yetenekleri otomatik olarak öğretir. Bu, büyük veri setlerini analiz ederek istatistiksel modellerin oluşturulması ve bu modellerin kullanılması yoluyla gerçekleşir. Yapay zekâ ise daha geniş bir kavramdır ve bilgisayar sistemlerinin insan benzeri zekâ ve düşünsel yetenekleri taklit etmesini amaçlar. Yapay zekâ, doğal dil işleme, görüntü ve ses tanıma, problem çözme, planlama gibi birçok alanda makine öğrenmesi yöntemlerini kullanır. Kısacası makine öğrenmesi yapay zekânın bilişsel yeteneklerini destekleyen bir araç olarak görülebilir.

Makine öğrenmesi, yapay zekânın gerçekleştirilmesinde önemli bir rol oynar. Verilerden öğrenme yeteneği sayesinde bilgisayar sistemleri, belirli görevleri yerine getirmek için kendilerini geliştirebilir ve optimize edebilir. Makine öğrenmesi algoritmaları, veriye dayalı öğrenme süreçleriyle model oluşturur ve bu modeller, çeşitli yapay zekâ uygulamalarında kullanılabilir.

2.3.1. Literatür Taraması

Makine öğrenmesinin gelişiminde yapıtaşı rolü oynayan olaylar kronolojik olarak aşağıdaki tablodaki gibidir:

Tablo 2.3: Makine Öğrenmesi Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
1947	Alan Turing	Computing Machinery and Intelligence adlı makalesinde makine öğreniminin potansiyelini tartıştı.
1952	Arthur Samuel	"Checkers Playing Program" adlı programını geliştirdi. Bu program, deneme yanılma yoluyla satranç oynamayı öğrenen ilk makine öğrenimi programıdır.
1957	Frank Rosenblatt	"Perceptron" adlı yapay sinir ağını geliştirdi. Perceptron, basit bir makine öğrenimi algoritmasıydı, ancak oldukça güçlüydü ve birçok uygulamada kullanıldı.
1960	Patrick Suppes	"Learning Theories" adlı kitabında makine öğreniminin temellerini attı.
1967	Marvin Minsky ve Seymour Paper	"Perceptrons" adlı kitabında perceptron'ların sınırlamalarını gösterdiler. Bu, makine öğrenimindeki araştırmayı bir süre yavaşlattı.
1980	David Rumelhart, Geoffrey Hinton ve Ronald Williams	"Learning Internal Representations by Error Propagation" adlı makalesinde geri yayılım algoritmasını geliştirdiler. Bu algoritma, yapay sinir ağlarının eğitiminde kullanılan en yaygın algoritmadır.

Tablo 2.3 (devam): Makine Öğrenmesi Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
1982	Tom M. Mitchell	"The Need for Biases in Learning Generalizations" adlı makalesinde makine öğrenim sistemlerinde önyargının önemini vurguladı.
1983	David E. Rumelhart ve James L. McClelland	"Pallel Distributed Processing: Explorations in the Microstructure of Cognition" adlı kitabını yayınladılar. Bu kitap, yapay sinir ağları hakkında klasik bir kaynaktır.
1984	Vapnik ve Chervonenkis	"The Nature of Statistical Learning Theory" adlı kitabını yayınladılar. Bu kitap, destek vektör makineleri hakkında klasik bir kaynaktır.
1985	David Haussler	"Decision Trees and Statistical Models" adlı makalesinde karar ağaçları hakkında klasik bir makale yayınladı.
1986	Robert E. Schapire	"The Strength of Weak Learnability" adlı makalesinde güçlü öğrenme ve zayıf öğrenme kavramlarını tartıştı.
1987	Andrew Ng ve Michael I. Jordan	"On the Optimality of Generalized Sequential Probability Ratio Tests" adlı makalesinde destek vektör makinelerinin optimalliğini gösterdiler.
1988	John Platt	"Probabilistic Outputs for Support Vector Machines" adlı makalesinde destek vektör makineleri için olasılıksal çıktıları önerdi.
1990	Geoffrey Hinton, Rumelhart ve Williams	"Learning Representations by Back-Propagating Errors" adlı makalesinde geri yayılım algoritmasını geliştirdiler. Bu algoritma, derin öğrenmenin temelini oluşturdu.
1991	Andreas Weigend ve David Rumelhart	"Backpropagation: A Review of Progress" adlı makalesinde geri yayılım algoritmasının bir incelemesini yaptılar.
1992	Yoshua Bengio	"Learning Long-Term Dependencies with Gradient Descent" adlı makalesinde uzun süreli bağımlılıkları öğrenmek için geri yayılım algoritmasını kullandı.
1993	Yann LeCun, Leonardo Bottou, Yoshua Bengio ve Patrick Haffner	"Gradient-Based Learning Applied to Document Recognition" adlı makalesinde görüntü tanıma için derin öğrenmeyi kullandılar.
1994	Thomas G. Dietterich	"Overfitting and Underfitting" adlı makalesinde makine öğrenimindeki aşırı uydurma ve aşırı uydurma kavramlarını tartıştı.
1995	John C. Platt	"Probabilistic Outputs for Support Vector Machines" adlı makalesinde destek vektör makineleri için olasılıksal çıktıları önerdi.
1996	Trevor Hastie, Robert Tibshirani ve Jerome Friedman	"The Elements of Statistical Learning" adlı kitaplarını yayınladılar. Bu kitap, makine öğreniminin temellerini öğreten bir klasiktir.

Tablo 2.3 (devam): Makine Öğrenmesi Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
1997	David Heckerman	"A Tutorial on Learning Bayesian Networks" adlı makalesinde Bayes ağlarını öğrenmeyi tartıştı.
1998	Michael I. Jordan	"Introduction to Statistical Learning" adlı kitabını yayınladı. Bu kitap, makine öğreniminin temellerini öğreten bir başka klasiktir.
1999	Geoffrey Hinton	"Reducing the Dimensionality of Data with Neural Networks" adlı makalesinde veri boyutunu azaltmak için yapay sinir ağlarını kullandı.
2001	Yann LeCun, Léon Bottou, Yoshua Bengio, ve Patrick Haffner	Gradient-based learning applied to document recognition (Belge tanıma için gradyan tabanlı öğrenme) çalışması yapıldı. Bu çalışmada, belge tanıma problemini çözmek için gradyan tabanlı öğrenme yöntemleri kullanıldı. Bu çalışma, el yazısı tanıma ve karakter tanıma gibi alanlarda önemli bir ilerleme sağladı.
2006	Geoffrey Hinton, Simon Osindero ve Yee-Whye Teh	A fast learning algorithm for deep belief nets" (Derin inanç ağları için hızlı öğrenme algoritması) çalışması yapıldı. Bu çalışmada, derin inanç ağları için hızlı bir öğrenme algoritması tanıtıldı. Bu algoritma, derin öğrenme alanında yaygın olarak kullanılan birçok teknik için temel oluşturdu.
2009	Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton	ImageNet Classification with Deep Convolutional Neural Networks (Derin Evrişimli Sinir Ağları ile ImageNet Sınıflandırması) çalışması yapıldı. Bu çalışma, derin evrişimli sinir ağlarını kullanarak büyük ölçekli görüntü sınıflandırma problemini ele aldı. Bu çalışma, derin öğrenme modellerinin görüntü işleme alanındaki etkinliğini kanıtladı ve ImageNet yarışmasında çığır açtı.
2010	Corinna Cortes ve Vladimir Vapnik	Support-vector networks (Destek vektör ağları) çalışması yapıldı. bu çalışmada, destek vektör ağları adlı bir sınıflandırma yöntemi tanıtıldı. Bu yöntem, özellikle sınıflandırma problemlerinde etkili bir şekilde kullanılmakta ve makine öğrenmesi alanında temel bir yöntem olarak kabul edilmektedir.
2012	Alex Graves, Abdel-rahman Mohamed ve Geoffrey Hinton	Supervised Sequence Labelling with Recurrent Neural Networks (Tekrarlayan Sinir Ağları ile Gözetimli Sıralı Etiketleme) çalışması yapıldı. Bu çalışma, tekrarlayan sinir ağlarını kullanarak gözetimli sıralı etiketleme problemini ele aldı. Bu çalışma, özellikle doğal dil işleme ve zaman serisi analizi gibi alanlarda önemli bir rol oynamıştır.
2014	Ian Goodfellow, Yoshua Bengio ve Aaron Courville	Generative Adversarial Nets (Jeneratif Rekabetçi Ağlar) çalışması yapılmıştır.
2015	Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun	Deep Residual Learning for Image Recognition (Görüntü Tanıma için Derin Kalıntı Öğrenimi) çalışması yapılmıştır.

Tablo 2.3 (devam): Makine Öğrenmesi Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
2017	François Chollet	Xception: Deep Learning with Depthwise Separable Convolutions (Xception: Derin Öğrenme için Derinlik Bazlı Ayrılabilir Evrişimler) çalışması yapılmıştır.
2018	Thomas N. Kipf ve Max Welling	"Semi-Supervised Classification with Graph Convolutional Networks" (Graf Evrişim Ağları ile Yarı Gözetimli Sınıflandırma) çalışması yapılmıştır.
2020	Anima Anandkumar, Rong Ge, Daniel Hsu ve Sham M. Kakade	Tensor decompositions for learning latent variable models (Gizli değişken modelleri öğrenmek için tensör çözümlemeleri) çalışması yapıldı.
2022	Tongfeng Weng, Chunzi Li, Huijie Yang	Çalışmalarında üç ayrı makine öğrenimi modeline odaklanılmış, seçilen modellerin, öğrenilmiş bir kaotik sistemle neredeyse aynı uzun vadeli istatistiksel özellikleri sunduğunu bulunmuştur.
2023	Colin Smith, Allison Weathers, Steven Lewis	"An overview of clinical machine learning applications in neurology" adlı çalışmada makine öğrenimi araçları klinik uygulamalara göre sınıflandırılmakta ve nörolojideki kullanım örnekleri daha ayrıntılı olarak açıklanmaktadır.
2024	Fuwei Jiang, Tian Ma, Feifei Zhu	Çin hisse senedi piyasasının firmaya özgü bir dizi özelliğini kullanarak hisse senedi fiyat çöküş risklerini tahmin etmek için makine öğrenimi algoritmalarının uygulanmasını araştırıldı.
2024	Yu Gao, Jiayuan Wang, Xiaoxiao Xu	"Machine learning in construction and demolition waste management: Progress, challenges, and future directions" adlı çalışma ile güncel sıcak konuları ve ortaya çıkan eğilimleri belirlemek için 2012'den 2023'e kadar inşaat atık yönetiminde makine öğreniminin uygulanmasıyla ilgili 98 derginin kapsamlı bir analizini yapmaktadır.

2.3.2. Kullanım Alanları

Bankacılık sektörü insanlardan çok fazla veri temin eden ve bu veriye göre müşterilerine ürün ve hizmet sunan bir sektör olduğu için veri odaklı bir sektör olduğunu söylemek olağan olacaktır. Yapılan iş gereği sürekli olarak karar verme sistemlerinin aktif olarak devrede olup geçmişe yönelik değerlendirmelerin ve gelecek zamandaki müşteri davranışlarının tahmin edilmesi yapılan işin çok büyük bir kısmını oluşturmaktadır. Dolayısıyla makine öğrenmesi ile analiz ve tahminlemeler bankacılık sektörünün kalbini oluşturmaktadır. İlerleyen süreçte de tamamen yapay zekâ ile ilerleyen bir sektör olması birçok bili adamı tarafından şüphesiz olarak öngörülmektedir. Yapay zekânın girdisi olan verilerin bolluğu yönüyle diğer sektörlerle fark atan bankacılık sektörünün kalbi analiz ve tahminleme çalışmalarıyla yapay zekâ alanındadır. Gerek analiz gerek tahminleme süreçlerinde kullanılan bu verilerin bir kısmı doğum yeri,

doğum tarihi, anne&baba adı gibi demografik verilerden oluşmakta olup tamamen müşteriyi tanımaya yönelik veya güvenlik hassasiyetleriyle alınan verilerdir. Bunun dışında müşterinin hesaplarına giren kıymetler, bu gelirin harcama, birikim ve yatırımı ile ilgili yaptığı her bir işlem o müşterinin ödeme başarısının hesaplanabilmesi ve buna göre amacı doğrultusunda kendisine en uygun ürüne yönlendirilmesi için kayıt altına alınarak son derece kıymetli ve müşteri açısından özel verilerdir. Bu verilerin paylaşılmasının yasal ve etik olarak sakıncalı olabileceği için bankacılıkta yapay zekânın kullanımı kısıtlanabilmektedir. Veri gizliliği ve korunması birçok uygulamada sorun teşkil ederken, konuya ilişkin etik süreçler her ülkede farklılık göstermektedir. (Celebi ve Inal, 2019)

2.3.3. Sınıflandırma

Temel bir makine öğrenimi yöntemi olan sınıflandırma, veri noktalarını özelliklerine veya karakteristiklerine göre önceden tanımlanmış sınıflara veya kategorilere ayırma işlemini içerir. Bir sınıflandırma modelinin geliştirme süreci, birkaç temel yapı taşını kapsayan sistematik bir prosedürdür. İlk olarak, veri toplama, ilgili sınıfları veya kategorileri ile birlikte veri noktalarının örneklerini içeren etiketli bir veri kümesinin elde edilmesinde çok önemli bir rol oynar. Daha sonra, verileri model eğitime hazırlamak için temizleme, dönüştürme ve normalleştirme dahil olmak üzere veri ön işleme adımları gerçekleştirilir. Bunu, modelin tahmin yeteneklerini geliştirmek için ilgili özelliklerin seçildiği özellik seçimi takip eder. Bir sonraki aşama, verilerin niteliğine ve sorun alanına bağlı olarak karar ağaçları, lojistik regresyon veya destek vektör makineleri gibi uygun bir sınıflandırma algoritmasının seçilmesini içerir. Daha sonra yeni örnekleri doğru bir şekilde sınıflandırabilecek bir tahmin modeli oluşturmak için etiketli veri kümesi kullanılarak model eğitimi gerçekleştirilir. Eğitimin ardından, doğruluk, kesinlik, geri çağırma ve F1 puanı gibi ölçütleri kullanarak sınıflandırma modelinin performansını değerlendirmek için model değerlendirmesi esastır.

Sınıflandırma yöntemleri, kategorik verileri işleme kabiliyeti, yorumlanabilirlik ve hesaplamada verimlilik gibi çeşitli güçlü yönlere sahiptir. Bununla birlikte, bu modeller aşırı uyum, yanlılık veya varyansa yatkınlık gibi zayıflıklar sergileyebilir ve geliştirme sırasında dikkatli ayarlama ve düzenleme teknikleri gerektirir. Sınıflandırma modellerinin uygulamaları, e-postalarda spam tespiti, sosyal medyada duygu analizi, nesne tanımlama için görüntü tanıma ve hastalık tahmini için tıbbi teşhis gibi örneklerle çeşitli alanları kapsar. Sınıflandırma yöntemlerini kullanmanın birincil amacı, özelliklerine göre veri noktalarına etiket veya kategori

atama sürecini otomatikleştirmek ve çeşitli gerçek dünya senaryolarında verimli karar verme ve örüntü tanımaya olanak sağlamaktır.

2.3.4. Kümeleme

Kümeleme, veri analitiği ve yapay zekâ alanlarında çığır açan bir gelişme olarak öne çıkan makine öğrenmesinin sıklıkla kullanılan yöntemlerinden birisi olarak belirgin bir yere sahiptir. Temel olarak tanımlı yapılacak olunursa; gözetimsiz bir öğrenme yöntemi olup veri kümesini benzerlik ölçütlerine dayanarak gruplara ayırma işlemini ifade eder.

Kümeleme, veri analitiği sürecinde yaygın olarak kullanılan bir unsupervised yani gözetimsiz öğrenme yöntemidir. Gözetimsiz öğrenmenin ise verilerin herhangi bir etiket veya sınıflandırma bilgisi olmadan analiz edildiği bir yaklaşım olduğu söylenebilir. Kümeleme ile bir veri kümesindeki benzer örnekleri tanımlanarak gruplanır. Aynı kümedeki örneklerin birbirine benzer olması, farklı kümedeki örnekler arasında ise farklılık göstermesi temel prensiplerinden biridir.

Gelişim sürecine bakıldığında kümeleme istatistiksel ve bilgisayar bilimleri arasındaki kesişim noktasında ortaya çıkmıştır. İlk olarak, istatistiksel analizde kullanılan gruplama ve sınıflandırma teknikleri, veri analitiği alanında daha yaygın hale gelmiştir. Daha sonra, bilgisayar bilimleri ve yapay zekâ alanındaki ilerlemeler, kümeleme algoritmalarının geliştirilmesine ve uygulanmasına olanak sağlamıştır. Özellikle, K-means, hierarchical clustering, DBSCAN gibi popüler kümeleme algoritmaları bu süreçte önemli bir yere sahiptir. En sık kullanıldığı alan müşteri segmentasyonudur. Sektör fark etmeksizin kümeleme ile pazarlama alanında müşterileri benzer özelliklere sahip gruplara ayırarak pazarlama stratejilerini kişiselleştirmek ve hedef kitleye özel kampanyalar geliştirmek mümkündür. Tıp kümelemenin yoğun kullanıldığı bir diğer alandır. Biyo-informatikte biyolojik verilerin analizi, gen verilerinin kümelmesi, protein dizilerinin sınıflandırılması gibi alanlarda kümeleme yöntemleri büyük önem taşır. Bu sayede, biyolojik sistemlerin anlaşılması ve hastalık mekanizmalarının belirlenmesi kolaylaşır. Ayrıca görüntü işleme ve anormallik tespiti için de kümeleme sektör fark etmeksizin birçok alanda yaygın olarak kullanılır. Görüntü segmentasyonunda ve nesne tanıma gibi uygulamalarda kümeleme algoritmaları kullanılan kümeleme ile görüntüleri anlamlı bölgelere ayrılır ve bu bölgeler üzerinden analizler yapılır. Kümelemeden sonra yapılan analizlerde veri setindeki anormal örüntüleri veya aykırıları tespit etmek mümkündür. Amazonun sisteme her açıdan sayısız taze ve çürük meyve görseli yükleyip

sisteme meyveyi tanıttıktan sonra bir sepet çileği kamerayla taratıp hangi koordinatta çürük çilek olduğunu saniyeler için tek tek göz kontrolüyle vakit kaybetmeden tespit etmesini buna örnektir. Ayrıca dolandırıcılık tespiti, ağ güvenliği ve hata teşhisi gibi alanlarda anomali tespitinde kullanılan kümeleme yöntemleri de kritik bir öneme sahiptir.

Kümeleme yönteminin uygulanması; veri setinin önceden işlenerek kullanıma hazır hale gelmesi, uygun bir kümeleme algoritmasının seçilmesi, algoritmanın veri setine uygulanması ve sonuçların değerlendirilmesi adımlarını içerir. Kümeleme sonuçlarının değerlendirilmesi, içsel ve dışsal değerlendirme metrikleri kullanılarak gerçekleştirilir. İçsel metrikler, kümeleme sonuçlarının homojenliği, ayrılabilirliği ve kompaktlığı gibi özelliklerini ölçerken; dışsal metrikler gerçek küme etiketleriyle karşılaştırarak kümeleme performansını değerlendirir. Kümeleme, makine öğrenimi ve veri analitiği alanında önemli bir yer tutmaktadır ve çeşitli uygulama alanlarında geniş bir kullanım potansiyeline sahiptir. Gelecekte, kümeleme algoritmalarının daha karmaşık veri yapılarıyla başa çıkabilmesi ve daha büyük ölçekli veri kümeleriyle çalışabilmesi için yeni yöntemlerin geliştirilmesi beklenmektedir. Ayrıca, kümeleme yöntemlerinin daha fazla endüstriyel ve bilimsel alanda kullanılmasıyla birlikte, veri analitiği ve karar destek sistemleri alanında önemli ilerlemelerin sağlanması hedeflenmektedir.

2.3.5. Birliktelik Analizi

Birliktelik analizi, veri madenciliğinde önemli bir yöntem olup bir veri kümesindeki öğeler arasındaki ilişkileri ve ilişkili kuralları belirlemek için kullanılır. Genellikle market sepet analizi olarak da bilinir, çünkü özellikle perakende sektöründe müşteri alışveriş davranışlarını anlamak ve kritik ilişkileri belirlemek için yaygın olarak kullanılır. Sebebi ise birlikte görülen öğelerin sık sık birlikte bulunma eğiliminde olduğu temeline dayanmasıdır. Bu, bir ürünü satın alan müşterilerin diğer belirli ürünleri de satın alma eğiliminde olabileceği anlamına gelir. Örneğin, bir markette bir müşteri bir ekmeği satın aldıysa, o müşterinin aynı alışverişte tereyağı veya peynir gibi diğer süt ürünlerini de satın alabileceği tahmin edilebilir. Ortaya çıkışına bakıldığında 1990'larda Agrawal ve Srikant tarafından geliştirilen Apriori algoritması ile başladığı görülmektedir. Apriori algoritması, pazar sepetinde birbirleriyle ilişkili olan öğeleri belirlemek için kural tabanlı bir yaklaşım kullanır. Daha sonra, FP-Growth algoritması gibi daha gelişmiş algoritmalar geliştirilmiştir, bu algoritmalar büyük veri kümeleriyle daha etkin bir şekilde çalışabilir. Böylelikle birliktelik analizi, çeşitli endüstrilerde ve iş alanlarında kullanılan bir yöntem olmuştur. Özellikle perakende sektöründe, müşteri satın alma alışkanlıklarını anlamak ve öneri sistemlerini geliştirmek için yaygın olarak kullanılır. Bununla

birlikte, web madenciliği, telekomünikasyon, sağlık hizmetleri, finansal hizmetler ve pazarlama gibi diğer alanlarda da kullanılmaktadır.

Uygulanma aşamalarına bakıldığında ilk olarak ilgili veriler bulunmalıdır, bu analize hazırlık aşaması olarak da düşünülebilir. Veri seti toplandıktan sonra mutlaka temizlenmeli, eksik değerlerin doldurulmalı ve gerekiyorsa dönüştürülmelidir. Hazır hale geldikten sonra Apriori veya FP-Growth gibi bir algoritma kullanılarak birliktelik kuralları belirlenir. Çıkarılan kuralların anlamlılığı ve kullanışlılığı değerlendirilip yorumlandıktan sonra sonuçlar anlamlı bir şekilde sunularak karar vericilere veya ilgili paydaşlara iletilir. Bu iki yöntemin detayları aşağıdaki gibidir.

2.3.5.1. Apriori

Etkili bir Pazar Sepeti Analizi, tüketicilerin ürünlerini daha kolay satın almalarını sağlayarak pazar satışlarında artışa yol açtığı için kritik öneme sahiptir. Bu analiz algoritmalarından biri olan apriori algoritması, birliktelik analizi için geliştirilmiş bir klasik algoritmadır. Bu algoritma, sık görülen desenleri (pattern) belirlemek için kullanılır ve veri kümesindeki sık öğeleri (frequent items) tespit eder. Kural tabanlı bir yaklaşım kullanır ve sık görülen öğelerin tespiti için bir aşamalı işleme süreci kullanır. Bu süreçte, öncelikle veri kümesindeki tek öğeli desenler bulunur. Daha sonra, iki öğeli desenler, üç öğeli desenler ve benzeri şekilde tüm olası desenler bulunur. Bu aşamalı süreç, minimum destek kriterini karşılayan sık görülen desenleri belirler. 1994 yılında R. Agrawal ve R. Srikant, boolean birliktelik kuralını kullanarak bir veri kümesinde en sık meydana gelen öğe kümelerini belirlemek için Apriori yöntemini geliştirmiştir. Ortak öğe kümesi özellikleri hakkında önceki bilgileri kullandığından, yöntem Apriori olarak adlandırılır. Bu, $k+1$ öğe kümesini bulmak için K-Means öğe kümesinin kullanıldığı iteratif bir teknik veya seviye-bilge yaklaşımı kullanılarak elde edilir. Apriori özelliği olarak bilinen temel bir özellik, sık öğe kümelerinin seviye bazlı üretiminin etkinliğini artırmak için kullanılır. Bu özellik, arama alanını en aza indirerek yardımcı olur ve bu da sık örüntülerin seviye bazında oluşturulmasının verimliliğini en üst düzeye çıkarmaya hizmet eder, basit bir önermeye göre çalışır. İşlemsel veri tabanı desteğinin seviyesini belirlenir ve minimum yardım ve güvenilirlik derecesini oluşturulur. İşlemin standart veya seçilen destek değerinden daha büyük olan tüm destekleri alınır. Bu alt gruplarda, kesme veya temel standarttan daha yüksek hassasiyete sahip tüm kuralları aranır. Kuralları artan güç sırasına göre düzenlemek en iyisidir.

En önemli dezavantajı öge kümelerinin büyüklüğüyle ilgilidir. Bu küme çok büyükse ve minimum destek en düşük seviyede tutulursa önemli miktarda hesaplama gerektirir. Ayrıca tüm veri tabanının tam olarak taranması gerekir.

