



Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü

İşletme Anabilim Dalı

Sayısal Yöntemler Bilim Dalı

# YAPAY SİNİR AĞLARI DESTEKLİ ETKİNLİK ÖLÇÜMÜ: VERİ ZARFLAMA ANALİZİ ÜZERİNE UYGULAMALAR

Irmak UZUN BAYAR

Doktora Tezi

Ankara, 2023



Yapay Sinir Ağları Destekli Etkinlik Ölçümü:  
Veri Zarflama Analizi Üzerine Uygulamalar

Irmak UZUN BAYAR

Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü  
İşletme Anabilim Dalı  
Sayısal Yöntemler Bilim Dalı

Doktora Tezi

Ankara, 2023

## KABUL VE ONAY

İrmak UZUN BAYAR tarafından hazırlanan "Yapay Sinir Ağları Destekli Etkinlik Ölçümü: Veri Zarflama Analizi Üzerine Uygulamalar" başlıklı bu çalışma, 16/12/2022 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Doktora Tezi olarak kabul edilmiştir.

---

Prof. Dr. Murat ATAN (Başkan)

---

Doç. Dr. Kazım Barış ATICI (Danışman)

---

Prof. Dr. Aydın ULUCAN

---

Prof. Dr. Yetkin ÇINAR

---

Dr. Öğretim Üyesi Mustafa ÇİMEN

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylım.

Prof.Dr. Uğur ÖMÜRGÖNÜLŞEN

Enstitü Müdürü

## YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinleri yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan **“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”** kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H.Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir. <sup>(1)</sup>
- Enstitü / Fakülte yönetim kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ..... ay ertelenmiştir. <sup>(2)</sup>
- Tezimle ilgili gizlilik kararı verilmiştir. <sup>(3)</sup>

29/12/2022

**Irmak UZUN BAYAR**

<sup>1</sup>“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”

- (1) Madde 6. 1. Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.
- (2) Madde 6. 2. Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulunun** gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.
- (3) Madde 7. 1. Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, **tezin yapıldığı kurum** tarafından verilir \*. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, **ilgili kurum ve kuruluşun önerisi** ile **enstitü** veya **fakültenin** uygun görüşü üzerine **üniversite yönetim kurulu** tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir. Madde 7.2. Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.

\* Tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** tarafından karar verilir.

## ETİK BEYAN

Bu çalışmadaki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi, görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, yararlandığım kaynaklara bilimsel normlara uygun olarak atıfta bulunduğumu, tezimin kaynak gösterilen durumlar dışında özgün olduğunu, **Doç. Dr. Kazım Barış ATICI** danışmanlığında tarafımdan üretildiğini ve Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü Tez Yazım Yönergesine göre yazıldığını beyan ederim.

**Irmak UZUN BAYAR**

*Biricik Eşim Mustafa Mehmet BAYAR'a*

*ve*

*Değerli Kızım Tomris BAYAR'a...*

## TEŞEKKÜR

Akademik yolculuğum boyunca desteğini her zaman hissettiren, tez çalışmamın her aşamasında bilgi ve düşüncelerinden yararlandığım, öneri ve eleştirileriyle bana yol gösteren, çalışmalarına değer katan, ilham aldığım ve birlikte çalışmaktan gurur duyduğum; akademik nosyonumu inşa eden kıymetli tez danışmanım Sayın Doç. Dr. Kazım Barış ATICI Hocam;

Yüksek lisans öğrenimimde danışmanlığımı yürüten, doktora sürecinde de yetişmemde büyük emeği olan ve akademik serüvenimde hep örnek aldığım, gerçek potansiyelime ufuk kabul ettiğim tüm sınırları aşmamı sağlayan ve sınırsızlığı prensip edindiren değerli hocam ve Sayın Prof. Dr. Aydın ULUCAN;

Tez izleme komitemde ve tez savunma jürimde yer alarak birbirinden değerli fikirleriyle ve tecrübeleriyle çalışmama katkıda bulunan sayın hocalarım Doç. Dr. Kazım Barış ATICI, Prof. Dr. Aydın ULUCAN, Prof. Dr. Yetkin ÇINAR, Prof. Dr. Murat ATAN ve Dr. Öğretim Üyesi Mustafa ÇİMEN;

Tez savunmama hazırlanırken destek ve yardımlarını esirgemeyen, bu süreç boyunca her zaman yanımda yer alarak motivasyon veren kıymetli arkadaşlarım Doç. Dr. Anıl BOZ SEMERCİ, Dr. Öğretim Üyesi Handan AKKAŞ, Dr. Öğretim Üyesi Özge DİNÇ CAVLAK ve Dr. Öğretim Üyesi Sıtkıcan SARAÇOĞLU;

Bu tez çalışması süresince üzerimde büyük emeği olan, kıymetli varlıklarıyla bana pozitif bir atmosfer sunan, ihtiyaç duyduğum enerjiyi ve motivasyonu veren ve sundukları sonsuz destekle her zaman yanımda olan sevgili kayınvalidem Banu BAYAR ve sevgili kayınpederim İlhan BAYAR;

Hayatımın her anında desteklerini hissettiğim, her koşulda yanımda olan, benim başarılı bir birey olmam için sonsuz katkı ve emek sunan, bu çalışmanın tamamlanabilmesinde büyük emekleri olan ve bana sağladıkları sonsuz yardım, fedakarlık ve motivasyon için kıymetli ebeveynlerim sevgili annem Mevhibe UZUN ve sevgili babam Enver UZUN;