2.3.5.2. *FP Growth*

FP-Growth (Frequent Pattern Growth) algoritması, birliktelik analizi alanında özellikle büyük veri kümeleriyle başa çıkmak için geliştirilen bir algoritmadır. Bu algoritma, sık görülen desenleri (pattern) belirlemek için kullanılır ve özellikle büyük veri kümeleri üzerinde etkili bir şekilde çalışır. FP-Growth algoritması, Apriori algoritmasının aksine, veri kümesini bir dizi sık görülen desen içeren bir öge ağacı (item tree) olarak temsil eder ve bu yapı üzerinde işlem yaparak birliktelik kurallarını çıkarır. Algoritma uygulanırken öncelikle veri kümesindeki sık görülen öğeleri belirler. Bu adımda, veri kümesi taranır ve minimum destek kriterini karşılayan sık öğeler (frequent items) belirlenir. Daha sonra, FP-Tree adı verilen bir yapı oluşturulur. FP-Tree, veri kümesindeki desenleri temsil etmek için kullanılır ve her bir desenin sıklığına göre düzenlenmiş bir şekilde saklanır. FP-Tree oluşturulduktan sonra, FP-Growth algoritması her bir sık öge için bir büyüme (growth) ağacı oluşturur. Bu ağaçlar, FP-Tree yapısını kullanarak veri kümesindeki desenleri temsil eder. Büyüme ağaçları oluşturulduktan sonra, birliktelik kuralları çıkarılır. Bu adımda, FP-Tree yapısı kullanılarak veri kümesindeki desenler arasındaki ilişkiler belirlenir ve birliktelik kuralları çıkarılır. Örneğin, bir marketin satış verilerini ele alınacak olunursa bu veri kümesinde, müşterilerin markette birlikte satın aldıkları ürünlerin listesi bulunmaktadır. FP-Growth algoritması, bu veri kümesini kullanarak müşteri alışveriş alışkanlıklarını analiz eder ve sık görülen desenleri belirler. İlk olarak veri kümesi taranarak sık görülen öğeler belirlenir. Örneğin, ekmek, süt ve peynir gibi sık görülen öğeler belirlenir. Daha sonra, FP-Tree yapısı oluşturulur. FP-Tree yapısı, her bir deseni ve desenlerin sıklığını temsil eder. FP-Tree oluşturulduktan sonra, FP-Growth algoritması her bir sık öge için bir büyüme ağacı oluşturur. Bu ağaçlar, FP-Tree yapısını kullanarak veri kümesindeki desenleri temsil eder. Son olarak, birliktelik kuralları çıkarılır. Örneğin, ekmek satın alan müşterilerin aynı alışverişte süt ve peynir de satın alma olasılığı yüksektir.

FP Growth Çıktılarında yorumlanan değerler aşağıdaki gibidir:

- Support (Destek Değeri): Bir ürünün/ilişkinin tüm olaylar içerisinde görülme olasılığıdır.

N: Toplam alışverişlerin sayısı

$$\text{Support}(X \rightarrow Y) = \text{Frequency}(X, Y) / N \quad (2.1)$$

- Confidence (Güven Değeri): X ürününü alan bir müşterinin Y ürününü alma olasılığıdır.

$$\text{Confidence}(X \rightarrow Y) = \text{Frequency}(X, Y) / \text{Frequency}(X) \quad (2.2)$$

- Lift: X olayının gerçekleşmesinin, Y olayının gerçekleşmesi ihtimalini kaç kat artırdığını gösterir.

$$\text{Lift} = \text{Support}(X, Y) / (\text{Support}(X) \times \text{Support}(Y)) \quad (2.3)$$

2.3.5.3. Apriori&FP Growth Karşılaştırması

Apriori ve FP-Growth algoritmaları, birliktelik analizi alanında benzer amaçlara hizmet ederler ancak farklı çalışma prensiplerine sahiptirler. Apriori algoritması, önce tüm olası desenleri bulur ve daha sonra destek kriterini karşılayan desenleri seçer. Bu nedenle, Apriori algoritması büyük veri kümeleri üzerinde çalışırken performans sorunları yaşayabilir. FP-Growth algoritması ise, veri kümesini bir öge ağacı olarak temsil eder ve bu yapı üzerinde işlem yaparak birliktelik kurallarını çıkarır. Bu nedenle, FP-Growth algoritması genellikle Apriori'ye göre daha hızlı çalışır ve daha büyük veri kümeleriyle daha iyi başa çıkabilir.

Tablo 2.4: Apriori & FP Growth Karşılaştırması

Apriori	FP Growth
Apriori, tekli öge kümesi, ikili öge kümesi, üçlü öge kümesi gibi eşleştirmeleri kullanarak öge kümeleri oluşturarak sık örüntüleri üretir.	FP Growth, sık örüntüler oluşturmak için bir FP-Tree oluşturur.
Apriori, sık alt kümelerin her seferinde bir öge genişletildiği aday üretimini kullanır.	FP-büyümesi, verideki her öge için koşullu FP-Ağacı oluşturur.
Apriori her adımında veritabanını taradığından, öge sayısının daha fazla olduğu veriler için zaman alıcı hale gelir.	FP-tree, başlangıç adımlarında veritabanının yalnızca bir kez taranmasını gerektirir, bu nedenle daha az zaman harcar.
Veritabanının dönüştürülmüş bir versiyonu hafızaya kaydedilir.	Her öge için koşullu FP ağacı kümesi belleğe kaydedilir.
Genişlik öncelikli arama kullanır.	Derinlik öncelikli arama kullanır.

2.3.6. Regresyon

Regresyon, istatistik ve makine öğrenimi alanlarında sıkça kullanılan bir analiz olmasıyla bilinmesinin yanında akademik tanımıyla bir bağımlı değişkenin (outcome) bir veya daha fazla bağımsız değişkene (predictor) göre nasıl değiştiğini anlamak için kullanılan bir istatistiksel modelleme yöntemidir. Regresyon analizi, bu değişkenler arasındaki ilişkiyi anlama ve gelecekteki değerleri tahmin etme yeteneğiyle önemli bir araçtır.

Regresyon analizinin temel amacı bağımlı değişkenin değerlerini bağımsız değişkenlerin değerlerine dayanarak tahmin etmektir. Bu, değişkenler arasındaki ilişkiyi matematiksel bir modelle ifade ederek gerçekleştirilir. Regresyon modelleri, genellikle doğrusal veya doğrusal olmayan olabilir ve istatistiksel tekniklerle parametreleri belirlenir. Ayrıca bir diğer kullanım amacı iki değişken arasındaki ilişkiyi analiz etmektir. Bu ilişkiyi korelasyon kat sayısı denilen ve -1 ile 1 arasında değer alabilen bir kat sayı ile ifade eder. Örnek verilecek olunursa a ve b adında iki değişkenin regresyon ile ilişki analizinin sonucunda korelasyon kat sayısının 0,7 çıkması a değişkeninde olacak değişimin b'yi %70 etkileyeceği yani bu iki değişken arasındaki ilişkinin %70 olduğu anlamına gelmektedir. Korelasyon kat sayısının sıfır ya da sıfıra çok yakın değerler alması ise değişkenler arasında ilişki bulunmadığını gösterir. Bazı durumlarda değişkenler arasındaki ilişki ters ilişki de olabilmektedir. Böyle bir durumda korelasyon kat sayısı negatif değer alır. Bir önceki örnek baz alınacak olunursa korelasyonun -0,7 çıkması bu iki değişken arasındaki ilişkinin %70 olduğu ama a değişkenindeki artışın b'yi artış miktarının %70'i kadar azaltacağı anlamına gelmektedir.

Regresyonun güçlü yönleri temel olarak 3 ana başlıkta toplanabilir.

1. Tahmin Yeteneği: Regresyon analizi, veri setindeki değişkenler arasındaki ilişkileri anlama ve gelecekteki değerleri tahmin etme yeteneği ile öne çıkar. Bu özelliği sayesinde, ekonomi, finans, pazarlama, tıp, meteoroloji ve daha birçok alanda gelecek olayların tahmininde ve stratejik karar verme süreçlerinde kullanılır.
2. İlişki Analizi: Regresyon analizi, değişkenler arasındaki korelasyonu belirleme ve bu ilişkiyi nicel olarak ifade etme imkânı sunar. Bu sayede, potansiyel neden-sonuç ilişkileri ve değişkenlerin etkileri daha iyi anlaşılabilir.
3. Değişken Önemi Sıralaması: Regresyon analizi, bağımsız değişkenlerin bağımlı değişkene olan katkısını ölçerek, değişkenlerin önem sırasını belirleyebilir. Bu sayede, modelde hangi değişkenlerin daha etkili olduğu ve dikkate alınması gereken özelliklerin belirlenmesi sağlanır.

Regresyon analizi, doğal bilimlerden sosyal bilimlere, mühendislikten ekonomiye kadar birçok alanda yaygın olarak kullanılır. Sektör ve kullanım detayları şu şekildedir:

- **Ekonomi ve Finans:** Hisse senedi fiyatları, ekonomik büyüme, tüketici harcamaları gibi finansal ve ekonomik göstergelerin tahmininde; altın, dolar gümüş gibi değerlerin piyasa değerleri arasındaki ilişki analizinde kullanılır.
- **Pazarlama:** Müşteri satın alma davranışlarının analizi, reklamların satışlara etkisinin değerlendirmesi ve ileriki dönemlerin satış tahminlerini yapmak için kullanılır.
- **Sağlık ve Tıp:** Hastalıkların risk faktörlerinin belirlenmesi, bu faktörlerin birbirini ve asıl hastalığı nasıl tetiklediğinin analizi, tedavi sonuçlarının ve hastalık yayılımının tahminlemesinde kullanılır.
- **Çevre Bilimleri:** Çevresel faktörlerin birbiri ile ilişkisinin yanında su kalitesi, hava kirliliği ve iklim değişikliği gibi temel durumların üzerindeki etkilerini değerlendirmede kullanılır.
- **Mühendislik:** Malzeme dayanıklılığı, yapısal analiz ve kalite kontrol gibi alanlarda kullanılır. Ürünü etkileyen kriterlerin belirlenmesini sağlar, bu kriterlerin birbiri ve ürünle ilişkisini ortaya koyar.

Bu alanlar sadece birkaç örnek olup, regresyon analizi birçok farklı alanda verilerin analizinde ve değerlendirilmesinde güçlü bir araçtır. Tarihçesine bakıldığında istatistiksel bir yöntem olarak 19. yüzyılda geliştirilmiştir ve tarihçesi oldukça uzundur. Temelleri 19. yüzyılın ortalarında Sir Francis Galton ve Karl Pearson gibi istatistikçiler tarafından atılmış olup ilk başlarda en sık astronomi alanında yapılan gözlemlerin analizinde ve hata hesaplamalarında kullanılmıştır. Temel gelişim aşamaları ve önemli kilometre taşlarına bakıldığında oklar 19. yüzyılı gösterse de 18. yüzyılda Carl Friedrich Gauss ve Adrien-Marie Legendre, doğrusal regresyon yöntemine ulaşılmasına önemli katkılarda bulunmuşlardır. Gauss, en küçük kareler yöntemini geliştirmiş ve doğrusal regresyonunun gelişiminin önünü açmıştır. Legendre ise doğrusal regresyonun matematiksel temellerini incelemiştir. Bu temellerin atılmasının ardından regresyonun ortaya çıkışı 1886 yılında, İngiliz bilim insanı Sir Francis Galton, bir dizi aile üyelerinin boy uzunluklarını incelediği bir çalışma yaparken, ebeveynlerin boy uzunluğu ile çocuklarının boy uzunluğu arasında bir ilişki olduğunu gözlemesiyle başladı. Galton, bu ilişkiyi araştırdı ve ebeveynlerin boy uzunluklarının ortalamasına geri dönme eğilimine "regresyon" adını verdi. Bu terim, daha sonraki dönemlerde regresyon analizine verilen adın kaynağı oldu. Sonraki yıllarda Galton'ın çalışmalarından etkilenen Karl Pearson, regresyon analizini daha da

geliştirerek korelasyon kavramını tanıttı. 1895 yılında yayınladığı makalede, iki değişken arasındaki ilişkiyi ölçmek için Pearson korelasyon katsayısını tanımladı. Bu, regresyon analizindeki bağımlı ve bağımsız değişkenler arasındaki ilişkiyi ölçmek ve ifade etmek için kullanılan temel bir istatistiksel yöntem oldu. 20. Yüzyıla gelindiğinde Ronald A. Fisher, istatistik alanında önemli bir isim olmuş ve regresyon analizine katkılarda bulunmuştur. Fisher, "Ortalama Karelerin Farkı" (ANOVA) yöntemini geliştirerek regresyon analizinin sınıflandırma problemleri üzerindeki etkisini incelemiştir. Neyman-Pearson yaklaşımı ise hipotez testi ve en güçlü test kavramlarını regresyon analizine dahil etmiştir. 20. Yüzyılın ortalarında Alan Turing, yapay zekâ ve makine öğrenimi alanlarında önemli çalışmalar yapmıştır. Turing, "Turing testi" olarak bilinen kavramı geliştirerek, makinelerin insana benzer şekilde düşünebilmesini sağlamak için regresyon analizine dayalı algoritmaları incelemiştir. Bu zamana kadarki tüm gelişmeler doğrusal regresyon alanında olsa da 20. yüzyılın ikinci yarısında, regresyon analizinde nonparametrik yöntemler geliştirilmiş ve bu alandaki çalışmalar önem kazanmıştır. Epanechnikov, Nadaraya-Watson düğüm regresyon gibi nonparametrik regresyon yöntemleri veri dağılımının parametrik varsayımlara uymadığı durumlarda kullanılmış ve regresyon analizine daha esnek bir yaklaşım getirmiştir. Non-parametrik regresyon yöntemlerinin temellerinden biri de Gaussian pürüzsüzleştirme yöntemidir. 1940'larda ve 1950'lerde bu yöntem, sinyal işleme ve görüntü işleme gibi alanlarda yaygın olarak kullanılmıştır. 1964 yılında Nadaraya ve Watson, rassal gürültü içeren verileri yumuşatmak için yeni bir non-parametrik regresyon yöntemi geliştirdiler. Bu yöntem, kernel pürüzsüzleştirme olarak da bilinir ve bugün hala kullanılan temel non-parametrik regresyon yöntemlerinden biridir. 1970 ve 1980'lerde kernel regresyon yöntemleri, çeşitli istatistik ve makine öğrenimi alanlarında popülerlik kazanmıştır. Kernel regresyon yöntemleri, non-parametrik regresyon için çekirdek (kernel) fonksiyonlarını kullanarak veriye pürüzsüzleştirme uygulaması yapar. 20. yüzyıl boyunca istatistik biliminin ve matematiksel yöntemlerin gelişimiyle birlikte daha da ilerledi. İlk başta basit doğrusal regresyon yöntemi yaygın olarak kullanılırken, zamanla çoklu doğrusal regresyon, lojistik regresyon ve polinomial regresyon gibi farklı regresyon türleri de geliştirildi. Ayrıca, regresyon analizindeki hataların dağılımı ve önemli hipotez testleri gibi konularda da önemli ilerlemeler kaydedildi. 1980'lerde Cleveland tarafından geliştirilen Loess yöntemi, veriye daha esnek bir şekilde uyum sağlamak için yerel regresyon uygulaması yapar. Loess, çeşitli alanlarda veri analizi ve görselleştirmede yaygın olarak kullanılmaktadır. 1986 yılında Hastie ve Tibshirani tarafından önerilen Genelleştirilmiş Eklemler Modelleri (GAM), non-parametrik regresyon için yaygın bir yöntemdir. GAM, çeşitli

parametrik ve non-parametrik bileşenleri birleştirerek veri analizinde esneklik ve uyum sağlama yeteneği sunar. Non-parametrik regresyon yöntemleri, veri analizinde özellikle doğrusal olmayan yapıya sahip veri setlerini modellemek için etkili ve güçlü araçlar sağlar. Geliştirilen yöntemlerin çeşitliliği ve esnekliği sayesinde non-parametrik regresyon, birçok alanda veri analizinde ve kestirimde yaygın olarak kullanılmaktadır. 20. Yüzyılın sonlarına doğru ve 21. yüzyılın başlarında, regresyon analizi makine öğrenimi alanında da önemli bir yer edindi. Makine öğrenimi, büyük veri setlerinin analizinde ve tahmin yapmak için kullanılan algoritmaların geliştirilmesinde regresyon yöntemlerine dayanmaktadır. Bugün, regresyon analizi birçok alanda uygulama bulmuş ve istatistik ve makine öğrenimi alanlarının temel taşlarından biri haline gelmiştir. Sonuç olarak, regresyon analizi, istatistiksel düşünce ve matematiksel yöntemlerin birleşimiyle ortaya çıkmış ve zamanla geliştirilmiş önemli bir analiz yöntemidir. Galton ve Pearson gibi istatistikçilerin çalışmaları, regresyonun temellerinin atılmasına ve bu alanda ilerlemelere yol açmıştır. Günümüzde regresyon analizi, verilerdeki ilişkileri anlama, tahmin yapma ve modelleme gibi birçok alanda yaygın olarak kullanılan etkili bir araçtır ve birçok program aracılığıyla yapılabilmektedir. Regresyon yapılabilen yazılım ve programlardan bazıları şunlardır:

- R: R, açık kaynaklı ve istatistiksel hesaplamalar için yaygın olarak kullanılan bir programlama dilidir. R'da regresyon analizleri için çeşitli paketler ve fonksiyonlar bulunmaktadır, örneğin "lm()" fonksiyonu doğrusal regresyon yapmak için kullanılırken, "glm()" fonksiyonu genelleştirilmiş lineer modeller (GLM) için kullanılır.
- Python: Python, çok amaçlı bir programlama dilidir ve veri analizi, makine öğrenimi ve regresyon analizleri için popüler kütüphanelere sahiptir. SciPy, NumPy, Pandas ve Statsmodels gibi kütüphaneler ile regresyon analizleri yapılabilmektedir.
- SPSS: SPSS (Statistical Package for the Social Sciences), istatistiksel analizler için kullanılan bir yazılımdır. SPSS, kullanıcı dostu arayüzü ile özellikle sosyal bilimler alanında yaygın olarak kullanılmaktadır.
- SAS: SAS (Statistical Analysis System), çeşitli istatistiksel analizler yapabilen ve büyük veri setlerini işleyebilen bir yazılımdır. SAS, özellikle sağlık, finans ve endüstriyel alanlarda kullanılmaktadır.
- STATA: STATA, istatistiksel analizler için kullanılan bir yazılımdır ve ekonometri ve sosyal bilimlerde yaygın olarak kullanılır.

- Excel: Microsoft Excel, basit regresyon analizleri yapabilen ve genellikle kullanıcı dostu arayüzü sayesinde sıkça kullanılan bir elektronik tablo programıdır.
- JMP: JMP, istatistiksel analizler ve veri görselleştirmesi için kullanılan bir yazılımdır. Özellikle endüstriyel ve bilimsel araştırmalarda sıkça tercih edilir.
- MATLAB: MATLAB, sayısal hesaplamalar ve veri analizi için kullanılan bir programlama dili ve yazılım ortamıdır. Regresyon analizlerini kolayca gerçekleştirmek için özel fonksiyonlar ve araçlar sağlar.

Regresyonun uygulanacak gerinin çeşidine göre birçok çeşidi olup detaylar aşağıdaki gibidir.

2.3.6.1. Doğrusal Regresyon

Doğrusal regresyon, regresyon analizinin en yalın formudur. Bu analizde bağımlı değişkeni (outcome) bağımsız değişkenlere (predictors) bağlı olarak modellemek için kullanılan formül, doğrusal regresyon için aşağıdaki gibidir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_i X_i + \varepsilon \quad (2.4)$$

Burada:

Y: bağımlı değişkenin değeri (tahmin edilmek istenen değer).

β_0 : sabit (intercept) terimi, bağımsız değişkenlerin tümü sıfır olduğunda Y'nin alacağı değer.

$\beta_1, \beta_2, \dots, \beta_i$: bağımsız değişkenlerin katsayıları, bağımsız değişkenlerin etkisini belirleyen değerler.

$X_1, X_2, \dots, X_i$: bağımsız değişkenlerin değerleri.

ε : hata terimi (error term), modelin gerçek değerler ile tahmin edilen değerler arasındaki farkı ifade eden hata bileşeni.

Uygulama aşamaları şu şekildedir:

İlk adım, veri setinin hazırlanması ve bağımsız değişkenlerin standartlaştırılmasıdır. Bağımsız değişkenler arasındaki büyüklük farklılıkları, modelin performansını olumsuz etkileyebilir. Bu nedenle, değişkenlerin ortalama sıfır ve standart sapması bir olacak şekilde standartlaştırılır. Daha sonra model parametreleri (modeldeki katsayılar) ($\beta_0, \beta_1, \beta_2, \dots, \beta_i$) ve sabit terim (β_0) hesaplanır. Bu parametreler, veri setindeki değişkenler arasındaki ilişkiyi ifade eden modelin matematiksel tanımlarıdır. Katsayılar, regresyon analizini gerçekleştiren matematiksel yöntemler veya optimizasyon algoritmaları kullanılarak belirlenir. Bu belirmenin ardından

kullanılan modelin uygunluğu değerlendirilir. Modelin performansını değerlendirmek için çeşitli istatistiksel metrikler ve testler kullanılır. R-kare (coefficient of determination), ortalama kare hatası (mean squared error), F-testi gibi yöntemlerle modelin ne kadar iyi verilere uyarlandığı ve tahmin gücünün nasıl olduğu belirlenir. Daha sonra modelin tahmin ettiği değerler ile gerçek veriler arasındaki farklar incelenerek hata analizi yapılır. Hataların normal dağılıma uygunluğu ve homoscedasticity (varyansın sabit olması) incelenir. Eğer hatalar belirli bir düzen içeriyorsa veya normal dağılmıyorsa, modelin iyileştirilmesi için düzeltmeler yapılabilir. Regresyon analizi, bağımsız değişkenlerin bağımlı değişkene katkısını değerlendirmek için kullanılır. Değişken önemi, katsayıların mutlak değerleri veya t-testleri gibi yöntemlerle belirlenir. Bu, modelde hangi değişkenlerin daha etkili olduğunu ve modelin güvenilirliğini artırmak için hangi değişkenlere odaklanılması gerektiğini gösterir. Modelin uygunluğu ve parametreleri belirlendikten sonra, model gelecekteki değerleri tahmin etmek için kullanılabilir. Yeni veri noktaları üzerinde modeli kullanarak bağımlı değişkenin tahmin edilen değerleri elde edilir.

Doğrusal regresyon analizi birçok alanda güçlü bir araç olmasına rağmen, bazı durumlarda yetersiz kalabilir veya etkinliği sınırlı olabilir. Yetersiz kaldığı bazı alanlar şunlardır:

Doğrusal Olmayan İlişkiler: Regresyon analizi, temel olarak değişkenler arasındaki doğrusal ilişkiyi modellemeye odaklanır. Ancak, bazı durumlarda değişkenler arasındaki ilişki doğrusal değildir ve regresyon modeli bu tür karmaşık ilişkileri yeterince ifade edemez. Doğrusal olmayan ilişkilere sahip veriler için, doğrusal olmayan regresyon yöntemleri veya diğer makine öğrenimi teknikleri daha uygun olabilir.

Yüksek Boyutlu Veri Kümeleri: Regresyon analizi, yüksek boyutlu veri kümelerindeki değişkenler arasındaki ilişkiyi anlamak ve tahmin yapmak için zaman ve hafıza açısından verimli olmayabilir. Yüksek boyutlu veri kümelerinde, modelin karmaşıklığı artabilir ve aşırı uyum riski yükselir. Bu tür durumlarda, boyut azaltma ve değişken seçimi gibi yöntemlerle veri kümesinin boyutunu düşürmek veya daha karmaşık modeller kullanmak gerekebilir.

Aşırı Uyum (Overfitting) Sorunu: Regresyon analizinde, eğitim veri kümesine aşırı uyum sağlanması, modelin yeni verilere genelleme yapma yeteneğini olumsuz etkileyebilir. Özellikle çok sayıda bağımsız değişkenin olduğu durumlarda veya veri noktalarının az olduğu durumlarda aşırı uyum riski artar. Bu nedenle, aşırı uyumu engellemek için modelin basitleştirilmesi veya düzenlenmesi gerekebilir.

Çoklu Doğrusal Bağlantı: Regresyon analizinde, bağımsız değişkenler arasında yüksek düzeyde ilişki olduğunda (çoklu doğrusal bağlantı), modelin güvenilirliği azalabilir. Bu durumda, tahmin edici gücün artırılması ve değişkenlerin etkisini daha doğru bir şekilde belirlemek için çözümler bulmak gerekebilir.

Değişen Varyans: Regresyon analizi, değişen varyanslara sahip verilerle de başa çıkmakta zorlanabilir. Varyansın değiştiği durumlarda, modelin performansı düşebilir ve tahmin edilen değerlerde yanıltıcı sonuçlar alınabilir.

Bu yetersizliklerden dolayı regresyon analizini desteklemek için başka yöntemlerle birleştirmek gerekebilir. Özellikle doğrusal olmayan ilişkiler veya yüksek boyutlu veri kümeleri gibi durumlarda alternatif yöntemlere başvurmak önemli olabilir. Birkaç yöntemin bir arada kullanılsa dahi çözüm sağlamayan problemler doğrusal regresyonun yanında farklı çeşitte daha komplike çalışan regresyon analizlerinin ortaya çıkmasını sağlamıştır. Doğrusal olmayan regresyon, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin doğrusal olmadığı durumlarda kullanılır ve farklı yöntemlerle ifade edilir. Polinom, logaritmik, üstel ve logaritmik regresyon gibi çeşitleri vardır.

Non-parametrik regresyon, parametrik olmayan bir yaklaşım ile veri analizini gerçekleştiren bir regresyon yöntemidir. Bu yöntemde, veri setinin dağılımına ve yapısal özelliklerine ilişkin kesin varsayımlar yapılmadan, veriye daha esnek bir şekilde uyum sağlamaya çalışılır. Non-parametrik regresyonun ortaya çıkışı ve gelişimi, istatistik ve matematik alanındaki birçok araştırmacının katkıları ile şekillenmiştir.

2.3.6.2. Polinom Regresyon

Polinom regresyonu, regresyon analizinin temel bir uzantısıdır ve 18. yüzyıl matematikçisi Carl Friedrich Gauss tarafından ortaya atılmıştır. Polinom regresyonu, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi daha esnek bir şekilde ifade etmek için polinomlar kullanır. Polinom regresyonu, düz bir çizgi veya doğru ile ifade edilemeyen verilerin modellenmesi için kullanılmaktadır.

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \dots + \beta_n X^n + \varepsilon \quad (2.5)$$

Burada X^2 , X^3 , ... X^n gibi bağımsız değişkenlerin kuvvetleri polinom dereceleri olarak ifade edilir. Polinom regresyon, doğrusal olmayan yapıları yakalamak için düşük ve yüksek dereceli polinomlar kullanır.

Polinom regresyonu, doğrusal olmayan yapıya sahip verilerin modellemesi için uygun bir yöntemdir. Doğrusal regresyon, bağımsız değişkenlerin birinci dereceden (doğrusal) olduğu durumlar için etkili olsa da bazı veri setleri düz bir çizgi ile açıklanamaz. Bu gibi durumlarda, polinom regresyonu kullanılarak veriler daha esnek bir yapıda modellemeye imkân sağlar. Uygun olduğu durumlara bakıldığında verilerin doğrusal bir ilişkiye uymadığı, ancak daha karmaşık bir eğri veya eğrisel yapı olduğu durumlar polinom regresyonu için uygun olabilir. Düşük dereceli polinomlar, basit eğrisel yapıları modellemek için kullanılırken, yüksek dereceli polinomlar daha karmaşık veri yapılarını yakalamak için kullanılabilir. Ayrıca düz bir çizgi veya düzlemle açıklanamayan verilerde, polinom regresyonu daha iyi sonuçlar verebilir.

Polinom regresyonun güçlü yönleri incelenecek olunursa esneklik polinom regresyonun güçlü yönlerinin başında gelmektedir. Verilerin doğrusal olmayan ilişkilerini modellemek için yüksek esneklik sağlar, farklı polinom dereceleri seçerek veriye uygun eğriler elde etmek mümkündür. Ayrıca uyumluluğunun yüksek olması da bir diğer güçlü yönüdür. Doğrusal regresyon ile açıklanamayan veya düz bir çizgiyle ifade edilemeyen veri yapıları, esnek olmasıyla polinom regresyonu ile daha iyi açıklanabilir. Son olarak yüksek dereceli yaklaşımı da diğer polinom türlerine göre fark yaratan bir özelliktir. Yüksek dereceli polinomlar, doğrusal regresyonun sınırlarını aşarak eğrilere uyum sağlama yeteneğine sahiptir. Bu yönlerin yanı sıra polinom regresyonun en büyük handikapı da yine bu yüksek dereceli polinomlardır. Yüksek dereceli polinomlar, modelin karmaşıklığını artırarak parametreleri belirlemeyi zorlaştırabilir ve modelin yorumlanabilirliğini azaltabilir. Polinom regresyonu, doğrusal olmayan yapıya sahip verilerin modellemesi için önemli bir araçtır. Ancak, uygun polinom derecesini seçmek ve aşırı uyum gibi sorunlara dikkat etmek önemlidir. Diğer doğrusal olmayan regresyon teknikleri ve düzeltme yöntemleri, polinom regresyonun zayıf yönleriyle başa çıkma konusunda yardımcı olabilir. Veri eksikliği ve aşırı uyum sorunu da her çeşit regresyonun verimini düşürdüğü gibi polinom regresyonun da verimini baltalar.

Polinom regresyonun açık formülü şu şekildedir:

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \beta_3 X^3 + \dots + \beta_n X^n + \varepsilon \quad (2.5)$$

Burada:

- **Y:** bağımlı değişkenin değeri (tahmin edilmek istenen değer).
- **β_0 :** sabit (intercept) terimi, bağımsız değişkenlerin tümü sıfır olduğunda Y'nin alacağı değer.

- $\beta_1, \beta_2, \dots, \beta_n$: bağımsız değişkenlerin katsayıları, bağımsız değişkenlerin etkisini belirleyen değerler.
- X : bağımsız değişkenin değeri.
- ϵ : hata terimi (error term), modelin gerçek değerler ile tahmin edilen değerler arasındaki farkı ifade eden hata bileşeni.

Polinom regresyonu, doğrusal olmayan yapıya sahip verilerin modellenmesi için kullanılır. Doğrusal regresyon, bağımsız değişkenlerin birinci dereceden olduğu (yani X , X^2 , X^3 , gibi yüksek dereceli terimler içermediği) durumlar için uygun olsa da bazı veri setleri düz bir çizgi ile açıklanamaz ve polinom regresyonu daha esnek bir modelleme yöntemi sunar.

Polinom regresyonun açık formülü, bağımsız değişkenin kuvvetleriyle ifade edilen terimleri içerir. Bu terimler, polinom derecesine göre artar veya azalır. Örneğin, ikinci dereceden bir polinom regresyonunda ($n=2$), formülde X^2 terimi bulunurken, üçüncü dereceden bir polinom regresyonunda ($n=3$), formülde X^3 terimi de yer alır. Polinom regresyonda, polinomun derecesi, veri kümesine en iyi uyan ve veriyi en iyi açıklayan polinomu seçmek için belirlenmelidir. Polinomun derecesini belirlemenin birkaç farklı yöntemi vardır ve bu yöntemler veri kümesine ve probleme bağlı olarak değişebilir. Bu noktada polinom regresyonunda derecenin belirlenmesi için yaygın kullanılan yöntemler şunlardır:

1. Görsel Değerlendirme: İlk adım olarak, veri kümesini görselleştirmek ve polinom derecesini tahmin etmek için scatter plot (noktalı grafik) veya line plot (çizgi grafiği) gibi görsel araçlar kullanılabilir. Verilerin şekline ve dağılımına bakarak, veri kümesinin düz çizgiyle mi yoksa eğrisel bir yapı ile mi uyum sağladığı değerlendirilir.
2. Karmaşıklık-Kayıp (Complexity-Loss) Eğrisi: Farklı polinom derecelerini kullanarak polinom regresyon modellerini oluşturmak ve bunların performansını ölçmek için karmaşıklık-kayıp eğrisi kullanılabilir. Bu eğri, polinom derecesi ile modelin kayıp fonksiyonu (örneğin ortalama kare hatası) arasındaki ilişkiyi gösterir. Derecenin artmasıyla modelin eğitim verisine olan uyumu artar, ancak aşırı uydurma (overfitting) riski de artar. Eğri üzerinde, aşırı uyumun olmadığı ve kaybın düşük olduğu optimum derece seçilebilir.
3. Cross-Validation (Çapraz Doğrulama): Veri kümesini eğitim ve test alt kümelerine bölmek ve farklı polinom dereceleri için performansı karşılaştırmak için çapraz doğrulama yapılabilir. Çapraz doğrulama, modelin genelleme yeteneğini değerlendirir ve aşırı uydurmayı önlemeye yardımcı olur. En iyi derece, çapraz doğrulama hatasının en düşük olduğu derece olarak seçilebilir.

4. Bilgi Kriterleri: AIC (Akaike Information Criterion) ve BIC (Bayesian Information Criterion) gibi bilgi kriterleri, modelin karmaşıklığı ile veri uyumu arasındaki dengeyi sağlamak için kullanılabilir. Bu kriterler, modelin karmaşıklığını düzenlemek ve aşırı uyum riskini azaltmak için kullanılabilir.

Bu yöntemlerden herhangi biri veya birkaçı kullanılarak, polinom regresyonda uygun derece seçilebilir. Derece seçimi, aşırı uyumdan kaçınmak ve modelin genelleme yeteneğini artırmak açısından önemlidir. Ancak, veri kümesinin özelliklerine ve problem alanına bağlı olarak, derece seçimini doğru bir şekilde yapmak için dikkatli değerlendirme ve analiz gereklidir.

Polinom regresyon, düz bir çizgi ile açıklanamayan veri yapılarını modellemek için kullanılabilecek güçlü bir yöntemdir. Ancak, yüksek dereceli polinomlar, aşırı uyum (overfitting) sorununa yol açabilir ve modelin yeni verilere genelleme yapma yeteneğini olumsuz etkileyebilir. Bu nedenle, polinom derecesi seçerken dikkatli olunmalı ve veri setinin özelliklerine göre uygun bir derece belirlenmelidir. Ayrıca, veri eksikliği veya düzensiz veri dağılımları gibi diğer zorluklara da dikkat edilmelidir.

2.3.6.3. Logaritmik Regresyon

Logaritmik regresyon, non-parametrik regresyon analizinin bir türü olup bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi logaritmik bir eğri ile modellemek için kullanılır. Logaritmik regresyon, bağımlı değişkenin logaritmik dönüşümü ile doğrusal hale getirilir ve daha sonra doğrusal regresyon gibi standart yöntemler kullanılarak model oluşturulur. Özellikle bağımlı değişkenin değerleri arasında hızlı değişimlerin olduğu durumlar veya doğrusal olmayan ilişkilerin olduğu veri setleri için tercih edilen bir modelleme yöntemidir. Ancak, veri setinin özellikleri ve bağımlı değişkenin yapısı göz önünde bulundurularak uygunluğu dikkatlice değerlendirilmelidir.

Logaritmik regresyon, ilk olarak matematikçi Carl Friedrich Gauss tarafından 18. yüzyılda ortaya atılmıştır. Logaritmik regresyon, bağımsız değişkenin değerleri arttıkça bağımlı değişkenin nasıl değiştiğini modellemek için kullanılır. Bu tür bir değişken dönüşümü, bazı veri setlerinde bağımlı değişkenin düzensiz bir şekilde arttığı veya azaldığı durumlarda faydalı olabilir.

Logaritmik regresyonun spesifik özellikleri şunlardır:

- **Logaritmik Dönüşüm:** Logaritmik regresyon, bağımlı değişkenin doğal logaritmasını alarak bağımlı değişkenin değerlerini dönüştürür. Bu dönüşüm sayesinde, bağımlı değişkenin

değerleri arttıkça hızla değiştiği durumlar veya doğrusal olmayan ilişkiler daha iyi modellenenebilir.

- Doğrusallaştırma: Logaritmik dönüşüm, bazı veri setlerinde doğrusal olmayan yapıları doğrusal hale getirir. Böylece, logaritmik regresyon, doğrusal regresyon gibi standart yöntemlerle kullanılabilir.
- Değerleri Sınırlama: Logaritmik regresyon, bağımlı değişkenin değerlerini sınırlamak için faydalı olabilir. Özellikle, bağımlı değişkenin değerleri yüksek olduğunda veya sıfıra yaklaştığında, logaritmik dönüşüm ile değerlerin sınırlanması mümkündür.
- Hızlı Değişimlerin Modellemesi: Logaritmik regresyon, bağımlı değişkenin değerleri hızlı bir şekilde değiştiren durumlar için etkili bir modelleme yöntemidir. Örneğin, ekonomik büyüme, nüfus artışı gibi durumlar logaritmik regresyon ile daha iyi modellemeye uygun olabilir.
- Eksik Verilerle Uyum: Logaritmik regresyon, eksik verilerle uyum sağlama konusunda doğrusal regresyona göre daha esnek bir yöntemdir. Eğer bağımlı değişkenin değerleri sıfıra yaklaşıyorsa, logaritmik dönüşüm ile eksik verilerin modellenmesi kolaylaşabilir.
- Model Yorumlanabilirliği: Logaritmik regresyon, doğal logaritma dönüşümü nedeniyle modelin katsayılarının yorumlanabilirliğini etkileyebilir. Bu nedenle, model sonuçlarının ve katsayıların yorumlanmasında dikkatli olunmalıdır.

$$Y = \beta_0 + \beta_1 * \log(X) + \varepsilon \quad (2.6)$$

Burada:

- Y: bağımlı değişkenin değeri (tahmin edilmek istenen değer).
- β_0 : sabit (intercept) terimi, bağımsız değişkenlerin tümü sıfır olduğunda Y'nin alacağı değer.
- β_1 : bağımsız değişkenin logaritması ile çarpılan katsayı, bağımsız değişkenin etkisini belirleyen değer.
- $\log(X)$: bağımsız değişkenin doğal logaritması.
- ε : hata terimi (error term), modelin gerçek değerler ile tahmin edilen değerler arasındaki farkı ifade eden hata bileşeni.

Logaritmik regresyon, bağımlı değişkenin değerlerinin logaritması ile bağımsız değişkenler arasında doğrusal bir ilişki kurmak için kullanıldığından, verilerin doğrusal olmayan ilişkileri daha iyi modellemeye yardımcı olabilir. Ancak, logaritmik regresyonun uygunluğu, veri setinin

özelliklerine ve bağımlı değişkenin yapısına bağlı olarak dikkatli bir şekilde değerlendirilmelidir.

2.3.6.4. Üstel Regresyon

Üstel regresyon, bağımsız değişkenlerin üstel fonksiyonlarını kullanarak doğrusal olmayan ilişkileri modellemek için kullanılan nonparametrik bir regresyon analizi çeşididir ve bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi üstel bir eğri ile modellemek için kullanılır. İlk olarak bağımlı değişkenin üstel fonksiyonu ile doğrusal hale getirilir ve daha sonra doğrusal regresyon gibi standart yöntemler kullanılarak model oluşturulur. Bu tür regresyon, bağımlı değişkenin değerlerinin hızla arttığı durumlar veya hızlı büyüme gösteren veriler için kullanışlıdır. Özellikle bağımlı değişkenin değerleri hızla büyüyen veya azalan bir yapı gösteriyorsa, üstel regresyon bu tür verileri daha iyi modelleyebilir. Bu özellik logaritmik regresyon ile karıştırılmamalıdır. Üstel regresyon, bağımlı değişkenin bağımsız değişkenlerin üstel fonksiyonu olarak artış veya azalış gösterdiği durumlar için kullanılırken, logaritmik regresyon, bağımlı değişkenin bağımsız değişkenlerin logaritması olarak artış veya azalış gösterdiği durumlar için kullanılır. Her iki regresyon türü de bağımlı ve bağımsız değişkenler arasındaki ilişkiyi modellemek için lineer regresyon temel alınarak yapılır. Bu nedenle, eğer bağımlı değişken üstel olarak artıyorsa üstel regresyon kullanılırken, logaritmik olarak artıyorsa logaritmik regresyon tercih edilir.

$$Y = \beta_0 * e^{(\beta_1 X)} + \varepsilon \quad (2.7)$$

Burada:

- Y: bağımlı değişkenin değeri (tahmin edilmek istenen değer).
- β_0 : sabit (intercept) terimi, bağımsız değişkenlerin tümü sıfır olduğunda Y'nin alacağı değer.
- β_1 : bağımsız değişkenin katsayısı, bağımsız değişkenin etkisini belirleyen değer.
- e: doğal logaritma tabanı olan Euler sayısı (yaklaşık değeri 2.71828).
- X: bağımsız değişkenin değeri.
- ε : hata terimi (error term), modelin gerçek değerler ile tahmin edilen değerler arasındaki farkı ifade eden hata bileşeni.

Üstel regresyonun uygulanışı için genellikle en küçük kareler yöntemi kullanılır. Bu yöntem, verilerin hatasız bir üstel modele ne kadar yakın olduğunu hesaplar ve katsayıları tahmin eder. Aşağıdaki adımlarla üstel regresyon uygulanır:

1. Veri Toplama: İlgili bağımlı değişken (Y) ve bağımsız değişken (X) değerlerini içeren bir veri kümesi toplanır.
2. Veri Düzenleme: Gerekliyse, veri kümesindeki eksik veya anormal değerler düzenlenir veya çıkarılır.
3. Regresyon Katsayılarını Bulma: Veri kümesi kullanılarak regresyon katsayıları a ve b hesaplanır. Bu hesaplamalar genellikle istatistiksel hesaplama yöntemleri veya optimizasyon algoritmaları kullanılarak yapılır. Kat sayılarının hesaplanmasında ilk olarak veri kümesindeki bağımlı değişken (Y) ve bağımsız değişken (X) değerlerini toplu olarak alınır. Veri kümesindeki her bir veri çiftini (X, Y) üstel regresyon modeline yerleştirerek Y değerlerini tahmin edilir (Y_tahmin). Daha sonra gerçek Y değerleri ile tahmin edilen Y değerleri arasındaki hata karelerini bulunur ve bu hata karelerinin toplamını hesaplanır.

$$\text{Hata_kareleri_toplamı} = \sum(Y - Y_{\text{tahmin}})^2 \quad (2.8)$$

Hata karelerinin toplamını minimize edecek a ve b katsayılarını bulmak için optimizasyon yöntemleri kullanılır. Bu, genellikle gradyan inişi veya normal denklemler gibi yöntemlerle yapılır. En iyi a ve b katsayılarının bulunmasıyla üstel regresyon modeli hazır olur:

$$Y = a * \exp(b * X) \quad (2.9)$$

Elde edilen a ve b katsayıları, veri kümesine en uygun üstel regresyon modelini temsil eder ve bu model, veriyi en iyi açıklayan üstel ilişkiyi yansıtır. Hesaplamalar genellikle istatistiksel yazılımlar veya programlama dilleri aracılığıyla yapılır.

4. Üstel Regresyon Modelinin Oluşturulması: Elde edilen regresyon katsayıları kullanılarak üstel regresyon modeli oluşturulur ve bağımlı değişkenin bağımsız değişkenlere göre üstel ilişkisini ifade eder.
5. Modelin Değerlendirilmesi: Oluşturulan üstel regresyon modeli, veri kümesine uygunluğu ve performansı açısından değerlendirilir. Modelin ne kadar iyi uyum sağladığı ve gerçek verileri ne kadar iyi açıkladığı değerlendirilir.
6. Modelin Kullanımı: Başka bağımlı değişken ve bağımsız değişken değerleri için üstel regresyon modeli kullanılarak tahminler yapılabilir ve gelecekteki değerleri tahmin etmek için kullanılabilir.

Üstel regresyon, özellikle doğal büyüme, yıkım veya çürüme gibi süreçlerin modellenmesi için uygundur. Ayrıca, diğer regresyon yöntemleri ile modellenmesi zor olan veri yapılarında ve fenomenlerde de kullanılabilir. Uygulama aşamasında, veri kümesinin özelliklerine ve analiz ihtiyacına göre doğru bir şekilde uygulanmalı ve modelin performansı dikkatli bir şekilde değerlendirilmelidir. Hızlı büyüme veya azalma ilişkilerini yakalama üstel regresyonun temel

spesifik özelliğidir. Bağımlı değişkenin değerlerinin hızlı bir şekilde arttığı veya azaldığı veri setlerini modellemek için etkili bir yöntemdir. Hızlı büyüme veya azalma gösteren verileri doğrusal olmayan bir yapı ile modellemek için üstel regresyon kullanmak uygun olabilir. Üstel regresyon, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi doğrusal olmayan bir eğri ile modellemek için kullanılır. Bu nedenle, diğer regresyon türleri olan doğrusal, polinom ve logaritmik regresyonlardan farklı olarak, üstel regresyon daha esnek bir yapıya sahiptir. Ayrıca doğal logaritma tabanı kullanımı ile üstel regresyon, bağımlı değişkenin değerlerini e^x şeklinde ifade eder ve doğal logaritma tabanı olan "e"yi kullanır. Bu özelliği ile diğer regresyon türlerinden ayrılır. Bir diğer spesifik özelliği de hata dağılımı noktasındadır. Üstel regresyonda, hata terimi (error term) normal dağılım yerine log-normal dağılım olarak kabul edilir. Bu da hata terimi için farklı istatistiksel özelliklere sahip bir varsayım içerir.

2.3.6.5. Lojistik Regresyon

Lojistik regresyon, bir bağımlı değişkenin ikili sınıflandırma (binary classification) problemi olduğu durumlarda kullanılan bir makine öğrenimi ve istatistik yöntemidir. Bağımlı değişkenin değeri 0 veya 1 gibi iki kategoriye ait olduğu durumlarda, lojistik regresyon modeli kullanılarak olasılık değerleri hesaplanır ve bu değerlere göre veri örneklerinin hangi sınıfa ait olduğu tahmin edilir. Çıktı değerleri 0 ile 1 arasında olasılık değerleridir ve genellikle 0.5 eşik değeri kullanılarak tahminler yapılır (0.5'in altında 0, 0.5 ve üstünde 1 olarak kabul edilir).

Tarihçesine bakıldığında lojistik regresyon, 1940'larda ikili sınıflandırma problemleri için tasarlanmış olup biyometri ve tıp alanında kullanılmaya başlanmıştır. İlk olarak ekonometri alanında kullanılan lojistik regresyon, daha sonra istatistiksel sınıflandırma problemlerinin çözümünde önemli bir araç haline gelmiştir.

Lojistik regresyon, doğrusal regresyon modelinden farklı olarak, lojistik (sigmoid) fonksiyonu ile bağımlı değişkenin değerini sınırlar. Bu nedenle, lojistik regresyon modeli doğrusal olmayan bir yapıya sahiptir. Lojistik regresyon modeli, bağımsız değişkenlerin katsayılarına göre sınıflandırma işlemini gerçekleştirir ve bu katsayılar modelin öğrenilmesi sürecinde belirlenir.

Kullanım alanları şu şekildedir:

- Tıp alanında hastalık teşhisi (örneğin kanser teşhisi), ilaç testleri ve hastalık riski tahmini gibi alanlarda kullanılır.
- Pazarlama ve reklamcılıkta müşteri davranışlarını analiz etmek ve müşteri segmentasyonu yapmak için kullanılır.

- Bankacılık ve finans alanında kredi değerlendirmesi, dolandırıcılık tespiti ve risk analizi gibi uygulamalarda kullanılır.
- Endüstri mühendisliğinde ürün kalitesi kontrolü ve üretim hatalarının tespiti gibi alanlarda kullanılır.

Lojistik regresyon modeli, lojistik (sigmoid) fonksiyonu ile bağımlı değişkenin değerini sınırlayan bir yapıya sahiptir. Formülü aşağıdaki gibidir:

$$p = 1 / (1 + \exp(-z)) \quad (2.10)$$

Burada:

p: bağımlı değişkenin 1 (pozitif sınıf) olma olasılığını temsil eder.

z: bağımsız değişkenlerin katsayıları ile çarpılmış ve birleştirilmiş hali olan lineer fonksiyonu ifade eder.

Lojistik regresyon modelinde, genellikle en küçük kareler yöntemi veya maksimum olabilirlik (maximum likelihood) yöntemi kullanılarak bağımsız katsayıları bulunur. Bu katsayılar belirlendikten sonra, veri kümesindeki yeni bağımsız değişken değerleri için lojistik fonksiyonu kullanılarak olasılık değerleri hesaplanır. Eşik değeri (genellikle 0.5) kullanılarak, bu olasılık değerlerine göre veri örneklerinin hangi sınıfa ait olduğu tahmin edilir.

2.3.7. Makine Öğrenmesi Metotları

2.3.7.1. *Principal Component Analysis (Temel Bileşenler Analizi)*

PCA, çok değişkenli veri setlerinin boyutunu azaltmak ve içerdikleri bilgiyi özetlemek için kullanılan bir istatistiksel tekniktir. Temel olarak, PCA, orijinal değişkenler arasındaki korelasyonu dikkate alarak yeni bir değişken seti oluşturur. Bu yeni değişkenler, orijinal verilerdeki değişkenliğin büyük bir kısmını korurken, boyutu azaltır. Birçok alanda kullanılan bir veri analizi yöntemi olsa da özellikle, veri görselleştirme, veri sıkıştırma ve boyut indirgeme, gürbüz veri analizi ve veri ön işleme gibi alanlarda sıkça tercih edilir. Ayrıca, çeşitli makine öğrenimi ve veri madenciliği uygulamalarında da yaygın olarak kullanılır. Bu faydaların anlam ve etki alanına bakılacak olunursa ilk olarak boyut indirgeme çok boyutlu veri setlerinde boyutu azaltarak veri analizini kolaylaştırır. Yüksek boyutlu veri setlerinde, gereksiz bilgi ve gürültüyü filtreleyerek daha anlamlı bileşenlere odaklanmayı sağladığından dolayı boyut azaltma özelliği en önemli faydası olarak öne çıkmaktadır. Benzer olarak verileri sıkıştırabilme kabiliyetiyle de verilerin boyutunu azaltarak depolama ve iletim maliyetlerini

düşürür. Aynı zamanda, sıkıştırılmış veriler üzerinde işlemlerin hızını artırır. Makine öğrenmesinin temel kullanım alanı olan veri görselleştirme de PCA ile sağlanabilir. Çok boyutlu verilerin görselleştirilmesini kolaylaştırır, iki veya üç temel bileşeni kullanarak verileri bir grafik üzerinde temsil etmek, veri setindeki yapıyı ve desenleri daha iyi anlamayı sağlar. Ayrıca gürbüz veri analizi yapabilen PCA, veri setindeki anormallikleri veya aykırı değerleri belirlemek için kullanılabilir. Aykırı değerler, temel bileşenlerde anormal bir davranışa yol açar ve bu sayede tespit edilebilirler. Veri ön işleme özelliği ile PCA, makine öğrenimi veya veri madenciliği uygulamaları öncesinde veri setinin önceden işlenmesinde kullanılabilir. Gürültüyü azaltmak, korelasyonu dikkate almak veya çoklu kolinearlik sorununu çözmek gibi çeşitli ön işleme adımlarında etkili bir araçtır. Bu temel kullanım alanlarının dışında da sıklıkla kullanılan PCA, finans, biyoloji, görüntü işleme, doğal dil işleme ve daha birçok alanda başarıyla kullanılmaktadır.

PCA, temel prensip olarak veri setindeki değişkenler arasındaki ilişkiyi temsil eden yeni bir koordinat sistemi oluşturur. Bu yeni koordinat sisteminde, ilk bileşen (PC1), orijinal verilerdeki en fazla varyansı açıklayan bileşendir. İkinci bileşen (PC2), PC1'e dik olan yönde yer alır ve kalan varyansın en fazla kısmını açıklar. PCA, bu şekilde orijinal veri setinin tüm bileşenlerini sıralar ve varyansın azaldığı her bir bileşeni ekler.

PCA'nın çalışma adımları şu şekilde özetlenebilir:

- Veri setinin standartlaştırılması: PCA, veri setindeki her bir değişkenin ortalamasını sıfır, standart sapmasını ise bir yaparak başlar. Bu adım, verilerin ölçeklendirilmesini ve değişkenler arasında uygun bir karşılaştırma yapılmasını sağlar.
- Kovaryans matrisinin hesaplanması: Standartlaştırılmış veri seti kullanılarak kovaryans matrisi hesaplanır. Kovaryans, değişkenler arasındaki ilişkiyi ölçen bir istatistiksel terimdir.
- Özdeğer ve özvektör analizi: Kovaryans matrisi özdeğer ve özvektör analizine tabi tutulur. Özdeğerler, kovaryans matrisinin karakteristik kökleridir ve veri setindeki değişkenliğin miktarını temsil eder. Özvektörler ise bu değişkenliği açıklayan bileşenlerin yönünü temsil eder.
- Temel bileşenlerin seçimi: Özdeğerler sıralandıktan sonra, en yüksek özdeğere sahip olan bileşenler seçilir. Bu bileşenler, veri setindeki değişkenliğin büyük bir kısmını açıklar.
- Yeni veri setinin oluşturulması: Seçilen temel bileşenler kullanılarak yeni bir veri seti oluşturulur. Bu veri seti, boyutu azaltılmış ve orijinal verilerin büyük bir kısmını koruyan bilgiyi içerir.

2.3.7.2. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin işleyişinden esinlenen ve karmaşık problemleri çözmek için kullanılan güçlü bir hesaplama modelidir. Paralel hesaplama yetenekleri ve öğrenme yetenekleri sayesinde birçok alanda büyük başarılar elde etmiştir.

Çıkış noktasına bakıldığında yapay sinir ağlarına olan ilgi, sinirbilim alanındaki çalışmalardan kaynaklanmaktadır. Sinir hücrelerinin (nöronlar) çalışma prensipleri ve sinir ağlarının bilgi işleme yetenekleri, YSA'ların temelini oluşturmuştur. İnsan beyninin karmaşıklığı ve olağanüstü işleme kapasitesi, bilim insanlarını bu doğal örnekten ilham almaya yönlendirmiştir.

1950'ler ve 1960'lar, YSA'ların temellerinin atıldığı dönemdir. McCulloch-Pitts modeli, ilk yapay sinir ağı modeli olarak kabul edilir. Bu model, sinir hücrelerinin basit matematiksel temsillerini kullanarak hesaplamalar gerçekleştirmek için bir çerçeve sağlamıştır. Ayrıca, Rosenblatt'ın perceptron algoritması da bu dönemde geliştirilmiştir. Perceptron, basit bir sinir ağı modeli olup, ikili sınıflandırma problemlerini çözebilmektedir.

Ancak, 1960'ların sonlarına doğru YSA'lar hakkındaki ilgi azalmış ve gelişimi yavaşlamıştır. Bu dönemde, YSA'ların sınırlamaları ve karmaşıklığıyla başa çıkmak zor olduğu düşünülmüştür. Alternatif hesaplama modelleri, özellikle sembolik hesaplama (örneğin, uzman sistemler) daha popüler hale gelmiştir.

Yapay sinir ağlarına olan ilgi, 1980'lerde tekrar canlanmıştır. Özellikle, geri yayılım algoritması (backpropagation) ile çok katmanlı yapay sinir ağları (MLP) geliştirilmiştir. Bu algoritma, sinir ağlarının öğrenme yeteneklerini artırarak, daha karmaşık problemleri çözebilme kapasitelerini ortaya çıkarmıştır. Ayrıca, Hopfield ağları gibi rekurrent sinir ağı modelleri de bu dönemde geliştirilmiştir. Sonraki yıllarda, yapay sinir ağları üzerinde birçok gelişme kaydedilmiştir. Radyal baz fonksiyon ağları (RBF), sınıflandırma ve regresyon problemlerinde başarılı olmuştur. Ayrıca, Convolutional Neural Networks (CNN) gibi özel sinir ağı mimarileri, görüntü işleme ve derin öğrenme alanlarında büyük ilerlemeler sağlamıştır. Ayrıca bu alanda literatür de oldukça zengindir. Önem arz eden çalışmalar sayesinde veri yayılım algoritması, derin öğrenme ve sinir ağı mimarileri gibi önemli kavramlar, bu çalışmalarla birlikte ortaya çıkmıştır.

Yapay sinir ağları, birçok temel bileşenden oluşmaktadır. Bu temel bileşenler şu şekildedir:

Sinir Hücresi (Nöron): Yapay sinir ağlarının temel birimi olan sinir hücresi, gelen girdi sinyallerini alır, bu sinyalleri ağırlıklarla çarpar ve bir çıkış değeri üretir. Nöronlar, aktivasyon fonksiyonları ile gelen sinyalleri dönüştürerek, çıkışları belirler.

Ağırlıklar ve Bağlantılar: Sinir hücreleri arasındaki bağlantılar, ağırlıklarla temsil edilir. Her bağlantı, iki sinir hücresi arasında bir ağırlık değeriyle ilişkilendirilir. Ağırlıklar, sinir ağının öğrenme sürecinde ayarlanır ve girdi sinyallerinin çıkışa olan etkisini belirler.

Katmanlar: Yapay sinir ağları, genellikle katmanlara ayrılır. Giriş katmanı, verilerin ağına girdi olarak verildiği ilk katmandır. Ara katmanlar, giriş ve çıkış katmanı arasında bulunur ve genellikle hesaplama ve öğrenme işlemlerini gerçekleştirir. Çıkış katmanı, ağın sonuçlarını üreten son katmandır.

Aktivasyon Fonksiyonları: Sinir hücrelerinde kullanılan aktivasyon fonksiyonları, gelen sinyallerin dönüştürülmesinde rol oynar. Sigmoid, ReLU, tanh gibi yaygın aktivasyon fonksiyonları vardır. Bu fonksiyonlar, sinir ağının non-lineer ilişkileri öğrenmesine olanak sağlar.

Geri Yayılım Algoritması: Geri yayılım algoritması, yapay sinir ağlarının öğrenme sürecinde kullanılır. Bu algoritma, ağırlıkların optimizasyonunu gerçekleştirerek, hata değerini minimize etmeyi hedefler. Geri yayılım algoritması, hata sinyallerini geriye doğru yayarak ağırlık güncellemelerini gerçekleştirir.

Derin Öğrenme ve CNN: Derin öğrenme, çok katmanlı yapay sinir ağlarının kullanıldığı bir alanı temsil eder. Convolutional Neural Networks (CNN), özellikle görüntü işleme ve desen tanıma gibi alanlarda başarıyla kullanılan özel sinir ağı mimarileridir.

2.3.7.3. Random Forest

Random Forest (Rastgele Orman), makine öğrenimi alanında yaygın olarak kullanılan bir topluluk öğrenimi algoritmasıdır. Bir topluluk öğrenimi algoritması olarak, birden fazla karar ağacının bir araya getirilmesiyle oluşturulan bir modeldir. Bu ağaçların seçiminde doğruluk ve bağımsızlık temel kriterlerdir. Random Forest, yüksek doğruluk sağlama, değişken önemini belirleme ve overfitting'i azaltma gibi avantajlarıyla popülerlik kazanmıştır. Sınıflandırma yaparken veri kümesinin birçok farklı alt kümelerine tahmin doğruluğunu iyileştirmek ve aşırı uyumu kontrol etmek için ortalamayı kullanan bir meta tahmin metodudur. Alt kümelerin boyutu her zaman orijinal veri kümesinin boyutuyla paraleldir. 3 temel prensibi bulunmaktadır:

2. **Karar Ağacı (Decision Tree):** Random Forest, bir topluluk öğrenimi algoritması olduğu için, temelinde karar ağaçlarını kullanır. Karar ağaçları, veri kümesini özniteliklere göre bölerek kararlar veren ağaç yapısıdır. Her düğüm, bir öznitelikle bölünmüş ve alt düğümlere ayrılmıştır. Yaprak düğümlerinde ise sınıflandırma veya regresyon sonuçları bulunur.

3. Rastgelelik: Random Forest, rastgelelik ilkesine dayanır. Her bir karar ağacı, rastgele bir örneklem (bootstrap) ve rastgele özniteliklerin bir alt kümesi üzerinde eğitilir. Bu, her bir ağacın farklı bir alt kümeyle eğitilmesini sağlar ve çeşitlilik oluşturur. Rastgele seçim, genel modelin varyansını azaltır ve overfitting'i engeller.

4. Oybirliği (Voting): Random Forest, topluluk öğrenimi olduğu için, karar ağaçlarının çoğunluk oyuyla sonuç üretir. Sınıflandırma problemleri için en yaygın yöntem, çoğunluk oyuyla sınıf belirlemektir. Regresyon problemleri için ise, çoğunluk oyu yerine tahminlerin ortalaması kullanılır.

Random Forest algoritması, birçok uygulama alanında başarıyla kullanılmaktadır. Bu alanlara sınıflandırma, öznitelik önemi belirleme ve regresyon örnek verilebilir.

- Sınıflandırma: Random Forest, sınıflandırma problemlerinde etkili bir şekilde kullanılabilir. Hastalık teşhisi, müşteri segmentasyonu, spam filtreleme gibi birçok alanda sınıflandırma problemleri için tercih edilen bir yöntemdir. Birden fazla karar ağacının oyuyla sınıf belirlenerek, yüksek doğruluk elde edilebilir.
- Öznitelik Önemi Belirleme: Random Forest, özniteliklerin önem sırasını belirlemede de kullanılır. Özniteliklerin katkısını değerlendirmek için, Random Forest algoritması, özniteliklerin kullanım sıklığına ve her bir özneliğin kullanımıyla elde edilen bilgi kazancına bakar. Bu sayede, veri setindeki en önemli öznitelikler tespit edilebilir.
- Regresyon: Random Forest, regresyon problemlerinde de etkili bir şekilde kullanılabilir. Özellikle tahmin problemlerinde, birden fazla karar ağacının tahminlerinin ortalaması kullanılarak doğru bir tahmin elde edilebilir.

Çalışma aşamaları şu şekildedir:

Veri Hazırlığı: Random Forest yönteminin uygulanmasının ilk adımı, veri ön işleme aşamasını içerir. Bu adımda, veri seti analiz edilir ve eksik veriler doldurulur, gereksiz öznitelikler kaldırılır ve kategorik veriler sayısal değerlere dönüştürülür. Veri setinin temizlenmesi ve hazırlanması, modelin performansını artırmak için önemlidir.

Veri Bölünmesi: Veri seti genellikle eğitim ve test veri kümelerine ayrılır. Eğitim veri kümesi, Random Forest modelinin eğitildiği veri kümesidir. Test veri kümesi ise modelin performansını değerlendirmek için ayrılan ve modelin daha önce görmediği verileri içeren kümedir. Bu bölünme, modelin genellemesi ve gerçek dünya verileri üzerindeki performansının tahmin edilmesi açısından önemlidir.

Karar Ağacı Oluşturma (Decision Trees): Random Forest yöntemi, birden fazla karar ağacının bir araya gelmesiyle oluşur. Karar ağaçları, veri kümesindeki özniteliklere göre verileri sınıflandırmak veya değerleri tahmin etmek için kullanılan ağaç yapılarıdır. Bu adımda, eğitim veri kümesi üzerinde birden çok karar ağacı oluşturulur, her bir ağaç rastgele alt küme veriler ve özniteliklerle eğitilir.

Rastgelelik Uygulaması: Random Forest'ın temel özelliği, her bir karar ağacının rastgele veri noktaları ve özniteliklerle eğitilmesidir. Rastgele örnekleme ve öznitelik seçimi, modelin çeşitliliğini artırarak aşırı uyumu azaltır ve modelin genellemesini iyileştirir. Ayrıca, bu rastgelelik sayesinde, veri setindeki gürültüye ve değişkenliğe daha dayanıklı bir model elde edilir.

Karar Ağaçlarının Birleştirilmesi: Oluşturulan tüm karar ağaçları, sınıflandırma veya regresyon problemlerine göre bir araya getirilerek Random Forest oluşturulur. Sınıflandırma problemlerinde, ağaçlardan elde edilen sonuçların çoğunluğuna dayanarak bir sınıf etiketi seçilirken, regresyon problemlerinde ise ağaçların çıktılarının ortalaması alınarak bir tahmin değeri elde edilir. Bu birleştirme işlemi, modelin doğruluğunu ve performansını artırmaya yardımcı olur.

Model Değerlendirme: Random Forest modeli, test veri kümesi üzerinde değerlendirilir. Modelin performansı, çeşitli metrikler kullanılarak ölçülür. Bu metrikler arasında doğruluk, hassasiyet, kesinlik, F1 skoru gibi ölçütler bulunur. Modelin performansı, hiperparametrelerin ayarlanması ve veri ön işleme tekniklerinin optimize edilmesi ile iyileştirilebilir.

Tahminlerin Yapılması: Random Forest modeli, eğitim aşamasında öğrenilen bilgileri kullanarak gerçek dünya verileri üzerinde tahminler yapmak için kullanılır. Bu, yeni verilerin sınıflandırılması veya değerlerin tahmin edilmesi için kullanılabilir.

Random Forest yöntemi, bu adımların tekrarlanarak ve daha karmaşık modellerin birleştirilmesiyle daha yüksek performans elde etmek için kullanılabilir. Çeşitli makine öğrenimi uygulamalarında etkili sonuçlar elde etmek için yaygın olarak kullanılan güçlü bir teknik olsa da eksik kalabildiği durumlar bulunmaktadır. Bu durumlar özellikle örneklem kümesinin dar olduğu senaryolardır. Az miktarda veri ile çalışıyor olmak uyumun oldukça artmasıyla karşılaşılır. Bu durum over fitting olarak adlandırılır ve çalışmalarda karşılaşılmak istenmeyen bir durumdur. Over fitting yaşanmasa bile veri setindeki darlık modelin yanlış bir şekilde önceliklendirilmesine yol açabilir ve ölçümün hassasiyetini düşürebilir. Dolayısıyla

Random Forest algoritmasının veri yeterliliği olan problemlerde çözüm amaçlı kullanılması daha uygundur. Bu veri yeterliliğinin sınırlandırılması oldukça kritiktir çünkü random forest küçük veri kümelerinde hata payı yüksek olabilecek bir yöntem olmanın yanında çok yüksek boyutlu veri kümeleriyle çalıştığında da performans açısından zorlanabilir. Yüksek boyutlu veri setleri, her bir karar ağacının aşırı karmaşık olmasına neden olabilir ve bu durum, eğitim süresini artırabilir. Ayrıca, yüksek boyutlu veri setlerinde ve dengesiz veri kümeleriyle çalışıldığında da gürültüyü ve düşük önemli özellikler daha az etkili bir şekilde ele aldığı için modelin performansı olumsuz etkilenebilir.

Random Forest yönteminin yetersiz kalma ihtimali olan bir diğer konu da dengesiz veri kümeleriyle çalışmaktır. Eğer sınıflar arasındaki örnek sayısı dengesizse, az sayıda örnek içeren sınıfların doğru şekilde sınıflandırılması zorlaşabilir. Ayrıca regresyon ihtiyacı olan karmaşık problemlerin çözümü için de yetersizdir. Özellikle düzgün sürekli fonksiyonları modellemek veya veriler arasındaki ince değişiklikleri yakalamak gerektiğinde, regresyon yöntemleri daha etkili olabilir. Random Forest, genellikle sınıflandırma problemlerinde daha iyi performans gösterirken, regresyon problemlerinde bazı durumlarda daha az doğruluk elde edebilir. Tüm bu yetersizliklere rağmen, Random Forest yöntemi birçok uygulamada başarılı sonuçlar verir ve güvenilir bir seçenek olarak kabul edilir. Ancak, veri setinin özelliklerine ve problemin gerekliliklerine bağlı olarak, bazı durumlarda daha uygun bir makine öğrenimi yöntemi seçmek veya Random Forest modelinin hiperparametrelerini optimize etmek gerekebilir.

2.4. ÖNERİ SİSTEMLERİ

Bilgi ve seçenek bolluğunun arttığı günümüzde, kullanıcıların aradıkları ürün, hizmet veya bilgiyi bulmaları git gide zorlaşmaktadır. Öneri sistemleri, bu sorunun çözümü için ortaya çıkan ve kullanıcılara kişiselleştirilmiş öneriler sunarak bilgi keşfini kolaylaştıran teknolojik bir araçtır. Bir diğer deyişle öneri sistemleri, kullanıcılara kişisel tercihlerine, geçmiş davranışlarına ve demografik özelliklerine göre ürün, hizmet veya içerik önerileri sunan sistemlerdir. Bu sistemler, kullanıcıların ilgi alanlarını ve ihtiyaçlarını belirlemek için çeşitli yöntemler kullanır ve bu bilgiler ışığında en uygun önerileri sunmaya çalışır. İlk olarak 1990'larda ortaya çıktığı zamanlarda bu sistemler oldukça basit algoritmalar kullanılmaktaydı. Zamanla, makine öğrenmesi ve yapay zekâ gibi teknolojilerin gelişmesi ile öneri sistemleri de daha karmaşık ve sofistike hale geldi.

Öneri sistemlerinin gelişimindeki önemli kilometre taşlarına bakacak olursak 1990'ların işbirlikçi filtreleme ve içerik tabanlı filtreleme gibi temel algoritmaların geliştiği, 2000'lerin makine öğrenmesi tekniklerinin öneri sistemlerine uygulandığı, 2010'larınsa derin öğrenme ve yapay zekanın öneri sistemlerinde kullanılmaya başlandığı dönem olarak konumlandırılabilir.

Öneri sistemleri, kullanılan algoritmalara ve veri türlerine göre collaborative filtering (işbirlikçi filtreleme), content based filtering (içerik tabanlı filtreleme) ve hybrid filtering (hibrit filtreleme) olmak üzere 3 gruba ayrılmaktadır. İşbirlikçi filtreleme, kullanıcıların geçmiş davranışlarını ve puanlarını analiz ederek benzer zevklere sahip kullanıcılara öneriler sunarken içerik tabanlı filtreleme kullanıcıların geçmişte satın aldığı veya beğendiği ürünlerin özelliklerini analiz ederek benzer ürünler önerir. Hibrit sistemlerse işbirlikçi filtreleme ve içerik tabanlı filtrelemenin birlikte kullanıldığı karmaşık sistemlerdir. Süreç olarak farklı işlemler de tüm öneri sistemlerinin ortak faydaları vardır. Kullanıcıların aradığını bulmasına yardımcı olması ve yeni ürün&hizmetler keşfetmelerini sağlaması temel faydası olduğu söylenebilir. Ayrıca karar verme sürecini hızlandırır hem kullanıcı memnuniyetini artırır hem de satışları arttırarak gelire katkıda bulunur. Temel dezavantajının ise kullanıcılara sadece kendi ilgi alanlarına giren öneriler sunmaya başlaması olduğu söylenebilir. Bu etkiye baloncuk etkisi denir.

Öneri sistemlerinin kullanıldığı temel alanlarsa aşağıdaki gibidir:

- E-ticaret: Kullanıcılara geçmişte satın aldıkları veya beğendikleri ürünlere benzer ürünler önerir.
- Müzik ve film platformları: Kullanıcılara geçmişte dinledikleri veya izledikleri müzik ve filmlere benzer seçenekler sunar.
- Sosyal medya: Kullanıcılara ilgisini çekebilecek içerikler ve profiller önerir.
- Haber siteleri: Kullanıcılara okudukları haberlere göre diğer haberleri önerir.

2.4.1. Öneri Sistemleri Literatür Taraması

Öneri sistemlerinin gelişiminde yapıtaşı rolü oynayan olaylar kronolojik olarak aşağıdaki tablodaki gibidir:

Tablo 2.5: Öneri Sistemleri Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
1992	Paul Resnick, H. R. Varian	Yapılan çalışmada öneri sistemlerinin temelleri ele alınmış, özellikle bilgi filtreleme ve kişisel önerilerin nasıl yapılabileceği konusunda ilk çerçeve oluşturulmuştur.
1994	Paul Resnick, Neophytos Lacovou, Mitesh Suchak, Peter Bergstrom, John Riedl	Yapılan çalışmada kullanıcılara haber önerebilmek için Pearson Bağıntısı'nı kullanan kullanıcı tabanlı bir öneri sistemi geliştirilmiştir. Bellek Tabanlı İşbirlikçi Filtreleme Yöntemi, makine öğrenmesi dilinde, İşbirlikçi Filtreleme Yöntemi'nin tembel versiyonu olarak adlandırılmaktadır.
1996	U. Shardanand, P. Maes	"Social information filtering: Algorithms for automating word of mouth" adlı çalışma ile kullanıcıların benzer ilgi alanlarına sahip kişilerin tercihlerine dayalı olarak önerilerde bulunulmasını sağlayan bir sosyal bilgi filtreleme sistemi tanıtılmıştır.
1998	Breese	Çalışmada bir demetleme modeli oluşturularak aynı tercihleri paylaşan kullanıcılar aynı gruplara yerleştirilmiştir. Belirli bir sınıftaki aktif kullanıcıların oyları bağımsız kabul edilerek Naive Bayes formülüne göre hesaplanmıştır.

Tablo 2.5 (devam): Öneri Sistemleri Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
1998	Lyle H. Ungar, Dean P. Foster	Nesnelere bağlı olarak kişilerin gruplanmasını içeren algoritmalar İşbirlikçi Filtreleme Yöntemi'ne uygulanmıştır.
1999	Jonathan J. Herlocker	İşbirlikçi Filtreleme Yöntemleri'ndeki tahminlerin doğruluğunu arttırabilmek için algoritmik bir Framework geliştirilmiştir. Çalışma sonucunda farklı veri setleri üzerinde Spearman bağıntısının, Pearson bağıntısından daha iyi sonuçlar verdiği gözlemlenmiştir.
1999	G. Linden, B. Smith, J. York	Amazon.com'un öneri sistemlerinin işleyişini ve kullanıcı deneyimini detaylandıran bu çalışma, e-ticaret alanındaki öneri sistemlerinin erken dönemlerine ışık tutmaktadır.
2000	David N. Pennock	İşbirlikçi Filtreleme Yöntemleri'ni kullanan, kişiliği tanıma (personality diagnos) adında yeni bir sistem geliştirilmiştir. Geliştirilmiş olan framework sayesinde Pearson Benzerlik Yöntemi'ne bağlı kümeleme işlemleri için yeni bir ölçekleme yöntemi oluşturulmuştur
2000	Jonathan L. Herlocker, Joseph A. Konstan, John Riedl	E-ticaret sistemleri için kullanılabilecek farklı algoritmaların analizini içeren bir çalışma yapılmıştır. Çalışma iki ayrı veri kümesine uygulanmıştır. Veri kümelerinden bir tanesi Movilens Veri Kümesi diğeri ise bir e-ticaret sitesinden alınmış verilerdir. Çalışma sonucunda farklı alt görevlere sahip parçacıkların bir araya getirilerek daha yeterli bir İşbirlikçi Filtreleme Algoritması'nın gerçekleştirilebileceği gösterilmiştir
2000	Danyel Fisher	İşbirlikçi Filtreleme Algoritmalarının, Java tabanlı olarak çalıştırılabileceği bir Framework geliştirilmiştir
2001	Badrul Sarwar, George Karypis, Joseph Konstan, John Riedl	İşbirlikçi Filtreleme Yöntemleri'nin, öneri kalitesini arttırmak için İçerik Tabanlı Uygulamaları, İşbirlikçi Filtreleme Yöntemi'nin içerisine entegre eden model geliştirilmiştir.
2001	B. Sarwar, G. Karypis, J. Konstan, J. Riedl	Kolaboratif filtreleme yöntemlerinden biri olan ve özellikle Netflix Prize yarışmasında dikkat çeken bu çalışma, ürün bazlı öneri sistemlerinin etkinliğini incelemektedir.
2001	Ken Goldberg	Eigentaste isimli yeni bir algoritma geliştirilmiştir. 8 Geliştirilen algoritmada oy matrisinin içerisindeki yoğun bir altkümeyle Pearson Korelasyon Katsayısını uygulamıştır. Eigentaste Algoritması sayesinde, çevrimiçi hesaplama zamanında anlamlı bir azalma sağlanmıştır
2002	Koji Miyahara, Michael Pazzani	Klasik İşbirlikçi Filtreleme Algoritmalarından farklı olarak hem kullanıcı tabanlı hem de nesne tabanlı İşbirlikçi Filtreleme Algoritması üzerinde Bayesian sınıflandırıcılarını kullanan bir yöntem geliştirilmiştir.
2002	Matthew Brand, Kent Wittenburg, Davis Wong	Web sayfalarında öneri amaçlı kullanılmak üzere GAB isimli bir öneri sistemi tasarlanmıştır. Geliştirilmiş olan yöntem ile sık kullanılan sayfalar belirlenerek kullanıcılara bir etkin sayfa listesi hazırlanmakta ve bu sayfa listesi kullanılarak, kullanıcılara sayfa önerisinde bulunulması sağlanmaktadır
2003	J. S. Breese, D. Heckerman, C. Kadie	"Empirical analysis of predictive algorithms for collaborative filtering" adlı çalışma ile, çeşitli kolaboratif filtreleme algoritmalarının performansını karşılaştırarak, hangi yöntemlerin daha etkili olduğunu araştırılmıştır.

Tablo 2.5 (devam): Öneri Sistemleri Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
2006	Rong Hu, Yansheng Lu	Geliştirdikleri hibrit yöntemde de kullanıcı ve nesne tabanlı İşbirlikçi Filtreleme Yöntemleri birleştirilmiştir. Geliştirilmiş olan Hibrit Algoritma'ya HSPA ismi verilmiştir
2006	Y. Koren	"Factorization meets the neighborhood: a multifaceted collaborative filtering model" adlı çalışma, matris faktörizasyonu ve mahalle tabanlı yöntemleri birleştiren bir modeli tanıtarak, öneri sistemlerinde daha iyi performans elde etmeyi amaçlamaktadır.
2007	Enhong Chen	CFBIS isimli yeni bir İşbirlikçi Filtreleme Algoritması önerilmiştir. Yapılan deneysel çalışmalar sonucunda algoritmanın klasik İşbirlikçi Filtreleme Algoritması'ndan daha iyi sonuçlar ürettiği gözlemlenmiştir. Ayrıca algoritma klasik İşbirlikçi Filtreleme Yöntemi'nin bir eksikliği olan yetersiz veri sorununu da çözülmüştür.
2007	Hemalatha Chandrashekhar, Bharat Bhasker	Kullanıcıların oylarını temel alan Bellek Tabanlı bir İşbirlikçi Filtreleme Algoritması geliştirilmiştir. Buradaki yöntemde aktif kullanıcı için komşuların seçiminde, komşular arasındaki, Kompleks ilişkiler kullanılmıştır. Komşu seçiminde kullanılan ölçütler, entropi ölçüsü kullanılarak ölçülebilecek ölçütlerdir. Kullanılan yöntemin klasik İşbirlikçi Filtreleme Yöntemi'nden daha iyi sonuçlar ürettiği ve her türlü veri kümesi üzerinde uygulanabileceği anlaşılmıştır.
2009	Baltornas	Filtreleme yöntemleri ile ilgili iki farklı çalışma yapılmıştır. Bunlardan bir tanesi, kullanıcılardan gelecek geribildirimleri kullanan, ön filtreleme yöntemine sahip bir filtreleme sistemidir. Diğer çalışmada ise kullanıcı oylarını kullanan, klasik İşbirlikçi Filtreleme Yöntemleri'nin geliştirilmesini sağlamak için kullanıcıların oylama işlemini yaparken, sadece kullanıcı oylarını kullanmanın yeterli olamayacağı, bu yüzden daha önceden kaydedilmiş olan kullanıcıya ait bağlamsal bilgilere ihtiyaç duyulduğu açıklanmıştır
2010	Y. Koren, R. Bell, C. Volinsky	Matris faktörizasyonu gibi tekniklerin kullanımını öneri sistemlerindeki başarısını inceleyerek, Netflix Prize yarışmasında etkili olan bir yaklaşımı açıklamışlardır.
2011	Defu Lian, Xing Xie, Enhong Chen, Hui Xiong	Kişiselleştirilmiş öneri sistemlerinde, kullanıcılara benzer sayfa önerilerinde bulunmak için geliştirilmiş İşbirlikçi Filtreleme Sistemlerinin yapısı ele alınmıştır.
2013	P. Cremonesi, Y. Koren, R. Turrin	"Performance of recommender algorithms on top-n recommendation tasks" isimli bir çalışma yürütmüşlerdir. Bu çalışmada farklı öneri algoritmalarının performansını karşılaştırarak, en iyi n öneriyi sağlama görevlerinde nasıl performans gösterdiklerini incelemişlerdir.
2015	X. He, L. Liao, H. Zhang, L. Nie, X. Hu, T. Chua	Nöral işbirlikçi filtreleme çalışması yapılmıştır. Çalışmada derin öğrenme teknikleri kullanılarak kolaboratif filtreleme için yeni bir model önerilmiş ve öneri sistemlerindeki performans değerlendirilmiştir.

Tablo 2.5 (devam): Öneri Sistemleri Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
2017	H. Wang, N. Wang, D. Y. Yeung	Öneri sistemlerinde işbirlikçi derin öğrenme metoduyla çalışmışlardır. Bu çalışma, derin öğrenme tekniklerini kolaboratif filtreleme ile birleştirerek, öneri sistemlerinde daha etkili bir model geliştirilmesini sağlamıştır.
2018	Y. Zhou, D. Wilkinson, R. Schreiber, R. Pan	Yapılan filtreleme çalışmasıyla Netflix için geniş ölçekli paralel işbirlikçi filtreleme çalışılmış, öneri sistemindeki etkisi değerlendirilmiştir.
2020	S. Wu, Y. Tang, Y. Zhu, L. Wang, S. Li	Grafik sinir ağları kullanılarak oturum tabanlı öneri sistemleri için yeni bir model önerilmiş ve bu modelin performansı değerlendirilmiştir.
2020	Sarah Pozzi, Yazan Roupail, Aziz Nazha ve diğerleri	Son teknoloji açıklanabilir yapay zeka modellerini kullanarak genotip-fenotip ilişkilerini tanımlaya çalışıldı.
2021	Isaac Ward, Ling Wang, Juan Lu, Mohammed Bennamoun, Girish Dwivedi, Frank Sanfilippo	Bir bireyin sağlık bilgilerini (örneğin ilaç geçmişi ve komorbiditeleri) girdi olarak alan ve bireyin Akut Koroner Sendrom (AKS) olumsuz sonucuna sahip olma olasılığını tahmin eden modeller oluşturuldu..
2022	Hui Wen Loh, Chui Ping Ooi, Prabal Datta Barua	Açıklanabilir yapay zekanın (XAI) sağlık hizmetlerinde nasıl tahminleme yapabildiğini açıklayarak sağlık hizmetlerinde yapay zeka sistemlerinin kullanımını teşvik etmişlerdir.
2022	Fanyou Wu, Cheng Lyu, Yang Liu	Yaptıkları "A personalized recommendation system for multi-modal transportation systems" adlı çalışmada öneri sistemi ve ulaşım mühendisliğini birleştiren proaktif seyahat modu önerisi için kavramsal bir çerçeve sağlanmıştır.
2022	İrem İşlek, Şule Gündüz	"A hierarchical recommendation system for E-commerce using online user reviews" adlı çalışmada, e-ticaret öneri sisteminin performansını artırmak için hiyerarşik bir öneri sistemi önerilmiştir..
2023	Linjiang Zhou, Xiaochuan Shi, Yaxiong Bao, Lihua Gao, Chao Ma	Dijital Finansal Kapsayıcılık Endeksi'ni inceleyerek açıklanabilir yapay zeka tekniklerinin daha yenilikçi ekonomik içgörüler sağlayabileceğini göstermişlerdir.
2023	Ying Zhou, Haoran Li, Zhi Xiaoi, Jing Qiu	Yaptıkları çalışma ile açıklanabilir yapay zeka (XAI) yöntemlerine dayalı finansal dolandırıcılık tespit modelleri için kullanıcı merkezli açıklamalar üretmeyi amaçlanmıştır.
2023	Osamah Ibrahim Khalaf, Ajmera Kiran, Wing Keung Wong ve diğerleri	Sağlık ile ilgili yararlı bilgiler sunan öge tabanlı işbirlikçi filtreleme ile sağlık danışmanlığı programı geliştirilmiştir.
2024	Kiarash Sadeghi, Divesh Ojha, Puneet Kaur, Amandeep Dhir	açıklanabilir yapay zekanın tedarik zinciri karar alma süreçleri üzerindeki etkisine dair ampirik kanıtlar sunan öncü çalışmalardan biridir. Bulgular, açıklanabilir yapay zekanın şeffaflığı artırdığını ve böylece tedarik zinciri siber saldırıları sırasında siber dayanıklılığı artırmak için çevik karar vermeye önemli ölçüde katkıda bulunduğunu ortaya koymaktadır.
2024	Suman Thapaliya, Omid Fatahi Valilai, Hendro Wiaksono	CNC freze makineleri kullanan şirketlerin freze makinelerinin çalışmasını zaman ve enerji açısından verimli bir şekilde planlama ve programlamaları için makine öğrenmesi yöntemleri ve açıklanabilir yapay zeka kullanarak model geliştirmişlerdir.


Tablo 2.5(devam): Öneri Sistemleri Literatür Çalışması

Yıl	Kişi	Yapılan Çalışma
2024	Simin Yu, Hao Wang, Ye Su, Ziyu Niu, Jianjun Liu	Çift bulut modelinde sosyal ilişkilere dayalı, gizliliği koruyan bir öneri sistemi geliştirilmiştir. Bu sistemin güvenli hesaplamasını sağlamak için, güvenli eşitlik protokolü ve güvenli karşılaştırma protokolü gibi bazı temel güvenli protokoller de tasarlanmış ve geliştirilmiştir.
2024	Yuguo Yuan, Weimin Zheng	"Your trip, your way: An adaptive tourism recommendation system" adlı çalışma ile uyarlanabilir bir turizm öneri sistemi önererek güzergah planlama zorlukların üstesinden gelmek amaçlanmıştır.

2.4.2. Kullanılan Yöntemler

Hedeflenen kullanıcılara benzeyen gruplardan alınan bilgileri işleyerek onların tercihleri ile ilgili tahmin etmeye çalışan öneri sistemleri hızla gelişen teknoloji neticesinde oluşan datasetin içerisinde kullanıcıların ihtiyaçlarını karşılayacak bilgilere hızlı ve doğru bir şekilde erişim imkânı sunan bir köprü olarak da tanımlanabilir. Bahsi geçen ihtiyaç müzik, film, kitap veya alışveriş kombinleri gibi sayısız tercih olabilir. Örneğin evli ve çocuklu olan X kişisi makarna alırken yanına eklediği ürün yoğurt olurken, üniversite öğrencisi olan Y kişisi makarna alışverişinin yanında gazlı içecek tercih ediyor olabilir. Bu iki profili birbirinden ayırmak ancak benzerlerinden oluşan topluluğu inceleyip kümelemekle mümkündür.

Kümelemenin ardından kendisine en uygun olan ürün önerilebilir. Uygulama sırasında kullanıcılar arasındaki benzerlikler, kullanıcıların ürünler ile ilgili yorumları, uygulama öncesindeki belli bir zaman boyunca ziyaret etmiş oldukları web siteleri, favoriledikleri ürünler, en çok arattıkları kelimeler gibi pek çok farklı ölçüt dikkate alınabilir. Bu ölçütler öneri sistemine konu olan nesneye dair içerik verileri ise öneri sistemi İçerik Tabanlı Filtreleme Sistemleri; kullanıcılara ait ölçütler ise İşbirlikçi Filtreleme Sistemleri olarak adlandırılır. Bazı durumlarda her iki öneri sistemi modeli iç içe kullanılarak gelişmiş modeller üretilir. Bu tip öneri sistemlerine ise Hibrit Öneri Sistemleri denir.



Şekil 2.5: Öneri Sistemlerinde Kullanılan Yöntemler

2.4.2.1. İçerik Tabanlı Filtreleme Yöntemi


İçerik Tabanlı Filtreleme yöntemleri öneri sistemine konu olan ürünün içeriğine göre filtrelendiği ile yapılır. Filtreleme esnasında belirlenen kriterler ürüne göre değişebilmektedir. Manav reyonundaki filtrelemede renk, tat, görüntü, saklanma koşulları ölçüt olabilirken; kütüphanedeki filtrelemede ölçüt konu, doküman kalınlığı, yazar veya yazıldığı sene olabilir. Bu tip sistemlerin işlemesindeki temel mantık; içerik ile ilgili veriler toplayıp bu verileri kümeledikten sonra ve öneri aşamasında bu kümelerle ilişki sorgulayarak öneride bulunmaktır. İçerikler arasındaki benzerlikler hesaplanırken ölçüm olarak ağırlık vektörleri dikkate alınmaktadır. Kullanılacak yönteme göre en yüksek ya da en düşük ağırlık değerine sahip ilk n kelime dikkate alınarak dokümanların temsil edilmesi sağlanır. Gelişen teknolojiyle birlikte yapılan araştırmaların internet ortamına kaymasıyla kullanıcılara ait ilgi alanları kolaylıkla kayıt altına alınabilmektedir. Bu durum içerik tabanlı öneri sistemlerinin gelişimindeki yapı taşı olarak tanımlanabilir. Üstelik sadece arama çubuğuna yazılan konular değil; aynı zamanda görüntülenen sayfalar, yapılan yorumlar, beğenilen ürün ve içerikler de içerik tabanlı öneri sistemlerine veri sağlamaktadır. Bu veriler sayesinde sistemin kullanıcıların ihtiyaç duyacağı, hoşlanacağı, yönelimi bulunan şeyler hakkında öneri üretmesi sağlanır.

İçerik tabanlı filtreleme yöntemi, kullanıcının geçmiş tercihlerine ve içeriğin özelliklerine dayanarak kişiselleştirilmiş öneriler sunma avantajına sahip olduğundan dolayı kullanıcıların ilgi alanlarına daha uygun içeriklere erişmelerini sağlayarak kullanıcı memnuniyetini artırabilir. Ayrıca, önerilerin neden yapıldığını anlamak diğer yöntemlere göre daha kolaydır, çünkü öneriler, içeriğin nitelikleri ve kullanıcının ilgi alanları arasındaki uyumu temel alır. Bununla birlikte, içerik tabanlı filtreleme yöntemi, kullanıcıların ilgi alanlarının daralmasına ve çeşitlilikten yoksun kalmasına neden olabilir çünkü sadece içerikle ilgili geçmiş veriyi baz aldığından dolayı sınırları oldukça dardır, aynı yerde dönüp durabilir. Bu da yeni ve farklı içeriklerin keşfini zorlaştırabilir ve kullanıcıların sık sık aynı türde içeriklerle karşılaşmasına yol açabilir. Bir diğer riskli yönü ise içeriklerin tanımlanmasıyla ilgilidir. Sistem tamamen içeriğe göre yönlendirme yaptığı için içeriklerin doğru bir şekilde tanımlanması ve özelliklerinin belirlenmesi önem arz etmektedir. Doğru tanımlanmayan her girdi sistemi bozup yanlış önerilere sebep olabilmektedir. Yine de bu yaklaşımın birçok avantajı vardır. Kullanıcı tercihleri zamanla değişme eğiliminde olduğundan, bu yaklaşım kendisini değişen kullanıcı tercihlerine dinamik olarak hızlı bir şekilde uyarlama yeteneğine sahiptir. Bir kullanıcı profili yalnızca o kullanıcıya özel olduğundan, bu algoritma, öneri sürecine herhangi bir etki sağlamadığından diğer kullanıcıların profil ayrıntılarına ihtiyaç duymaz. Bu, kullanıcı verilerinin güvenliğini ve gizliliğini sağlar.

2.4.2.2. İş Birlikçi Filtreleme Yöntemler

İşbirlikçi yaklaşımlar, kullanıcılar arasındaki benzerlik ölçüsünden yararlanır; dolayısıyla hangi işbirlikçi yöntem kullanılırsa kullanılsın temel mantık kümeleme üzerinedir. Bu teknik, tercihleri, beğenileri ve antipatileriyle A kullanıcısının kine benzer olan B kullanıcısının bir grubunu veya koleksiyonunu bulmakla başlar. B'deki kullanıcıların çoğu tarafından beğenilen yeni öğeler daha sonra A kullanıcısına önerilir. İşbirliğine dayalı bir algoritmanın verimliliği, algoritmanın hedef kullanıcının kümesini ne kadar doğru bulabildiğine bağlıdır. Geleneksel olarak iş birliğine dayalı filtreleme tabanlı sistemler, kullanıcı verilerinin paylaşılması gerektiğinden soğuk başlangıç sorunu ve gizlilik endişelerinden mustarıdır; ancak işbirlikçi filtreleme yaklaşımları, öneri oluşturmak için öğe özelliklerine ilişkin herhangi bir bilgi gerektirmez. Ayrıca bu yaklaşım, yeni öğeler keşfederek kullanıcının mevcut ilgi alanlarını

geniřletmeye yardımcı olabilir. İř birliđine dayalı filtrelemenin temel mantıđı ařađıdaki řekilde gsterildiđi gibidir:



řekil 2.6: İřbirliki Filtreleme İřleyiři

İřbirliki filtreleme model bazlı ve hafıza bazlı filtreleme yntemleri olarak ikiye ayrılır. Hafıza temelli iřbirliki yaklařımlar, kmenin tercihlerini dikkate alarak yeni ğeler nerir ve tahmin iin dođrudan fayda matrisinden yararlanırlar. Bu yaklařımda ilk adım bir model oluřturmaadır. Model, fayda matrisini girdi olarak alan bir fonksiyona eřittir. rn bazlı ve kullanıcı bazlı yaklařımlar olmak zere ikiye ayrılan hafıza bazlı filtreleme yntemlerinden rn bazlı yaklařımda kullanıcının daha nce derecelendirdiđi tm benzer maddelerden oluřan bir rn kmesi oluřturulur. Farklı yeni bir rn iin kullanıcının puanı, benzer bir ge kmesinde bulunan tm derecelendirmelerin ađırlıklı ortalaması hesaplanarak tahmin edilir.

Model tabanlı sistemler ise eřitli veri madenciliđi ve makine đrenimi algoritmalarını kullanır. Derecelendirilmemiř bir ge iin kullanıcının derecelendirmesini tahmin etmek iin bir model geliřtirilir. neriler hesaplanırken veri kmesinin tamamına gvenilmez, ancak bir modeli hesaplamak iin veri kmesinden zellikler ıkarılır; bu nedenle modele dayalı teknik adı verilmiřtir. Bu tekniklerin tahmin iin de iki adıma ihtiyaı vardır; ilk adım modeli oluřturmak, ikinci adım ise ilk adımda tanımlanan modeli ve kullanıcı profilini girdi olarak alan bir (f) fonksiyonunu kullanarak derecelendirmeleri tahmin etmektir.

$$\text{Model} = f(\text{Fayda Matrisi})$$

$$(2.11)$$

Modeli ve kullanıcı profilini girdi olarak alan bir işleve dayalı olarak on öneri yapılmıştır. Burada yalnızca kullanıcı profili fayda matrisine ait olan kullanıcılara önerilerde bulunabiliriz. Bu nedenle, yeni bir kullanıcıya öneride bulunmak için, fayda matrisine kullanıcının eklenmesi ve benzerlik matrisinin yeniden hesaplanması gerekir, bu da bu tekniğin hesaplamasını ağır hale getirir.

$$\text{Öneri} = f(\text{tanımlanan model, kullanıcı profili}) \quad (2.12)$$

Burada kullanıcı profili $\in$ fayda matrisi

İşbirlikçi yaklaşımlar ürün bazlı ve kullanıcı bazlı yaklaşımlar olmak üzere yine iki türe ayrılır. Kullanıcı tabanlı yaklaşımda, yeni bir öğenin kullanıcı puanı, siteden başka kullanıcılar bulunarak hesaplanır. Aynı öğeyi daha önce derecelendiren kullanıcı çevresi yeni bir öğe kullanıcı çevresinden olumlu değerlendirmeler alırsa, yeni öğe kullanıcıya tavsiye edilir. Ürün bazlı yaklaşımda ise kullanıcının daha önce derecelendirdiği tüm benzer maddelerden oluşan bir ürün kümesi oluşturulmaktadır. Kullanıcının farklı yeni bir ürünle ilgili puanı benzer bir ürün kümesinde bulunan tüm derecelendirmelerin ağırlıklı ortalaması hesaplanarak tahmin edilmektedir.

Model tabanlı sistemler, kullanıcının derecelendirilmemiş bir öğeye ilişkin derecelendirmesini tahmin etmeye yönelik bir model geliştirmek için çeşitli veri madenciliği ve makine öğrenimi algoritmalarını kullanır. Öneriler hesaplanırken veri kümesinin tamamına güvenmezler, ancak bir modeli hesaplamak için veri kümesinden özellikler çıkarırlar. Bu nedenle modele dayalı teknik adı verilmiştir. Bu tekniklerin tahmin için de iki adıma ihtiyacı vardır; ilk adım modeli oluşturmak, ikinci adım ise ilk adımda tanımlanan modeli ve kullanıcı profilini girdi olarak alan bir f fonksiyonunu kullanarak derecelendirmeleri tahmin etmektir.

$$\text{Öneri} = f(\text{tanımlanan model, kullanıcı profili}) \quad (2.13)$$

Burada kullanıcı profili $\notin$ fayda matrisi

Model tabanlı teknikler, tahminlerde bulunmadan önce yeni bir kullanıcının kullanıcı profilinin fayda matrisine eklenmesini gerektirmez. Modelde bulunmayan kullanıcılara dahi öneride bulunabiliyoruz. Model tabanlı sistemler grup önerileri açısından daha etkilidir. Önceden eğitilmiş modeli kullanarak bir grup öğeyi hızlı bir şekilde önerebilirler. Bu tekniğin doğruluğu büyük ölçüde modeli oluşturmak için kullanılan temel öğrenme algoritmasının verimliliğine

bağlıdır. Model tabanlı teknikler, boyut azaltma tekniklerini [86] ve model öğrenme tekniklerini kullanarak, öneri sistemlerinin seyreklik ve ölçeklenebilirlik gibi bazı geleneksel sorunlarını çözebilmektedir. İşbirlikçi Filtreleme yöntemlerinden KNN, Random Forest, Karar Ağacı, PCA, K-Means vs. gibi model bazlı birçok yaklaşım bulunmaktadır. Bu modellerden bazıları aşağıda detaylı olarak verilmiştir.

2.4.2.3. Hibrit Filtreleme Yöntemleri

Hibrit filtreleme, bireysel öneri tekniklerinin sınırlamalarını ele almak için birlikte kullanılan iki veya daha fazla tekniğin bir araya getirilmesiyle oluşan bir filtreleme yöntemidir. Farklı tekniklerin birleştirilmesi çeşitli şekillerde gerçekleştirilebilir. Hibrit bir algoritma, ayrı tekniklerden elde edilen sonuçları birleştirebilir veya işbirlikçi bir yöntemde içerik tabanlı filtrelemeyi kullanabilir. Ayrıca içerik tabanlı bir yöntemde işbirlikçi bir filtreleme tekniği kullanabilir. Farklı tekniklerin bu hibrit birleşimi genellikle birçok öneri uygulamasında artan performans ve artan doğrulukla sonuçlanır.

Tarihçesine bakılacak olunursa hibrit filtreleme yöntemleri, öneri sistemlerinin gelişimiyle birlikte ortaya çıkmıştır. Öneri sistemlerinin geliştirildiği ilk yıllarda geleneksel olarak, öneri sistemleri ya işbirlikçi filtreleme ya da içerik tabanlı filtreleme yöntemlerini kullanmaktaydı; ancak, her iki yaklaşımın da belirli kısıtlamaları vardı ve tek başlarına optimum performansı sağlayamıyorlardı. Bu nedenle, araştırmacılar farklı yöntemleri birleştirerek daha güçlü ve esnek bir öneri sistemi oluşturmanın yollarını aramaya başladılar.

Genellikle iki aşamalı bir süreç olarak uygulanan hibrit filtrelemede ilk olarak, kullanıcının tercihleri ve profil bilgileri gibi içerik tabanlı bilgiler kullanılarak potansiyel öneriler oluşturulur. Ardından, bu öneriler, benzer kullanıcıların tercihleri gibi kolaboratif filtreleme bilgileriyle birleştirilir ve daha hassas ve kişiselleştirilmiş öneriler elde edilir.

Hibrit filtreleme yöntemlerinin olumlu yönleri arasında, daha kapsamlı ve hassas öneriler sunma yeteneği, kullanıcıların tercihlerini daha iyi anlama ve çeşitli veri türlerini daha etkin bir şekilde kullanma kabiliyeti bulunmaktadır. Bununla birlikte, hibrit filtreleme yöntemleri, uygulama ve geliştirme sürecinde daha karmaşık ve zaman alıcı olabilir. Ayrıca, farklı yaklaşımların uyumlu bir şekilde birleştirilmesi gerektiğinden, algoritmanın karmaşıklığı artabilir ve performansı etkileyebilir. Bu nedenle, hibrit filtreleme yöntemlerinin uygulanması ve optimize edilmesi genellikle dikkatlice düşünülmesi gereken bir süreçtir.

Arı kolonisi, genetik algoritma, parçacıklı sürü optimizasyonu, ateşböceği algoritması temel hibrit yöntemlerden bazılarıdır. Bu çalışmada hibrit yöntem kullanılmadığından dolayı detay bilgilendirme yer almamaktadır.



3. YÖNTEM

3.1. ÇALIŞMANIN AMACI

Günümüzde faiz hassasiyeti nedeniyle müşterilerin tercihi haline gelen katılım bankalarında, geleneksel bankacılıktan gelen kısıtların yanında İslami Finans'ın ilkeleri gereğince de bir dizi kısıt eklenmesiyle ürün oluşturma ve bu ürünün en uygun müşteriye önerilmesi önem arz etmektedir. Bu çalışma ile makine öğrenmesinin en güçlü kollarından olan öneri sistemleri altında sınıflama, kümeleme ve sepet analizi yapıp bankanın potansiyel müşterileri ve her bir müşteriye en uygun olan ürünün tahminlenmesi çalışılmıştır. Müşteri tahminlemesinde sistem random bir kişinin verileriyle katılım bankası test ortam müşterilerinin temel verileri arasında benzerlik arayıp herhangi bir kümelemeye dahil olma ihtimalini sorgulamaktadır. Bu sorguya göre kişinin potansiyel müşteri olup olmadığını çıktı olarak vermektedir. Müşteriye önerilecek en uygun ürünün tahminlemesinde ise müşterileri aldıkları ürünlere ve demografik verilerine göre gruplanması suretiyle grupladıktan sonra sisteme giren bir müşteriye önce kendisine en çok benzeyen müşterilerin olduğu gruba atayıp daha sonra bu gruptaki müşterilerin sıklıkla satın aldığı ürünler listesi ile yeni müşterinin şimdiye kadar kullanmış olduğu ürünleri karşılaştırıp alakasız ürünlerin pazarlanmasına efor harcamadan kendisine en uygun ürünün önerilmesi amaçlanmaktadır.

3.2. VERİ SETİNİN TANITIMI

Veri seti test ortamı random verilerden oluşmaktadır, herhangi bir kurumla ilgisi bulunmamaktadır. 1000 kişiye ait veri setinde her bir müşteriye ait 20 kişisel veri, 18 adet de ürün grubuna ait kullanım bilgisi mevcuttur.

Kişisel veriler metinsel olarak, ürün kullanma bilgisi ise kullanım kullanmama durumuna göre 0 ve 1 ile kodlanmış şekildedir. Birkaç satırlık örnek vermek gerekirse:

Tablo 3.1: Veri Setinden Örnek Kesit

	A	B	C	D	AQ	AR	AS
1	YAŞ	CİNSİYET	DOĞUM YERİ	...	DEBİT KART	ALTIN HESABI	DÖVİZ HESABI
2	63	Kadın	GAZİANTEP		0	0	1
3	63	Kadın	AFYONKARAHİSAR		0	0	0
4	35	Erkek	GEDİZ		0	1	0
5	51	Erkek	ŞİRAN		0	0	0
6	...						
498	25	Erkek	VELBERT F.ALMANIA		0	0	0
499	50	Erkek	KONYA		1	0	0
500	36	Erkek	BATMAN		1	1	0
501	25	Kadın	SULTANBEYLİ		0	0	0
502	43	Erkek	ARAC		0	1	0

Uygulamada kullanılan X bankanın random test müşterilerinden alınan kişisel bilgiler şunlardır:

- Yaş

Minimum 14 maksimum 81 yaşında 1000 müşteri bulunmaktadır.

- Yaş Aralığı

Müşterilerin yaşları 0-20, 21-30, 31-40, 41-50, 51-60, 61 ve üstü olmak üzere 6 gruba ayrılmıştır.

- Cinsiyet

Kadın ve erkek olmak üzere 2 cinsiyet bulunmaktadır.

- Doğum Yeri

Nüfus bilgilerindeki doğum yerini göstermektedir.

- İkametgâh

Yaşanılan ili göstermektedir.

- Türkiye'nin en büyük 5 şehrinden birinde mi yaşıyor?

Yapılan son sayıma göre Türkiye'nin nüfus olarak en büyük 5 şehri İstanbul, Ankara, İzmir, Bursa ve Antalya'dır. Müşteri eğer bu şehirlerden birinden yaşıyorsa "evet", diğer şehirlerden birinde yaşıyorsa "hayır" olarak kodlanmıştır.

- Doğduğu şehirde mi yaşıyor?

İkametgâh ile doğum yerinin karşılaştırılmasıyla elde edilen veridir. “Evet” ve “hayır” olarak iki gruptan oluşmaktadır. Kişinin doğduğu şehirden eğitim, iş gibi sebeplerle ayrılmış olduğu var sayılarak belirleyici bir etken olarak modelin girdilerinden birini oluşturmaktadır.

- Medeni Durum

Evli, bekar ve dul olmak üzere 3 gruba ayrılmıştır.

- Çocuk Sayısı

Çocuk sayısı yok, 1 çocuk, 2 çocuk, 3 çocuk, 4 ve +4 çocuk, bilinmiyor olmak üzere 6 grupta incelenmiştir.

- Eğitim Durumu

Eğitim durumu mezun olunan son okula göre okuryazar, ilkokul, lise, lisans, yüksek lisans ve doktora olmak üzere 6 gruba ayrılarak incelenmiştir.

- Müşteri Olma Kanalı

Müşteri olma kanalı şube ve self servis olarak ikiye ayrılmaktadır. Şube fiziki ortamken self servis tüm online kanalları temsil etmektedir.

- Müşteri Olma Tarihi

- Müşteri Olma Süresi

Verinin elde edildiği 9 Aralık 2023 tarihi baz alınarak bugüne kadar geçen gün sayısını göstermektedir.

- Müşteri Tipi

Müşteri olma süresinden elde edilen bir veri olup müşterinin banka ile ilişkisinin zamansal olarak kümelenmesiyle oluşturulmuştur. Müşteri olma süresine göre 0-1 yıl, 1-3 yıl, 3-5 yıl ve eski müşteri olmak üzere 4 gruptan oluşmaktadır.

- Ev Durumu

Sahipliğe göre var, yok ve bilinmiyor olarak 3 gruba ayrılmıştır.

- Araba Durumu

Sahipliğe göre var, yok ve bilinmiyor olarak 3 gruba ayrılmıştır.

- Çalışma Durumu

Çalışma durumu müşterinin güncel bilgilerine göre çalışmıyor, ücretli, işveren ve emekli olmak üzere 4 gruba ayrılmıştır.

- Meslek

16 çeşit meslek bilgisi bulunmaktadır.

- Değer Segmenti

Müşterinin maddi durumu ve bankadaki aktifliğine göre banka tarafından hesaplanan değerdir, harf ile ifade edilir. Müşterinin banka için maddi değerini temsil etmektedir. Değer sıralaması sırasıyla A1, A2, B, C, D şeklindedir; ayrıca P pasif müşterileri gösterir.

- Mobile Son Giriş Gün Farkı

Güncel tarih verinin elde edildiği 9 Aralık 2023 tarihi baz alınarak mobile en son giriş yaptığı tarihten bu tarihe kadar geçen gün sayısını göstermektedir.

- Mobil Aktiflik

Mobil bankacılığı kullanan her müşterinin en azından fatura ödemeleri veya maaş işlemleri için ayda bir kez mobile gireceği varsayılarak maksimum son 31 günde mobil bankacılık uygulamasına giriş yapmış müşteriler mobil aktif, daha öncesi mobil pasif olarak kabul edilmiştir.

- Toplam Ürün Kullanımı

Her bir müşteriye dair ilgili bankada kullandığı toplam ürün sayısını ifade etmektedir. Kişi bazlı ürün kullanımı incelenerek sonradan elde edilmiş veridir.

- Ana Banka mı?

Müşterinin bankada kullandığı ürün sayısını gösteren total ürün kullanımı bilgisinin yorumlanmasıyla üretilmiştir. Eğer müşterinin bankadaki ürün sayısı 7 ve +7 ise müşterinin bankada yeterince aktif olduğu yorumu yapılmış ve ilgili banka müşterinin ana bankası olarak kodlanmıştır, ancak toplam ürün kullanımının 7'nin altında kalması durumunda müşteri yüksek aktiflikte olmadığı için bu gruptaki müşterilerin ana bankası olmadığı varsayılarak kodlanmıştır.

Ürün Kullanımıyla ilgili veriler ilgili müşteri tarafından kullanılıyorsa 1, kullanılmıyorsa 0 ile kodlanmıştır. Sorgulanan ürünler şunlardır:


- BES
- Fatura Talimatı
- HGS
- Hayat Sigortası
- Debit Kart
- Kredi Kartı
- Yatırım Fonu
- Konut Sigortası
- DASK
- Kasko
- Döviz Hesabı
- Kıymetli Maden Hesabı
- Mobil Şube Kullanımı
- Katılma Hesabı

- Premium Kredi Kartı
- Hisse Senedi

Veri setindeki müşterilere ait demografik verilerin analizi aşağıdaki gibidir:

i. Yaş


Veri setindeki müşterilerin yaklaşık olarak yaş ortalaması 39, standart sapması ise 13'tür. Ayrıca en genç müşteri 14 yaşındayken en yaşlı müşteri 81 yaşındadır.



Şekil 3.1: Yaş Dağılımı

ii. Cinsiyet


Veri setindeki müşterilerin %63'ü erkek, %37'si kadındır.



Şekil 3.2: Cinsiyet

iii. Medeni Durum


Veri setindeki müşterilerin %58'i evli, %30'u bekar ve %12'si duldur.



Şekil 3.3: Medeni Durum

iv. Çocuk Sayısı

Çocuk sayısı incelenirken veri 7 kategoriye ayrılmıştır. Veri setindeki müşterilerin %24'ünün hiç çocuğu yokken; %28'inin 1, %20'sinin 2, %12'sinin 3, %5'inin 4 ve %2'sinin 4'ten fazla çocuğu vardır. Bunun dışında %9'una ait çocuk sayısı ile ilgili bilgi bulunmuyor.



Şekil 3.4: Çocuk Sayısı

3.3. FP GROWTH ALGORİTMASI PYTHON KODU

Analizde kullanılan FP Growth algoritması, Python dilinde uygulanan bir dizi kod içermektedir. Bu kod, veri analizi sürecindeki kritik adımları gerçekleştirmek için kullanılmıştır. Python'un kolay okunabilir, esnek yapısı algoritmanın uygulanmasını kolaylaştırmaktadır.

FP Growth algoritmasının Python'daki kodundan bir kesit aşağıdaki gibidir:

```
class TreeNode:
```

```
    def __init__(self, name, count, parent):
```

```
        self.name = name
```

```
        self.count = count
```

```
        self.parent = parent
```

```
        self.children = {}
```

```
        self.node_link = None
```

```

def increase_count(self, count):

    self.count += count

def create_tree(dataset, min_support):

    header_table = {}

    for transaction in dataset:

        for item in transaction:

            header_table[item] = header_table.get(item, 0) + dataset[transaction]

    header_table = {k: v for k, v in header_table.items() if v >= min_support}

    frequent_items_set = set(header_table.keys())

    if len(frequent_items_set) == 0:

        return None, None

    for k in header_table:

        header_table[k] = [header_table[k], None]

    tree = TreeNode('Null Set', 1, None)

    for transaction, count in dataset.items():

        local_d = {}

        for item in transaction:

            if item in frequent_items_set:

                local_d[item] = header_table[item][0]

        if len(local_d) > 0:

```

```

        ordered_items = [v[0] for v in sorted(local_d.items(), key=lambda p: p[1],
reverse=True)]

```

```

        update_tree(ordered_items, tree, header_table, count)

```

```

    return tree, header_table

```

```

def update_tree(items, tree, header_table, count):

```

```

    if items[0] in tree.children:

```

```

        tree.children[items[0]].increase_count(count)

```

```

    else:

```

```

        tree.children[items[0]] = TreeNode(items[0], count, tree)

```

```

    if header_table[items[0]][1] is None:

```

```

        header_table[items[0]][1] = tree.children[items[0]]

```

```

    else:

```

```

        update_header(header_table[items[0]][1], tree.children[items[0]])

```

```

    if len(items) > 1:

```

```

        update_tree(items[1:], tree.children[items[0]], header_table, count)

```

```

def update_header(node_to_test, target_node):

```

```

    while node_to_test.node_link is not None:

```

```

        node_to_test = node_to_test.node_link

```

```

    node_to_test.node_link = target_node

```

```

def ascend_tree(leaf_node, prefix_path):

```

```

    if leaf_node.parent is not None:

```

```

    prefix_path.append(leaf_node.name)

    ascend_tree(leaf_node.parent, prefix_path)

def find_prefix_path(base_pat, tree_node):

    conditional_patterns_base = {}

    while tree_node is not None:

        prefix_path = []

        ascend_tree(tree_node, prefix_path)

        if len(prefix_path) > 1:

            conditional_patterns_base[frozenset(prefix_path[1:])] = tree_node.count

            tree_node = tree_node.node_link

    return conditional_patterns_base

def mine_tree(header_table, min_support, prefix, frequent_item_list):

    bigL = [v[0] for v in sorted(header_table.items(), key=lambda p: p[1][0])]

    for base_pat in bigL:

        new_frequent_set = prefix.copy()

        new_frequent_set.add(base_pat)

        frequent_item_list.append(new_frequent_set)

        conditional_patterns_base = find_prefix_path(base_pat, header_table[base_pat][1])

        conditional_tree, conditional_header_table = create_tree(conditional_patterns_base,
min_support)

```

```

if conditional_header_table is not None:

    mine_tree(conditional_header_table,          min_support,          new_frequent_set,
frequent_item_list)

def fp_growth(dataset, min_support):

    tree, header_table = create_tree(dataset, min_support)

    frequent_item_list = []


    mine_tree(header_table, min_support, set(), frequent_item_list)

    return frequent_item_list

print(itemset)

```

3.4. AKIŞ ŞEMASI



Şekil 3.5: Uygulama Akış Şeması

İlk olarak veri toplama ile çalışmaya başlanmıştır. 1000 satırdan oluşan test verisi kontrol edilerek olası hatalar önlenmiştir. Bu kontrol esnasında kişinin öğrenim durumu&meslek, yaş&öğrenim durumu gibi ilişkisel uyumlar sorgulanıp gerekli revizeler yapılmıştır. Ayrıca oldukça çeşitli ve dağınık halde bulunan meslek ve çalışma durumu verileri sadeleştirilmiştir. Yapılan veri temizliğinin tamamlanmasının ardından veri ön işleme aşamasına geçilmiştir. Bu aşamada ana veride bulunan bazı veri gruplarından çıkarımlar yapılarak modelin yüksek verimlilikte çalışmasına olanak sağlayacak doğduğu yerde mi yaşıyor, en büyük 5 şehrin birinde mi yaşıyor, müşteri tipi, total ürün kullanımı ve ana banka mı inputları üretilmiştir. Bu inputlar sayesinde modele girdi olamayacak kadar dağınık olan veriler sadeleşip aralıklara bölünmüştür. Bu dönüşümün ardından veri tekrar kontrol edilerek çalışmadaki hata minimize edilmiştir. Yapılacak uygulamada veriye ilk olarak K-Means algoritmasıyla kümeleme yapılmasıyla başlanmasına karar verilmiştir. K-Means'in sadece numerik verilerde çalıştığı için veri setinin tamamen numerik veriden oluşması gerekmektedir. Dolayısıyla veri setindeki her kritere ait her cevap grubu için yeni bir sütun oluşturularak var olma durumuna göre 0-1'li kodlara dönüştürülmüştür. Örneğin cinsiyet verisi için kadın ve erkek adlı sütunlar oluşturulup her satırdaki müşterinin cinsiyet bilgisine göre seçeneklerden biri 1 diğeri 0 olarak kodlanmıştır. Medeni durum ise 3 gruptan oluştuğu için 3 sütun eklenmiş kişinin medeni durumunu temsil eden seçenek 1, diğer 2 seçenek 0 olarak kodlanmıştır. Böylelikle müşterinin tanıtımına dair olan nominal verilerin numerik veriye çevrilmesi tamamlanmış, veri kümelemeye hazır hale gelmiştir. Yapılan kümelemenin ardından veri 8 kümeye bölünmüş ve her bir kümeye FP Growth algoritmasıyla birliktelik analizi yapılmıştır. Bunun ardından bankanın kendisi tarafından segmente edilen her müşteri grubuna da FP Growth uygulanarak birliktelik analizi yapılmıştır. Son aşamada bankanın değer segmentlerine uygulanan FP Growth sonucuyla uygulama kapsamında yapılan kümeleme çalışmasına uygulanan FP Growth çalışmasının sonucu karşılaştırılmıştır.

4. BULGULAR

Uygulamanın ilk aşaması olan kümelemede K-Means kullanılacağı ve K-Means sadece numerik veriyle çalıştığı için öncelikle müşteri bilgilerini içeren nominal, string veriler numerik veriye dönüştürülmüştür. Bu dönüşüm her bir kriterin 0-1’li kodlanmasıyla gerçekleştirilmiştir. Dönüşümün ardından ana veriye kümeleme uygulanmış olup detayları aşağıdaki gibidir:

4.1. KÜMELEME

Kümeleme 1000 satırlık test müşterisi verisiyle yapılmış olup yapılan çalışma detayları aşağıdaki gibidir.


4.1.1. Genel Çıktılar

En küçük Davies Bouldin oranına 8 küme ile ulaşıldığı görülmüştür. Bu 8 kümeye ait detaylar şu şekildedir:

Tablo 4.1: Kümeleme Sonucu Müşterilerin Dağılımı

Cluster Model	
Cluster 0	174 items
Cluster 1	125 items
Cluster 2	136 items
Cluster 3	103 items
Cluster 4	105 items
Cluster 5	137 items
Cluster 6	96 items
Cluster 7	124 items
Total number of items	1000

İlk çıktı 1000 kişiden oluşan veri setini 8 kümeye bölme sonucunda her bir kümeye kaç müşteri atandığını göstermektedir. Bu dağılıma göre müşterilerin %17,4’ü cluster_0’da, %12,5’i cluster_1’de, % 13,6’sı cluster_2’de, %10,3’ü cluster_3’te, %10,5’i cluster_4’te, %13,7’si cluster_5’te, %9,6’sı cluster_6’da ve %12,4’ü cluster_7’de bulunmaktadır.



Şekil 4.1: Kümeleme Sonucu Müşterilerin Dağılımı


İdeal kümelemeyle 8 kümeye bölünen veri setindeki Davies Bouldin kat sayısı ve her bir kümedeki centroid distance değeri olabilecek en küçük değeriyle aşağıdaki gibidir.

Tablo 4.2: Kümeleme Performansı Tablosu

PerformanceVector	
Avg. within centroid distance	0.098
Avg. within centroid distance_cluster_0	0.101
Avg. within centroid distance_cluster_1	0.079
Avg. within centroid distance_cluster_2	0.086
Avg. within centroid distance_cluster_3	0.090
Avg. within centroid distance_cluster_4	0.095
Avg. within centroid distance_cluster_5	0.121
Avg. within centroid distance_cluster_6	0.102
Avg. within centroid distance_cluster_7	0.103
Davies Bouldin	0.054

K-Means algoritmasına göre yukarıdaki tabloda görüldüğü üzere Davies Bouldin sayısı 0,054 ile oldukça küçük bir değer almış dolayısıyla veri başarılı bir şekilde kümelendi. Bu 8 kümenin her birine ait centroid uzaklığı tabloda verilmiş olup ortalama centroid uzaklığı ise 0,098 olarak hesaplanmıştır.

K-Means'in belki de en iyi çıktılarından biri olan Heat Map aşağıdaki gibi her bir kümedeki verilerin dağılım yoğunluğunu göstermektedir. Veri dağılırken ortalamanın %100 altında yoğunlukla dağılabileceği gibi en fazla %650 yoğunlukta bulunduğu kümeye rastlanılmıştır. Dolayısıyla Heat Map'in alt limiti -%100 iken üst limiti %650 olarak belirlenmiştir. Bu grafiğe göre yoğun bulunan özellikler yeşil ile boyanıp renk koyulaştıkça bulunma sıklığı artmaktadır. Kırmızı tonlar ise ortalamaya göre nispeten o özelliğin o kümede daha az bulunduğunu ifade eder ve kırmızılık koyulaştıkça seyreklik artmaktadır. Beyaz ise ilgili özelliğin o kümede tüm verinin ortalaması kadar bulunduğunu gösterir. Örneğin öğrenci müşterilerin en fazla hangi kümede olduğunu tespit etmek için meslek=öğrenci sütunundan aşağıya doğru hangi kutucuğun en yeşil olduğuna bakılması gerekmektedir. Bu şekilde bakıldığında öğrenci yoğunluğunun en fazla olduğu kümenin, küme_2 olduğu görülmektedir. Bu kümenin diğer belirgin özellikleri bekar, çalışmayan, genellikle ilköğretim veya lise mezunu ve yaşça genç müşterilerden oluştuğu söylenebilir. Yaş ortalaması ve eğitim düzeyi yüksek olan kutucuklara baktığımızda bunların kırmızı ile boyandığını görürüz. Bu mantiken beklenen bir durumdur ve oldukça başarılı bir kümeleme yapıldığını gösterir.



Şekil 4.2: Heat Map

Ayrıca her bir kümede en belirleyici olan özellikleri ortalamaya göre ne kadar az ya da fazla yoğunlukta bulunduğunu gösteren küme dağılımı grafiği de aşağıdaki gibidir:



Şekil 4.3: Kümelerdeki Baskın Özellikler Genel Görünüm

4.1.2. Oluşturulan Kümelerin İncelenmesi

Yapılan kümeleme sonucunda oluşturulan kümeler tek tek incelenecek olunursa ilk küme olan küme_0'a ait tablolar aşağıdaki gibidir. Küme_0'daki dağılım tüm verinin ortalamasına göre %187 oranda daha fazla meslek=memur, %180 oranda daha fazla ev=var ve %177 oranla daha fazla meslek=avukat grubundaki müşterileri içermektedir. Bir diğer deyişle küme_0'da memur veya avukat olup evi olan müşteriler diğer kümelere nazaran yoğun olarak bulunmaktadır. Her iki meslek grubu da minimum lisans mezuniyeti gerektirdiğinden bu kümedeki müşterilerin eğitim düzeyi ve maddi durumunun iyi olduğu yorumu yapılabilir. Ayrıca Heat Map'ten görülebileceği üzere bu kümede doktora ve yüksek lisans mezuniyeti diğer kümelere nazaran yoğun olarak bulunmakta olup yaş ortalaması yüksektir. Dolayısıyla bu küme “maddi durumu iyi & eğitim düzeyi yüksek müşteriler” olarak adlandırılabilir.


Cluster 0

174

meslek = Memur is on average 187.36% larger, ev = Var is on average 180.07% larger, meslek = Avukat is on average 177.45% larger

Şekil 4.4: Küme_0 Baskın Özellikleri

Bir diğer çıktı olan grafikte her kümenin en baskın 2 özelliğine göre müşterilerin dağılımı gösterilmektedir. Küme_0'ın en baskın özelliği ise ev sahibi ve meslek olarak memur olma olduğu için grafik bu kriterlere göre şekillenmiş olup aşağıdaki gibidir. Bu dağılıma göre koyu mavi ile renklendirilen küme_0 müşterilerinin her iki kriter için de yoğunluk olarak sıfırın üstünde konumlandığı görülmektedir.



Şekil 4.5: Küme_0 Dağılım Detayı Grafiği

Küme_1'deki dağılım tüm verinin ortalamasına göre %234 oranla daha fazla medeni durum=bekar, %211 oranla daha fazla meslek=öğrenci ve %201 oranla daha fazla yaş aralığı=21-30 grubundaki müşterileri içermektedir. Bir diğer deyişle küme_1'de daha genç

müşteriler bulunmaktadır. Bunlar da doğal olarak bekar ve öğrenci çoğunluktadır. Ayrıca Heat Map'e göre O yüzden bu küme "öğrenci veya yeni mezunlar" olarak adlandırılabilir.

Cluster 1

125

medeni_durum = Bekar is on average 234.25% larger, meslek = Öğrenci is on average 211.11% larger, yas_araligi = 21-30 is on average 201.11% larger

Şekil 4.6: Küme_1 Baskın Özellikleri

Küme_1'in en baskın özelliği bekar ve öğrenci olma olduğu için grafik bu kriterlere göre şekillenmiş olup aşağıdaki gibidir. Bu dağılıma göre açık mavi ile renklendirilen küme_1 müşterilerinin her iki kriter için de yoğunluk olarak sıfırın üstünde konumlandığı, özellikle sağ üstte bulunan kümede hem öğrencilik hem de bekarlık kriterini karşılayan müşterilerin yoğun bulunarak küme oluşturduğu görülmektedir.



Şekil 4.7: Küme_1 Dağılım Detayı Grafiği

Küme_2'deki dağılım tüm verinin ortalamasına göre %232 oranla daha fazla medeni durum=bekar, %328 oranla daha fazla meslek=öğrenci ve %139 oranla daha fazla meslek=işçi grubundaki müşterileri içermektedir. Bir diğer deyişle küme_2'de eğitim durumu daha düşük

ve genç müşteriler bulunmaktadır. Ayrıca Heat Map’e göre de öğrenci yoğunluğunun en yoğun olduğu kümedir. Küme_1’den farklı olarak eğitim düzeyi yüksek değildir, meslek grubu olarak içerdiği tek meslek işçi grubundadır. O yüzden bu küme “lisans altı mezun” olarak adlandırılabilir.


Cluster 2

136

meslek = Öğrenci is on average 328.92% larger, medeni_durum = Bekar is on average 232.39% larger, meslek = İsci is on average 139.26% larger

Şekil 4.8: Küme_2 Baskın Özellikleri

Küme_2’nin en baskın özelliği bekar ve öğrenci olma olduğu için grafik bu kriterlere göre şekillenmiş olup aşağıdaki gibidir. Bu dağılıma göre koyu yeşil ile renklendirilen küme_2 müşterilerinin her iki kriter için de yoğunluk olarak sıfırın üstünde konumlandığı, özellikle sağ üstte bulunan kümede hem öğrencilik hem de bekarlık kriterini karşılayan müşterilerin küme_1’de olduğu gibi yoğun bulunarak küme oluşturduğu görülmektedir.



Şekil 4.9: Küme_2 Dağılım Detayı

Küme_3’teki dağılım tüm verinin ortalamasına göre %262 oranla daha fazla meslek=işçi, %283 oranla daha fazla eğitim=lise ve %100 oranla daha az eğitim=yüksek lisans grubundaki

müşterileri içermektedir. Ayrıca Heat Map’e göre de işçi yoğunluğunun en yoğun olduğu kümedir. Eğitim durumu liseden sonra çoğunlukla ilkökul düzeyindedir ve evli müşterilerden oluşmaktadır. Orta yaşlı bir kitle olup bazılarının evi vardır. Dolayısıyla bu küme “işçi müşteriler” olarak adlandırılabilir.


Cluster 3

103

egitim = Lise is on average 283.83% larger, meslek = Isci is on average 262.15% larger, egitim = Yuksek_lisans is on average 100.00% smaller

Şekil 4.10: Küme_3 Baskın Özellikleri

Küme_3’ün en baskın özelliği işçi ve lise mezunu olma olduğu için grafik bu kriterlere göre şekillenmiş olup aşağıdaki gibidir. Bu dağılıma göre fısık yeşili ile renklendirilen küme_3 müşterilerinin her iki kriter için de yoğunluk olarak sıfırın üstünde konumlandığı, özellikle sağ kısımda oluşan yoğunlaştığı görölmektedir.



Şekil 4.11: Küme_3 Dağılım Detayı

Küme_4’teki dağılım tüm verinin ortalamasına göre %681 oranla daha fazla meslek=ev hanımı, %277 oranla daha fazla çalışma durumu=çalışmıyor ve %113 oranla daha fazla egitim=ilköğretim grubundaki müşterileri içermektedir. Heat Map’e bakıldığında bu kriterler

haricinde baskın gelen bir kriter de görülmemektedir. Baskın olmamakla birlikte bazılarının evi vardır, bazıları lise mezunudur. 30 yaş üstü müşterilerden oluşmaktadır. Ev hanımı yoğunlukta olduğu için kadınlardan oluşan bir küme olduğu söylenebilir. Dolayısıyla bu küme “ev hanımı müşteriler” olarak adlandırılabilir.


Cluster 4

105

meslek = Ev Hanımı is on average 681.44% larger, calisma_durumu = Calismiyor is on average 277.67% larger, egitim = Ilkogretim is on average 113.68% larger

Şekil 4.12: Küme_4 Baskın Özellikleri

Küme_4’ün en baskın özelliği dışarıda herhangi bir işte çalışmıyor olma ve meslek olarak ev hanımlığı yapmak olduğu için grafik bu kriterlere göre şekillenmiş olup aşağıdaki gibidir. Bu dağılıma göre açık yeşil ile renklendirilen küme_4 müşterilerinin her iki kriter için de yoğunluk olarak sıfırın üstünde konumlandığı, özellikle sağ kısımda oluşan yoğunlaştığı görülmektedir.



Şekil 4.13: Küme_4 Dağılım Detayı

Küme_5’teki dağılım tüm verinin ortalamasına göre %333 oranla daha fazla çalışma durumu=emekli, %196 oranla daha fazla yaş aralığı=61 ve üstü, %186 oranla daha fazla yaş_aralığı=51-60 grubundaki müşterileri içermektedir. Heat Map’e bakıldığında eğitim ve meslek belirleyici unsurlar değildir. Ev sahibi olma da tüm verinin ortalaması kadardır, beyaz

ile renklendirilmiştir. Emekli yoğunlukta olduğu için yaş ortalaması yüksek bir küme olduğu söylenebilir. Dolayısıyla bu küme “emekli müşteriler” olarak adlandırılabilir.


Cluster 5

137

calisma_durumu = Emekli is on average 333.01% larger, yas_araligi = 61 ve ustü is on average 196.92% larger, yas_araligi = 51-60 is on average 186.56% larger

Şekil 4.14: Küme_5 Baskın Özellikleri

Küme_5’in en baskın 2 özelliği emekli ve ileri yaşlarda olmak olduğu için grafik bu kriterlere göre şekillenmiş olup aşağıdaki gibidir. Bu dağılıma göre hardal rengi ile renklendirilen küme_5 müşterilerinin her iki kriter için de yoğunluk olarak sıfırın üstünde konumlandığı, özellikle sağ kısımda oluşan yoğunlaştığı görülmektedir.



Şekil 4.15: Küme_5 Dağılım Detayı

Küme_6’daki dağılım tüm verinin ortalamasına göre %275 oranla daha fazla eğitim=doktora, %223 oranla daha fazla meslek=avukat ve %217 oranla daha fazla eğitim=yüksek lisans grubundaki müşterileri içermektedir. Heat Map’e bakıldığında mühendis ve danışmanlarında ortalamaya nazaran bu grupta yoğun bulunduğu, yaşın belirleyici olmadığı ve bu kümedeki müşterilerin genellikle ev sahibi olmadığı görülmektedir. Genel olarak en belirgin durum eğitim düzeyinin oldukça yüksek olmasıdır. Bu durum kişilerin finansal okur yazarlığının da yüksek

olduğu yorumunu yaptırabilir. 6. Küme “eğitim düzeyi yüksek müşteriler” olarak adlandırılabilir.


Cluster 6

96

egitim = Doktora is on average 275.00% larger, meslek = Avukat is on average 223.28% larger, egitim = Yuksek_lisans is on average 217.58% larger

Şekil 4.16: Küme_6 Baskın Özellikleri

Küme_6’nın en baskın 2 özelliği avukat ve doktora mezunu olmak olduğu için grafik bu kriterlere göre şekillenmiş olup aşağıdaki gibidir. Bu dağılıma göre kahverengi ile renklendirilen küme_6 müşterilerinin her iki kriter için de yoğunluk olarak sıfırın üstünde konumlandığı, özellikle sağ kısımda oluşan yoğunlaştığı görülmektedir.



Şekil 4.17: Küme_6 Dağılım Detayı

Küme_7’deki dağılım tüm verinin ortalamasına göre %195 oranla daha fazla meslek=öğretmen, %124 oranla daha fazla meslek=mühendis ve %109 oranla daha fazla meslek=danışman grubundaki müşterileri içermektedir. Heat Map’e bakıldığında 6. Küme kadar yoğun olmasa da yüksek lisans ve doktora mezuniyetlerinin bulunduğu, genel olarak genç ve mal sahibi müşterilerden oluşan bir küme olduğu görülmektedir. Genç, eğitim düzeyi ortalamasının üstünde,

meslek ve bir miktar maddi birikimi olan bir kümedir. Gezmeye, yatırım yapmaya yatkın bir müşteri grubu olabilir. Bu küme “ücretli çalışan genç&eğitimli müşteriler” olarak adlandırılabilir.


Cluster 7

124

meslek = Ogretmen is on average 194.67% larger, meslek = Muhendis is on average 124.01% larger, meslek = Danisman is on average 109.08% larger

Şekil 4.18: Küme_7 Baskın Özellikleri

Küme_7'nin en baskın 2 özelliği de meslek ile ilgili olduğu ve bir kişinin her iki unvana da aynı anda sahip olamayacağı için sağ üstte küme oluşmamıştır ancak sağ altta öğretmenlerden oluşan küme, sol üstte ise mühendislerden oluşan küme görülebilir.



Şekil 4.19: Küme_7 Dağılım Detayı

4.2. BİRLİKTELİK ANALİZİ

Kümeleme sonrasında hem her bir küme için hem de banka tarafından oluşturulan her bir değer segmenti için FP Growth algoritmasıyla birliktelik analizi yapılmıştır. Bu analiz çalışması sonucunda elde edilen bulgular aşağıdaki gibidir:

4.2.1. Kümelenen Veriye Uygulanan FP Growth

Veri setine yapılan kümelemenin optimum sonucunda Küme 0'dan Küme_7'ye kadar sıralanan 8 küme oluşmuştur. Bu kümelerin her birine FP Growth algoritması ile birliktelik analizi yapılmış ve her küme için üretilen kurallar 500 adet ile sınırlandırılmıştır. Bu kurallardan bazıları küme bazında aşağıdaki gibidir.

4.2.1.1. Küme_0

Çalışılan FP Growth analizi sonucunda Küme_0 için oluşan kurallardan bazıları aşağıdaki gibidir:

- [katılma_hesabi=evet]: 51 ==> [mobil_sube_kullanimi=evet]: 51 <conf:(1)> lift:(1.07) lev:(0.02) conv:(3.22)

Güven(conf.) değerinin 1 çıkmasından dolayı Küme 0'a dahil olan müşterilerden katılma hesabı olanların aynı zamanda mobil şubelerinin aktif olma olasılığının %100 olduğu söylenebilir; zira 3,22 çıkan ve aradaki ilişkinin gücünü gösteren conv. değeri de bunu ispatlar niteliktedir. Kümedeki katılım hesabı mobil şube kullanımını tetikleyip %107 arttırmaktadır. Son olarak bu iki ürünün birlikte var olma olasılığı ayrı olmasından %2 daha fazladır.

- [kiymetli_maden=evet, doviz=evet, katılma_hesabi=evet]: 30 ==> [debit_kart=evet, mobil_sube_kullanimi=evet]: 30 <conf:(1)> lift:(1.08) lev:(0.01) conv:(2.24)

Bu kümede kıymetli maden, katılma hesabı ve döviz hesabı aynı anda olan kişilerin tamamının aynı zamanda debit kartı da vardır; bu yüzden conf. değerinin 1 çıktığı görülmektedir. Bu 3 ürünün müşteride birlikte var olması debit kart satışını %108 arttırmaktadır. Birlikte bulunma ihtimalleri ayrı ayrı bulunma ihtimallerinden %1 fazladır. Bu oranın düşük olması debit kartın bağımsız da bulunabileceğini gösterir. Yine de aralarında 2,24 oranında bağ vardır.

- [debit_kart=evet]: 172 ==> [mobil_sube_kullanimi=evet]: 161 <conf:(0.94)> lift:(1) lev:(-0) conv:(0.91)

Bu kümede bulunan 172 debit kart sahibinin 161'inin mobil şubesi de vardır; bir diğer deyişle debit kart sahiplerinin %94'ü mobil şube kullanmaktadır. Debit kart mobil şube kullanımını %100 arttırmıştır. Lev değerinin negatif çıkması ayrı bulunma ihtimallerinin birlikte bulunma ihtimallerinden yüksek olduğunu gösterir. Conv. değerinin de 1'in altında olması birlikte bulunmaya dair aralarında ilişki bulunmadığını destekler.

- [kiymetli_maden=evet, premium_kredi_karti=evet, fatura_talimati=evet, bes=evet]: 21 ==> [debit_kart=evet, mobil_sube_kullanimi=evet]: 19 <conf:(0.9)> lift:(0.98) lev:(-0) conv:(0.52)

Aynı anda kıymetli maden, premium kredi kartı ve fatura talimatı sahibi müşterin %90'ı debit kart da kullanmaktadır. Bu ürünlerin birlikte kullanımı debit kart satışlarını 0,98 kat arttırmıştır; ancak debit kartın bu 3 ürünün birlikteliğinden bağımsız da çokça var olabileceğini düşük çıkan lift ve conv. değerlerinden gözlemlenebilir.

4.2.1.2. Küme_1

- [debit_kart=evet, arac_finansmani=evet]: 59 ==> [hayat_sigortasi=evet]: 59 <conf:(1)> lift:(1.28) lev:(0.1) conv:(12.74)

Debit kartı ve araç finansmanı olan küme 1 müşterilerinin tamamının hayat sigortası da vardır. bu ürünlerin satışı hayat sigortasının satışını 1,28 kat arttırmıştır. Araç finansmanı kullanan herkese hayat sigortası satılmış olması muhtemeldir; zira conv değeri oldukça yüksektir, aralarındaki ilişki güçlüdür. Çoğunlukla bu küme için birlikte bulunsalar da yine de hayat sigortası bu iki üründen bağımsız da bulunabilir. Birlikte bulunma ihtimalleri bağımsız bulunma ihtimallerinden %10 fazladır.

- [mobil_sube_kullanimi=evet, arac_finansmani=evet]: 54 ==> [hayat_sigortasi=evet]: 54 <conf:(1)> lift:(1.28) lev:(0.09) conv:(11.66)

Küme 1 müşterilerinden mobil şubesi ve araç finansmanı olan müşterilerin tamamının hayat sigortası da vardır. Bu ürünlerin satışı hayat sigortasının satışını 1,28 kat arttırmıştır. Araç finansmanı kullanan herkese hayat sigortası satılmış olması muhtemeldir; zira conv değeri bir önceki kuraldaki kadar olmasa da yine de yüksektir, aralarındaki ilişki güçlüdür. Çoğunlukla bu küme için birlikte bulunsalar da yine de hayat sigortası bu iki üründen bağımsız da bulunabilir. Birlikte bulunma ihtimalleri bağımsız bulunma ihtimallerinden %9 fazladır.

- [hayat_sigortasi=evet, ihtiyac_finansmani=evet, kredi_karti=evet]: 33 ==> [arac_finansmani=evet]: 30 <conf:(0.91)> lift:(1.75) lev:(0.1) conv:(3.96)

Hayat sigortası, ihtiyaç finansmanı ve kredi kartı ürünlerini birlikte kullanan müşterilerin %91'i araç finansmanı da kullanmıştır. Bu 3 ürüne sahip olan müşteriler sayesinde küme 1'de araç finansmanı satışları 1,75 kat artmıştır. Aralarında 3,96 ile ilişki olsa da araç finansmanı bu 3 ürünün birlikte varlığından bağımsız da bulunabilmektedir. Yine de birlikte bulunma ihtimalleri araç finansmanının bağımsız olarak bulunma ihtimalinden %10 fazladır.

- [arac_finansmani=evet]: 65 ==> [ihtiyac_finansmani=evet]: 55 <conf:(0.85)> lift:(1.39) lev:(0.12) conv:(2.32)

Küme 1 müşterilerinden araç finansmanı kullananların %85'i ihtiyaç finansmanı da kullanmıştır. Araç finansmanı ihtiyaç finansmanı satışlarını 1,39 kat artırmış olup aralarında 2,32 değerinde bağlantı bulunmaktadır. Birlikte bulunma olasılıkları ayrı ayrı bulunma olasılıklarından %12 fazladır.

- [arac_finansmani=evet]: 65 ==> [mobil_sube_kullanimi=evet]: 54 <conf:(0.83)> lift:(1.06) lev:(0.02) conv:(1.17)

Küme 1 müşterilerinden araç finansmanı kullananların %83'ü mobil şubeyi de kullanmıştır. Araç finansmanı mobil şube kullanımını 1,06 kat artırmış olup conv. değerinin 1'den büyük olmasından dolayı aralarında bağlantı bulunduğu yorumu yapılabilir. Bu küme için birlikte bulunma olasılıkları ayrı ayrı bulunma olasılıklarından %2 fazladır.

- [premium_kredi_karti=evet]: 29 ==> [mobil_sube_kullanimi=evet]: 24 <conf:(0.83)> lift:(1.06) lev:(0.01) conv:(1.04)

Küme 1 müşterilerinden premium kredi kartı kullananların %83'ü mobil şubeyi kullanmaktadır. Premium kredi kartı mobil şube kullanımını 1,06 kat artırmış olup aralarında güçlü olmasa da olsa bağlantı bulunmaktadır, conv değeri 1'den büyüktür. Birlikte bulunma olasılıkları ayrı ayrı bulunma olasılıklarından %1 fazladır, ayrı ayrı da bulunabilir.

4.2.1.3. Küme_2

- [arac_finansmani=evet]: 41 ==> [hayat_sigortasi=evet]: 41 <conf:(1)> lift:(2.83) lev:(0.2) conv:(26.53)

Küme 2'ki araç finansmanı kullanan 41 müşterinin tamamı hayat sigortası da kullanmıştır. Araç finansmanı ile birlikte hayat sigortası da satıldığı için bu beklenen bir durumdur. Araç finansmanı satışı hayat sigortası satışını küme 2'de 2,83 kat arttırmıştır. Birlikte bulunma ihtimalleri ayrı bulunma ihtimallerinden %20 fazladır. 26,53 ile aralarında çok ciddi bir ilişki mevcuttur.

- [katilma_hesabi=evet]: 30 ==> [debit_kart=evet]: 29 <conf:(0.97)> lift:(1.1) lev:(0.02) conv:(1.88)

Katılma hesabı olan küme 2 müşterilerininin %97'sinin debit kartı da vardır. İkili arasında ilişki olsa da debit kart olamama durumunda katılım hesabı bulunabilir. Yine de birlikte bulunma ihtimalleri ayrı bulunma ihtimallerinden %2 fazladır. Katılma hesabı debit kart satışını 1,1 kat arttırmıştır.

- [kiymetli_maden=evet]: 57 ==> [debit_kart=evet]: 51 <conf:(0.89)> lift:(1.02) lev:(0.01) conv:(1.02)

Kıymetli maden hesabı olan küme 2 müşterilerininin %89'unun debit kartı da vardır. kıymetli maden hesabı açılışı bu kümedeki debit kart sahibi olmayı %100'den fazla arttırmıştır. Birlikte bulunma olasılıklar ayrı ayrı bulunma olasılıklarıyla neredeyse aynıdır. Aralarında güçlü olmasa da ilişki vardır.

- [debit_kart=evet, hayat_sigortasi=evet, arac_finansmani=evet]: 36 ==> [mobil_sube_kullanimi=evet]: 31 <conf:(0.86)> lift:(1.15) lev:(0.03) conv:(1.5)

Debit kart, hayat sigortası ve araç finansmanı kullanan müşterin %86'sının aynı zamanda mobil şube kullanımı da mevcuttur. Bu ürün grubunun tamamını kullanılması küme 22 müşterilerinin mobil şube kullanımını %115 arttırmıştır. Birlikte bulunma olasılıklar ayrı ayrı bulunma olasılıklarıyla neredeyse aynıdır. Aralarında güçlü olmasa da ilişki vardır.

- [arac_finansmani=evet]: 41 ==> [ihtiyac_finansmani=evet]: 33 <conf:(0.8)> lift:(1.95) lev:(0.12) conv:(2.68)

Küme 2’de araç finansmanı kullananların %80’i ihtiyaç finansmanı da kullanmış ve araç finansmanı satışları ihtiyaç kart satışlarını nedereyse 2 kat arttırmıştır. Birlikte bulunma olasılıkları ayrı bulunma olasılıklarından %12 fazladır.aralarında ilişki vardır ve bu ilişki 2,68 değerince güçlüdür.

4.2.1.4. Küme_3

- [bes=evet]: 33 ==> [debit_kart=evet]: 33 <conf:(1)> lift:(1.03) lev:(0.01) conv:(0.96)

Küme 3’teki BES kullanan müşterilerin %100’ü aynı zamanda debit kart da kullanmaktadır. BES satışları debit kart satışlarını 1,03 kat arttırmıştır. Birlikte bulunma ihtimalleri ayrı ayrı bulunma ihtimalleriyle neredeyse aynıdır. Conv. değeri 1’in altında olduğu için aralarında ilişki bulunmamaktadır.

- [konut_finansmani=evet]: 12 ==> [hayat_sigortasi=evet]: 12 <conf:(1)> lift:(5.72) lev:(0.1) conv:(9.9)

Küme 3’teki konut finansmanı kullanan 12 müşterinin tamamı hayat sigortası da kullanmıştır. Konut finansmanı ile birlikte hayat sigortası da satıldığı için bu beklenen bir durumdur. Konut finansmanı satışı hayat sigortası satışını küme 3’te 5,72 kat arttırmıştır. Birlikte bulunma ihtimalleri ayrı bulunma ihtimallerinden %10 fazladır. 9,9 ile aralarında güçlü bir ilişki mevcuttur.

- [debit_kart=evet, konut_finansmani=evet]: 12 ==> [dask=evet]: 12 <conf:(1)> lift:(8.58) lev:(0.1) conv:(10.6)

Hem debit kartı hem de konut finansmanı olan küme 3 müşterilerin tamamının dask’ı da vardır. Debit kart ve konut finansmanı sahibi olan müşteriler sayesinde küme 3’teki dask satışları 8,58 kat artmıştır. Buradaki ilişkinin debit karttan ziyade konut finansmanından kaynaklandığı düşünülmektedir. İlişkilerinin gücünü gösteren değer 10,6 olup oldukça yüksektir.

- [doviz=evet, bes=evet]: 13 ==> [fatura_talimati=evet]: 11 <conf:(0.85)> lift:(3.01) lev:(0.07) conv:(3.11)

Küme 3 içindeki hem döviz hesabı hem BES’i olan müşterilerin%85’inin aynı zamanda fatura talimatı da vardır. Bu müşteriler fatura talimatı satışlarını 3 kat arttırmıştır. Birlikte bulunma ihtimalleri ayrı bulunma ihtimallerinden %7 fazladır.

4.2.1.5. Küme_4

- [doviz=evet]: 32 ==> [debit_kart=evet]: 32 <conf:(1)> lift:(1.05) lev:(0.01) conv:(1.52)

Küme 4'teki döviz hesabı olan tüm müşterilerin tamamının debit kartı da vardır ancak bu birliktelik aralarındaki gücün fazlalığını ifade etmemektedir. Conv. değeri 1'in üstünde olduğu için ilişkileri olduğu görülse de çok yüksek bir değerde olmadığı için bu ilişki güçlü değildir. Döviz hesabı küme 3'teki debit kart satışını 1,05 kat arttırmaktadır.

- [katılma_hesabi=evet]: 33 ==> [kiymetli_maden=evet]: 31 <conf:(0.94)> lift:(1.37) lev:(0.08) conv:(3.46)

Katılma hesabı olan küme 4 müşterilerinin %94'ünün kıymetli maden hesabı da vardır. Katılma hesabı bu kümedeki kıymetli maden hesabı açılışlarını 1,37 kat arttırmıştır. Birlikte bulunma olasılıkları ayrı bulunma olasılıklarından %8 fazladır. Aralarında 3,46 ile güçlü bir ilişki vardır.

- [kredi_karti=evet, katılma_hesabi=evet]: 13 ==> [kiymetli_maden=evet]: 12 <conf:(0.92)> lift:(1.35) lev:(0.03) conv:(2.04)

Küme 4 müşterilerinden kredi kartı ve katılma hesabı olan müşterilerin %92'sinin kıymetli hesabı da vardır. Bu ürünler kıymetli maden satışını 1,35 kat arttırmaktadır. Birlikte bulunabilecekleri gibi müşteriler tarafından ayrı ayrı da kullanılabilir. Bu ürünlerin küme 4 müşteri tarafından birlikte kullanılma olasılığı ayrı bulunma olasılığından %3 fazladır.

- [katılma_hesabi=evet]: 33 ==> [debit_kart=evet]: 29 <conf:(0.88)> lift:(0.92) lev:(-0.02) conv:(0.31)

Küme 4 müşterilerinden katılma hesabı olanların %88'inin debit kartı da vardır. Katılma hesabı debit kart satışlarını bu kümede %92 arttırmaktadır. Birlikte bulunma olasılıkları ayrı bulunma olasılıklarıyla neredeyse aynıdır. Birbirlerinin satışını etkilememekle birlikte aralarında ilişki bulunmamaktadır.

- [bes=evet]: 22 ==> [mobil_sube_kullanimi=evet]: 18 <conf:(0.82)> lift:(1.13) lev:(0.02) conv:(1.22)

BES'i olan Küme 4 müşterilerinin %82'sinin mobil şubesi de vardır. Bu kümede BES satışları mobil şube kullanımını %113 arttırmaktadır. Birlikte bulunma olasılıkları ayrı bulunma

olasılıklarıyla neredeyse aynıdır. Conv. değeri 1'in üstünde olduğu için aralarında ilişki olduğu görülmektedir.

4.2.1.6. Küme_5

- [kasko=evet]: 55 ==> [debit_kart=evet]: 55 <conf:(1)> lift:(1.01) lev:(0) conv:(0.4)

Kaskosu olan küme 5 müşterilerinin tamamının debit kartı da vardır ancak bu birliktelik aralarında ilişki olduğunu kanıtlamaz zira conv. değeri 1'in altındadır ve bu aralarında ilişki bulunmadığını gösterir. Birlikte bulunma ihtimalleri ayrı bulunma ihtimalleriyle tamamen aynıdır.

- [kredi_karti=evet, hgs=evet]: 21 ==> [debit_kart=evet, kasko=evet]: 21 <conf:(1)> lift:(2.49) lev:(0.09) conv:(12.57)

Küme 5 müşterilerinden hem kredi kartı hem HGS'si olanların aynı zamanda debit kartı ve kaskosu da vardır. Kredi kartı ve HGS debit kart ve kasko satışlarını 2,49 kat arttırmakta olup aralarında 12,57'lik conv. değeri ile güçlü bir ilişki bulunmaktadır. Birlikte bulunma ihtimalleri ayrı ayrı bulunma ihtimallerinden %9 fazladır.

- [katılma_hesabi=evet]: 28 ==> [debit_kart=evet]: 27 <conf:(0.96)> lift:(0.97) lev:(-0.01) conv:(0.1)

Katılma hesabı bulunan küme 5 müşterinin %96'sının debit kartı da vardır ancak sayısal olarak bu fazlalık ilişkiyi göstermez. Ayrı bulunma ihtimalleri birlikte bulunma ihtimallerinden fazladır ve küme 5 özelinde bu iki ürün arasında ilişki bulunmamaktadır.

- [katılma_hesabi=evet]: 28 ==> [kiymetli_maden=evet]: 24 <conf:(0.86)> lift:(1.35) lev:(0.05) conv:(2.04)

Katılma hesabı olan küme 5 müşterilerinin %86'sının kıymetli maden hesabı da bulunmaktadır. Katılma hesabı satışları kıymetli maden hesabı satışlarını 1,35 kat arttırmakta olup bu iki ürünün birlikte bulunma ihtimali ayrı ayrı bulunma ihtimalinden %5 fazladır. Aralarında 2,04'lük ilişki bulunmaktadır.

- [premium_kredi_karti=evet]: 17 ==> [kiymetli_maden=evet]: 14 <conf:(0.82)> lift:(1.3) lev:(0.02) conv:(1.55)

Premium kredi kartı olan küme 5 müşterilerinin %82'sinin kıymetli maden hesabı da vardır. Premium kredi kartı cari hesapta yüksek meblağ gerektirdiğinden bu müşterilerin altın caride bulunan altın birikimlerinden dolayı Premium kredi kartı aldıkları yorumu yapılabilir. Aralarında 1,55 ile ilişki vardır.

4.2.1.7. Küme_6

- [kiymetli_maden=evet]: 48 ==> [mobil_sube_kullanimi=evet]: 48 <conf:(1)> lift:(1.02) lev:(0.01) conv:(1)

Küme 6 müşterilerinden kıymetli maden hesabı olan 48 kişinin hepsi mobil şube kullanıcısıdır. Kıymetli maden hesabı mobil şube kullanımını 1,02 kat arttırmaktadır. Birlikte bulunma olasılıkları ayrı ayrı bulunma olasılıklarıyla neredeyse aynıdır. Conv. değeri 1'den büyük olduğu için aralarında ilişki olduğu görülmektedir.

- [konut_finansmani=evet]: 43 ==> [hayat_sigortasi=evet]: 43 <conf:(1)> lift:(2.23) lev:(0.25) conv:(23.74)

Konut finansmanı kullanan küme 6 müşterilerinin tamamının hayat sigortası da vardır. Konut finansmanı satışları hayat sigortası satışını 2,23 kat arttırmıştır. Aralarında 23,74 ile çok güçlü bir bağ bulunmaktadır. Birlikte bulunma ihtimalleri ayrı bulunma ihtimallerinden %25 fazladır.

- [dask=evet]: 43 ==> [hayat_sigortasi=evet]: 43 <conf:(1)> lift:(2.23) lev:(0.25) conv:(23.74)

Küme 6'daki dask kullanan müşterilerin tamamı aynı zamanda hayat sigortası da kullanmıştır. Dask satışı hayat sigortası satışını 2,23 kat arttırmış olup bir önceki kuralda olduğu gibi aralarında 23,74 ile çok güçlü bir bağ bulunmaktadır ve birlikte bulunma ihtimalleri ayrı bulunma ihtimallerinden %25 fazladır. Bu benzerlik konut finansmanı kullanan müşterilere hayat sigortası yapılması ve genellikle mecburi olmasa da konut sigortası kullanılırken alınan konutun dask'ının da beraberinde yapılmasından kaynaklanmaktadır.

- [mobil_sube_kullanimi=evet, debit_kart=evet, kredi_karti=evet, hayat_sigortasi=evet, dask=evet]: 27 ==> [konut_finansmani=evet]: 27 <conf:(1)> lift:(2.23) lev:(0.16) conv:(14.91)

Mobil şube kullanıp debit kart ve kredi kartına sahip olan küme 6 müşterilerinin tamamı aynı zamanda konut finansmanı da kullanmıştır. Bu ürünlerin kullanımı konut sigortasının satışını

2,23 kat arttırmıştır. Birlikte bulunma ihtimalleri ayrı bulunma ihtimallerinden %16 fazladır aralarında 14,91 ile güçlü bir bağ bulunmaktadır. Bu kadar ürünün bir arada bulunup ilişkisinin güçlü olması bu kümede yüksek segment müşteri bulunduğunu göstermektedir.

- [hgs=evet]: 32 ==> [mobil_sube_kullanimi=evet]: 31 <conf:(0.97)> lift:(0.99) lev:(-0) conv:(0.33)

HGS sahibi küme 6 müşterilerinin %97'si mobil şube kullanmaktadır. Debit kartın hemen hemen herkese verilmesinden dolayı sayısal olarak fazlalığı bulundan dolayı diğer ürünlerden bağımsız olarak her kümede sayısı fazladır. Conv. değeri 1'in altında çıkmasından dolayı aralarında ilişki bulunmadığı görülmektedir.

4.2.1.8. Küme_7

- [debit_kart=evet, konut_finansmani=evet]: 19 ==> [dask=evet]: 19 <conf:(1)> lift:(6.53) lev:(0.13) conv:(16.09)

Debit kart ve konut finansmanı kullanan küme 7 müşterilerinin tamamı aynı zamanda dask da kullanmıştır. Debit kart ve konut finansmanının her ikisini de kullanan müşteriler sayesinde dask satışları 6,53 kat artmıştır. Bu ürünlerin birlikte bulunma olasılıkları ayrı bulunma olasılıklarından %13 fazladır. 16,09'luk conv değeriyle aralarında güçlü ilişki bulunmaktadır.

- [bes=evet, arac_finansmani=evet]: 23 ==> [hayat_sigortasi=evet]: 23 <conf:(1)> lift:(2.43) lev:(0.11) conv:(13.54)

Küme 7'deki BES ve araç finansmanı kullanan müşterilerin tamamı hayat sigortası da kullanmaktadır. Asıl ilişkili ürün araç finansmanıdır. Araç finansmanı satışında hayat sigortası da satılıp BES'in tanıtımı yapılıyor olması muhtemeldir. Aralarında 13,54 ile güçlü bir ilişki bulunmaktadır. Birlikte bulunma olasılıkları ayrı bulunma olasılıklarından %11 fazladır.

- [doviz=evet]: 55 ==> [mobil_sube_kullanimi=evet]: 53 <conf:(0.96)> lift:(1.07) lev:(0.03) conv:(1.77)

Döviz kullanan kü e 7 müşterilerinin %96'sı mobil şube de kullanmaktadır. Döviz hesabı bu kümedeki müşterilerin mobil şube kullanımını 1,07 kat arttırmaktadır. Anlık kur takipleri ve döviz&alım satımı için mobil şube gerekli olduğundan dolayıbu ilişki beklenen bir durumdur. Mobil şube döviz hesabının varlığından bağımsız da bulunabileceği için lev, değeri yüksek değildir. Birlikte bulunma olasılıkları ayrı bulunma olasılıklarından sadece %3 fazladır.

- [kredi_karti=evet, bes=evet]: 41 ==> [mobil_sube_kullanimi=evet]: 38 <conf:(0.93)> lift:(1.03) lev:(0.01) conv:(0.99)

Kredi kartı ve BES'i olan 41 müşteriden 38'inin aynı zamanda mobil şubesi de kullanılıyor durumdadır. Bu ürünler mobil şube kullanımını 1,03 kat arttırmıştır. Birlikte bulunma olasılıklarıyla ayrı bulunma olasılıkları neredeyse aynıdır. İlişkileri de 0,99'la neredeyse var olarak yorumlanabileceği için ilişki olmadığını söylemek güçtür.

- [hayat_sigortasi=evet, fatura_talimati=evet]: 24 ==> [kredi_karti=evet]: 22 <conf:(0.92)> lift:(1.24) lev:(0.03) conv:(2.06)

Hayat sigortası ve fatura talimatı olan küme 7 müşterilerinin %92'sinin kredi kartı da vardır. Bu ürünler kredi kartı satışlarını küme 7 özelinde 1,24 kat arttırmaktadır. Conv. değeri 1'den büyük çıktığı için aralarında ilişki olduğu görülmektedir.

4.2.2. Banka Değer Segmentlerine Uygulanan FP Growth

4.2.2.1. A1 Segmenti Kümesi

Analiz sonucunda oluşan kurallardan ilk 117'sinin conf. değeri 1 çıkmıştır.

- [konut_sigortasi=evet]: 22 ==> [premium_kredi_karti=evet]: 20 <conf:(0.91)> lift:(1.05) lev:(0.02) conv:(0.99)

Konut sigortası kullanan A1 müşterilerin %91'inin Premium kredi kartı vardır. Bu ürünlerin birlikte bulunma olasılığı ayrı bulunma olasılığından %2 fazladır; ancak ilişkilerinin olup olmadığıyla ilgili yorum yapmak oldukça güçtür çünkü conv değeri 0,99 çıkarak 1'in altında kalmıştır.

- [doviz=evet]: 33 ==> [fatura_talimati=evet]: 30 <conf:(0.91)> lift:(1.15) lev:(0.08) conv:(1.75)

Döviz hesabı olan A1 müşterilerinden %91'inin aynı zamanda fatura talimatı da vardır. Döviz hesabı fatura talimatını 1,15 kat arttırmaktadır. Bu ürünlerin birlikte bulunma olasılığı ayrı bulunma olasılığından %8 fazla olup aralarında 1,75 ile ilişki olduğu görülmektedir.

- [premium_kredi_karti=evet, konut_sigortasi=evet]: 20 ==> [debit_kart=evet, kıymetli_maden=evet]: 18 <conf:(0.9)> lift:(1.09) lev:(0.03) conv:(1.15)

A1 kümesindeki Premium kart ve konut sigortası kullanan 20 kişinin 18'i debit art ve kıymetli maden hesabına da sahiptir. Premium kart ve konut sigortası kullanan müşteriler debit kart ve kıymetli maden hesabı satışını 1,09 kat arttırmaktadır. Ürün grupları arasında ilişki olduğu görülmektedir.

4.2.2.2. A2 Segmenti Kümesi

- [debit_kart=evet, konut_finansmani=evet]: 16 ==> [hayat_sigortasi=evet]: 16
<conf:(1)> lift:(4.85) lev:(0.13) conv:(12.7)

Hem debit kartı hem de konut finansmanı olan 16 müşterinin aynı zamanda hayat sigortası da vardır. debit kart ve konut finansmanının bir arada bulunması hayat sigortası satışını 4,85 kat arttırmaktadır. Aralarında 12,7 ile çok güçlü bir ilişki bulunmaktadır. Birlikte bulunmaları ayrı bulunmalarından daha muhtemel olup %13'lük fark vardır.

- [mobil_sube_kullanimi=evet, hayat_sigortasi=evet, konut_finansmani=evet]: 15 ==> [dask=evet]: 15 <conf:(1)> lift:(6.06) lev:(0.13) conv:(12.53)

A2 müşterilerinden hem mobil şubesi hem de hayat sigortası ve konut finansmanı olan müşterilerin tamamının aynı zamanda dask'ı da vardır. ürünler arasında bir önceki kuralda olduğu gibi güçlü bir ilişki vardır. 12,53 conv. için yüksek bir değerdir. Ürün sayısı fazla olmasına rağmen birlikte bulunma olasılıkları ayrı bulunma olasılıklarından %13 fazladır.

- [yatirim_fonu=evet]: 38 ==> [debit_kart=evet, fatura_talimati=evet]: 37 <conf:(0.97)> lift:(1.12) lev:(0.04) conv:(2.55)

Yatırım fonu olan A2 müşterilerinin %97'sinin debit kartı ve fatura talimatı da vardır. Yatırım fonu bu ürünlerin kullanımını 1,12 kat arttırmaktadır. ilişkili olmalarına rağmen ayrı da bulunabilirler, yatırım fonu ile debit kart ve fatura talimatının birlikte bulunma ihtimali ayrı bulunma ihtimalinden %4 fazladır.

4.2.2.3. B Segmenti Kümesi

- [konut_finansmani=evet]: 46 ==> [hayat_sigortasi=evet]: 46 <conf:(1)> lift:(2.44) lev:(0.13) conv:(27.16)

Konut finansmanı kullanan B segment müşterilerin hepsinin hayat sigortası da vardır. konut finansmanı hayat sigortası satışlarını 2,44 kat arttırmıştır. Birlikte bulunma ihtimalleri ayrı

bulunma ihtimallerinden %13 fazladır. Bu fark araç finansmanı kullanan müşterilerin de hayat sigortası olmasından kaynaklanmaktadır. Aralarında 27,16 ile güçlü bir ilişki bulunmaktadır.

- [kiymetli_maden=evet, konut_finansmani=evet]: 34 ==> [debit_kart=evet, dask=evet]: 34 <conf:(1)> lift:(4.57) lev:(0.13) conv:(26.55)

Kıymetli maden hesabı olup konut finansmanı olan B segment müşterilerin hepsinin aynı zamanda debit kartı ve dask'ı da vardır. Kıymetli maden hesabı ve konut finansmanı kullanan müşteriler, debit kart ve dask satışını 4,57 kat arttırmaktadır. Birlikte bulunma ihtimalleri ayrı bulunma ihtimallerinden %13 fazladır. Conv değeri 26,55 almakla ürünler arasındaki ilişkinin güçlü olduğunu ispatlamaktadır.

- [debit_kart=evet, doviz=evet]: 107 ==> [mobil_sube_kullanimi=evet]: 93 <conf:(0.87)> lift:(1.04) lev:(0.02) conv:(1.19)

B segmenti müşterilerinden debit kartı ve döviz hesabı olanların %87'sinin mobil şube kullanımı da vardır. Bu ürünler mobil şube kullanımını 1,04 kat arttırmaktadır. Birlikte buldukları gibi ayrı ayrı da bulunmaktadır; yine de aralarında ilişki vardır.

4.2.2.4. C Segmenti Kümesi

- [hayat_sigortasi=evet, konut_finansmani=evet]: 45 ==> [dask=evet]: 45 <conf:(1)> lift:(6.96) lev:(0.12) conv:(38.53)

Hayat sigortası ve konut finansmanı kullanan C segment müşterilerin tamamının aynı zamanda dask'ı da vardır. bu ürünler dask satışını 6,96 kat arttırmaktadır. Birlikte bulunma ihtimalleri ayrı ayrı bulunma ihtimallerinden %12 fazladır. 39,53 ile aralarında güçlü bir ilişki vardır.

- [bes=evet]: 70 ==> [mobil_sube_kullanimi=evet]: 62 <conf:(0.89)> lift:(1.12) lev:(0.02) conv:(1.62)

C Segment müşterilerden BES kullananların %89'unun mobil şubeyi kullandığı görülmektedir. BES bu kümedeki mobil şube kullanımını 1,12 kat arttırmıştır. Birlikte bulunma ihtimalleri ile ayrı bulunma ihtimalleri arasında belirgin bir fark olmasa da conv. değeri 1'in üstünde olduğu için ilişkileri bulunmaktadır.

- [kredi_karti=evet, fatura_talimati=evet]: 50 ==> [mobil_sube_kullanimi=evet]: 43 <conf:(0.86)> lift:(1.09) lev:(0.01) conv:(1.3)

Kredi kartı ve fatura talimatı bulunan c segment müşterilerinin %86'sının mobil şube kullanımı vardır. bu ürünler mobil şube kullanımını 1,09 kat arttırmaktadır. Birlikte bulunma ihtimalleri ile ayrı bulunma ihtimalleri arasında belirgin bir fark olmasa da conv. değeri 1'in üstünde olduğu için ilişkileri bulunmaktadır.

4.2.2.5. D Segmenti Kümesi

- [bes=evet]: 35 ==> [debit_kart=evet]: 35 <conf:(1)> lift:(1.08) lev:(0.01) conv:(2.47)

BES'i olan 35 Dsegment müşterinin hepsinin debit kartı da bulunmaktadır. BES debit kart satışını 1,08 kat arttırmaktadır. Birlikte bulunma ihtimalleri ile ayrı bulunma ihtimalleri arasında belirgin bir fark olmasa da conv. değeri 1'in üstünde olduğu için ilişkileri bulunmaktadır.

- [ihtiyac_finansmani=evet]: 36 ==> [debit_kart=evet]: 35 <conf:(0.97)> lift:(1.05) lev:(0.01) conv:(1.27)

D segment müşterilerden ihtiyaç kart kullananların %97'sinin debit kartı da vardır. İhtiyaç finansmanı debit kart satışını 1,05 kat arttırmaktadır. Debit kartın neredeyse tüm müşterilere verildiği düşünülürse bu müşterilerin bankaya ihtiyaç finansmanı için geldiği yorumu yapılabilir. Birlikte bulunma ihtimalleri ile ayrı bulunma ihtimalleri arasında belirgin bir fark olmasa da conv. değeri 1'in üstünde olduğu için ilişkileri bulunmaktadır.

- [doviz=evet]: 51 ==> [debit_kart=evet]: 45 <conf:(0.88)> lift:(0.95) lev:(-0.01) conv:(0.51)

Döviz hesabı olan 51 D segment müşterisinin %88'inin debit kartı da mevcuttur. Bu uyuşma ilişkinin olduğunu göstermez, ürün fazlalığından da kaynaklanıyor olabilir; zira conv. değerine bakılırsa zaten ilişki olmadığı görülecektir çünkü 1'in altında değer almıştır.

4.2.2.6. P Segmenti Kümesi

Bu kümedeki müşterilerin ürün kullanımı bulunmadığından dolayı pasif olarak adlandırılmaktadır. Dolayısıyla FP Growth algoritmasıyla da herhangi bir kural tespit edilmemiştir.

5. TARTIŞMA

Yapılan uygulama ile ilk olarak kümeleme analizi, daha sonra oluşturulan kümelere ayrı ayrı birliktelik analizi yapılmıştır. Kümeleme esnasında K-Means algoritması uygulanmış daha sonrasında her bir kümeye FP Growth algoritması ile birliktelik analizi yapılmıştır. Ayrıca banka tarafından yapılan segmentasyon da bir çeşit kümeleme çalışması olduğundan dolayı her bir segmente de FP Growth algoritması uygulanarak sonuçlar karşılaştırılmıştır. Analiz sonuçlarına göre;

- Bankanın uyguladığı mevcut sistemde müşteriler kullandıkları ürün ve bankadaki maddi birikimlerine göre segmente edildikleri için banka potansiyel müşteriye (aktif olmamasından dolayı) satış yapma fırsatını kaçırabilmekteydi; ancak K-Means ile oluşturulan kümelerde müşteriler kullanılan ürün, maddi birikim anlamında incelendiği gibi ayrıca demografik özellikleri de incelenerek kümelerin karakteristik özellikleri belirlenmiştir. Bu şekilde müşterilerin tüketim alışkanlıklarının daha iyi tespit edilmesi sağlanmıştır.
- K-Means algoritması ile oluşturulan kümelere uygulanan birliktelik analizlerinde, bankanın segmentasyonu ile oluşan kümelere uygulanan birliktelik analizlerinden çok daha fazla kural ve ilişki saptandığından dolayı müşteri ihtiyacının daha iyi tespit edilmesiyle bankanın ürün satışları arttırılacaktır.
- Herhangi bir katılım bankasında müşterileri kümeleyerek her bir kümede biriken müşterileri ve müşterilere en uygun ürünlerin hangileri olduğu, küme içindeki müşterilerin ürünleri nasıl kombinasyonlarla satın aldıklarının ölçümlenebilir olduğu gösterilmiştir.
- Her müşteriye en uygun ürünün önerilmesiyle müşteri aktifliği dolayısıyla sadakati de arttırılması beklenmektedir.

Çalışma sırasında yaşanan en büyük zorluk literatürde İslami finans alanında yapay zekâ destekli çalışmaların yok denecek kadar az olması olmuştur. Bu sebeple atıf yapıp sonuçları karşılaştırılabilecek ürün önerme modeli içeren bir çalışma bulunmamaktadır. Bu çalışma ile

katılım bankacılığına karşı geleneksel bakış açısıyla dolu olan literatüre farklı bir bakış açısı sunulması amaçlanmaktadır.



6. SONUÇ VE ÖNERİLER

Günümüzde katılım bankacılığını seçen müşterin büyük çoğunluğu seçimini faiz hassasiyetiyle yapmaktadır. Bu hassasiyetle yaptığı tercihin sonucunda ise faizle çalışan bir bankaya kıyasla hem ürün hem hizmet anlamında daha verimsiz bir sistemle karşılaşmayı hak etmemektedir. Öte yandan katılım bankaları gerek devlet gerek özel kurumlarca belirlenen ekstra kısıtlarla ancak aksiyon alabilmektedir. Bu kısıtlar içerisinde konvensiyonel bankalarla rekabet etmeye çalışan katılım bankalarının potansiyel müşterisini tespit etmesi de müşterilerine en uygun ürünü önerip maksimum verim ile çalışmalarını sürdürmesi de oldukça kritik bir öneme sahiptir. En doğru müşteriye bulup bu müşteriye en uygun ürünü önermesiyle PR maliyetine katlanmadan maksimum verimliliğe ulaşacaktır. Bu çalışma katılım bankalarının müşterilerine ürün önerirken yapay zekâ tabanlı ürün önerme modellerinden faydalanmasının ne kadar faydalı olacağını ispatlar niteliktedir. İslami finans ile ilgili detaylı araştırmalar yapıp katılım bankacılığının işleyişi ve gelişimi ile ilgili bilgilere yer verilmiştir. Konvensiyonel bankacılıkla katılım bankacılığının farkını karşılaştırmalı olarak anlatıp faiz ile ticaretin farkına değinilmiştir. İslami finansın ardından yapay zekâ ile yapılan araştırmada birçok çalışmaya rastlanılsa da İslami değerler çerçevesinde yapay zekâ destekli çalışmaların yok denecek kadar az olduğu görülmüştür. Bu çalışma ile titizlikle veri toplama ile başlayan kapsamlı bir yolculuğa çıkılmış, ardından 1000 satırlık büyük bir test veri setinin temizlenmesini takiben veri ön işleme yapılmıştır. Daha sonra, metodolojilerin sıralı bir şekilde ilerlemesiyle derinlemesine bir analiz başlatılmıştır. Başlangıçta, K-Means algoritması kullanılarak kümeleme yapılmış ve veri kümesinin 8 kümeye ayrılmıştır. Daha sonra her bir küme, FP Growth algoritmasının merceğinde titiz bir incelemeye tabi tutularak birliktelik analizi yapılmıştır; bu şekilde kümelerin içindeki ilişkilerin ayrıntılı bir şekilde incelenmesi sağlanmıştır. Ayrıca FP Growth'u bankanın kendisi tarafından belirlenen müşteri gruplarına da uygulayarak bankanın özel segmentasyon kriterlerindeki ilişki kuralları sorgulanmıştır.

Analizin son ayağında, banka tarafından belirlenen değer segmentlerine uygulanan FP Growth'un sonuçları, kümeleme çalışmasından elde edilen sonuçlarla yan yana getirilmiştir. Bulgular, kümeleme temelli yaklaşımın üstün performans göstermesiyle birlikte ilişki analizinin etkinliğinde kayda değer bir eşitsizlik olduğunu ortaya koymuştur. Kümeleme ve

birliktelik analizinden oluřan bu titiz analiz alıřması, müşteri davranıřlarının ve tercihlerinin incelikli bir řekilde anlařılmasını saęlamıřtır.

Bu alıřma baz alınarak yapılacak alıřmalarda daha büyük veriyle ve eřitli hibrit önerme modelleriyle uygulama yapılması önerilmektedir. Bu řekilde modele farklı bir bakıř aısı getirilip alıřma geliştirilmiř olacaktır. Ayrıca bankadaki ödöl sisteminin de uygulamaya dahil edilmesi önerilen ürünün cazipliğini arttırmada etkili olacaktır.



KAYNAKLAR

Aktaş, H., Yüce, R., 2017, *Osmanlı Bankası: İmparatorluktan Cumhuriyete Türkiye'nin İlk Bankası*, İstanbul Bilgi Üniversitesi Yayınları, İstanbul.

Aktepe, İ. A., 2011, *İslam Hukuku Çerçevesinde Finansman ve Bankacılık*, Erkam Matbaası, İstanbul.

Alkan, A. M., Türkmen, H. K., 2018, An Analysis of The Factors Affecting The Development of Islamic Banking in Turkey, *International Journal of Islamic Economics and Finance Studies*, 4(1), 36-47.

Aysan, A. F., Disli, M., Duygun, M., 2017, Islamic Banks, Deposit Insurance Reform, And Market Discipline, *Journal of Financial Services Research*, 51(2), 257-282.

Bishop, C. M., 2006, *Pattern Recognition and Machine Learning*, Springer, New York.

Breiman, L., 2001, *Random Forests*, Machine Learning, In: Schapire, R. (ed), Chapter:1, Kluwer Academic Publishers, Netherland, 5-32.

Chappa, M. U, 2018, *İslam İktisadında Ahlak ve Adalet*, İSİFAM Yayınları, İstanbul

Cizakça, M., 1996, *Islamic Capitalism and Finance: Origins, Evolution, and the Future*, Edward Elgar Publishing, Kuala Lumpur.

Cutler, D. R., Edwards Jr, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J., 2007, Random Forests For Classification in Ecology. *Ecology*, 88(11), 2783-2792.

El-Gamal, M. A., 2006, *Islamic Finance: Law, Economics, and Practice*, Cambridge University Press.

Goodfellow, I., Bengio, Y., & Courville, A., 2016, *Deep Learning*, MIT Press, London, ISBN:201-6022-992.

Hastie, T., Tibshirani, R., Friedman, J., 2009, *The Elements Of Statistical Learning: Data Mining, Inference, and Prediction*. Springer Science & Business Media, New York, ISBN: 978-1-4899-0519-2.

Hassan, M.K., Aliyu, S., Huda, M., Rashid, M., 2019, A Survey on Islamic Finance and Accounting Standarts, *Borsa İstanbul Review*, 19(1), 1-13.

Haykin, S., 1999, *Neural Networks: A Comprehensive Foundation*, Prentice Hall, New Jersey.

İnalçık, H., 2000, *Osmanlı İmparatorluğu Klasik Çağ 1300-1600*, Yapı Kredi Yayınları, İstanbul.

Iqbal, Z., Mirakhor, A., 2011, *An Introduction to Islamic Finance: Theory and Practice*, John Wiley & Sons (Asia), Singapur.

Karakuş, S., Güçlü, M. T., 2017, Islamic Banking and Finance in Turkey: A Review And Analysis Of The Current State, *Journal of Islamic Finance*, 6(2), 23-34.

Karimov, A., Ergüven, M., 2014, Development of Islamic Banking in Turkey: Past, Present and Future, *International Journal of Economic Perspectives*, 8(2), 39-53.

Kettell, B., 2008, *Introduction to Islamic Banking&Finance*, Printhauss, London.

Khan, T., Bhatti, M. I., 2008, Risk Management: An Analysis of Issues in Islamic Financial Industry, *Thunderbird International Business Review*, 50(1), 15-34.

Koren, Y., & Bell, R., 2011, Advances in Collaborative Filtering, *Recommender Systems Handbook*, 145-186.

LeCun, Y., Bengio, Y., & Hinton, G., 2015, Deep Learning, *Nature*, 521(7553), 436-444.

Liaw, A., & Wiener, M., 2002, Classification and Regression by Random Forest, *R News*, 2(3), 18-22.

McCulloch, W. S., Pitts, W., 1943, A Logical Calculus of the Ideas Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 5(4), 115-133.

Odabaşı, M., Aktepe, İ. E., 2012, *Faizsiz Bankacılık Standartları*, AAOIFI, İstanbul.

Özsoy, A., Bozkurt, Ö., 2012, Osmanlı'da İslami Finans: Vakıf, Banka ve Esnaf Loncaları Üzerine Bir İnceleme, *Yönetim ve Ekonomi Araştırmaları Dergisi*, 10(1), 243-259.

Özsoy, M. Ş., 2012, *Sağlam Bankacılık Modeli ile Katılım Bankacılığına Giriş*, WINOMY, İstanbul

Pamuk, Ş., 2000, *A Monetary History of the Ottoman Empire*, Cambridge University Press, Cambridge.

Pireh, M., 2008, *Definition of Islamic Financial Instruments*, Islamic Finance Expert Securites & Exchange Organization (SEO), 21, Tahrán.

Rosenblatt, F., 1958, The perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65(6), 386-408.

Rumelhart, D. E., Hinton, G. E., Williams, R. J., 1986, Learning Representations By Back-Propagating Error, *Nature*, 323(6088), 533-536.

Savaşan, F., Yardımcıoğlu, F., Görmüş, Ş., Kaya, S., 2019, *İslam İktisadı Üzerine Söyleşiler*, İktisat Yayınları, İstanbul, ISBN: 978-605-81250-3-2.

Siddiqi, M. N., 2008, Islamic Banking and Finance in Theory and Practice: A Survey of State of the Art. *Islamic Economic Studies*, 15(2), 1-48.

Şeker, M., & Yıldırım, M., 2016, Osmanlı İmparatorluğu'nda Ahilik ve Loncaların Ekonomiye Katkısı, *Akademik Bakış Dergisi*, 58, 1-11.

Usmani, M. T., 2002, *An Introduction to Islamic Finance*. Kluwer Law International, Netherlands.

Veranyurt, Ü., Deveci, A.F., Esen, M. F., Veranyurt, O., 2020, Makine Öğrenmesi Teknikleriyle Hastalık Sınıflandırması: Random Forest, K-Nearest Neighbour ve Adaboost, *International Journal of Health Management and Strategies Research*, 6(2), 2149-6161.

Vogel, F. E., & Hayes, S. L., 1998, *Islamic Law and Finance: Religion, Risk, and Return* Kluwer Law International, Netherlands.

Warde, I., 2000, *Islamic Finance in the Global Economy*, Edinburgh University Press, Edinburgh.

Wold, S., Esbensen, K., & Geladi, P., 1987, Principal Component Analysis, *Chemometrics and Intelligent Laboratory Systems*, 2(1-3), 37-52.

Yılmaz, E., Duman, Y. S., 2016, Islamic banking in Turkey: Current state and future prospects. *Journal of Islamic Economics, Banking and Finance*, 12(4), 50-65.

Yılmaz, K., Özdağoğlu, A., 2020, *Awareness Analysis of Industry 4.0*, Ekin Basım Yayın Dağıtım, İstanbul, ISBN: 978-625-7090-21-6.



İNTİHAL RAPORU İLK SAYFASI

Pelin Nazlı Ezber

ORJİNALLIK RAPORU

%9

BENZERLİK ENDEKSİ

%8

İNTERNET KAYNAKLARI

%3

YAYINLAR

%3

ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1

acikbilim.yok.gov.tr

İnternet Kaynağı

%2

2

Submitted to The Scientific & Technological
Research Council of Turkey (TUBİTAK)

Öğrenci Ödevi

%1

3

easychair-www.easychair.org

İnternet Kaynağı

%1

4

dergipark.org.tr

İnternet Kaynağı

<%1

5

pdffox.com

İnternet Kaynağı

<%1

6

core.ac.uk

İnternet Kaynağı

<%1

7

docplayer.biz.tr

İnternet Kaynağı

<%1

8

www.tkbb.org.tr

İnternet Kaynağı

<%1

9

repositorio.ug.edu.ec

İnternet Kaynağı

<%1