Hayatımın her aşamasında yanımda olan varlığıyla bana güç veren, bana inanan, tez çalışmamın her aşamasında paha biçilmez emeği olan, çok değerli bilgi birikimiyle büyük katkılar sunan, sağladığı moral ve motivasyonla her derdimde yanımda olan, ilham kaynağım çok değerli hocam, sevgili eşim ve biricik hayat arkadaşım Dr. Mustafa Mehmet BAYAR, bu çalışmada varlığıyla bana sonsuz motivasyonu sağlayan, yüzümden gülümsemeyi eksik ettirmeyen hayat ışığım çok değerli kızım Tomris BAYAR ve son olarak tez sürecimi stressiz geçirmemi sağlayan çok tatlı kedim Safir;

Hepinize en içten saygılarımı ve sonsuz teşekkürlerimi sunarım!



## ÖZET

UZUN BAYAR, Irmak. *Yapay Sinir Ağları Destekli Etkinlik Ölçümü: Veri Zarflama Analizi Üzerine Uygulamalar*, Doktora Tezi, Ankara, 2023.

Bu tez çalışmasında; performans analizi literatüründe son yıllarda ilgi odağı haline gelen Yapay Sinir Ağları (YSA) ve Veri Zarflama Analizinin (VZA) birlikte kullanıldığı mevcut yöntemler değerlendirilerek YSA-VZA literatüründe değinilmemiş ve VZA'nın araştırmalarda sıklıkla odaklanılan olası bir zayıf yönü olan ağırlık belirleme serbestisi ve ayrıştırma gücü sorunsalına YSA ve VZA'nın yeni ve özgün bir kullanımı geliştirilerek yeni bir katkı önerilmiştir.

Bu tezde, VZA'da ayrıştırma gücü sorunsalına yönelik popüler bir yöntem olan ağırlık kısıtlı VZA için yeni bir nesnel bilgi kaynağı önerilmiştir. VZA'nın temel varsayımlarını dayanak alan bir genel üretim fonksiyonunun derin öğrenme ile modellendiği ve model tahminlerini açıklama güçleri bakımından farklı girdilerin görelî etkisini makine öğrenmesi yorumlama algoritmalarıyla ölçerek ordinal bilginin türetildiği bu araştırma, YSA-VZA literatürüne VZA kriterleri önem bilgisinde farklı perspektiflere yönelik iki ayrı yöntemin kullanımını sunmaktadır: Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması (PÖS) ve Shapley Değerleri Algoritması (SDA). Ve bu araştırmanın amacı; ayrıştırma gücü sorunsalına mutlak ve etkili bir veri temelli (*data-driven*) çözüm geliştirmektir. Ayrıca kullanımı önerilen girdi pertürbasyonu ile öznitelik sıralama algoritmasının geliştirilen yeni ve optimizasyon temelli bir versiyonu ile algoritma değişkenliği ortadan kaldırılmış ve algoritma *robust* hale getirilmiştir.

Bu araştırmada model tahminlerini açıklama güçleri bakımından farklı girdilerin görelî etkisini ölçen makine öğrenmesi yorumlama algoritmalarının kullanımı öncelikle bir keşif deneyi ile incelenmiş ve ardından 1000 deney içeren bir simülasyon analizi ile genellenebilirlik testine tabi tutulmuştur. Yapılan uygulamada keşif ve genellenebilirlik testi fazları sonunda VZA'nın ayrıştırma gücünü iyileştirmede PÖS'ün ve SDA'nın kararlı ve neredeyse denk iyileştirmeler sağladığı saptanmıştır. Önerilen yöntemler, VZA'da ayrıştırma gücü sorunsalına yönelik araştırmalara nesnel, erişilebilir bir bilgi üretebilmekte ve bu bilgi üzerinden formüle edilen ağırlık kısıtlı-VZA modelleri üzerinden tam bir çözüm sunmaktadır.

### Anahtar Sözcükler

Yapay Sinir Ağları, Derin Öğrenme, Veri Zarflama Analizi, Ayrıştırma Gücü, Yorumlanabilir Makine Öğrenmesi, Girdi Pertürbasyonu ile Öznitelik Sıralama, Shapley Değerleri

## ABSTRACT

UZUN BAYAR, Irmak. *Artificial Neural Network Aided Efficiency Measurement: Applications on Data Envelopment Analysis*, Doctoral Dissertation, Ankara, 2023.

This study reviews the existing methods in the literature of using Artificial Neural Networks (ANN) with Data Envelopment Analysis (DEA), a recent focus of attention. It proposes a new and novel contribution to improving one of the most frequently highlighted vulnerabilities of DEA in the literature: the discriminatory power of DEA.

This study aims to explore an absolute and data-driven recipe for the discrimination power issues in DEA. Towards this purpose, a new and objective source of information is introduced to the well-established weight-restricted DEA methods. First, founded on the major axioms of DEA, a general production function is modeled via deep learning. Then, inferences on the relative impacts of the inputs on the model predictions are derived-and-translated into ordinal rankings by employing machine learning (ML) interpretation algorithms. The two ML interpretation algorithms with different scopes employed in the research are the Input Perturbation Feature Ranking (PFR) and the Shapley Values (SV) algorithms. Moreover, an improvement to the PFR algorithm in removing the inferential variance and adding robustness via substituting a new optimized input re-arrangement with the conventional random shuffling approach.

In this research, the use of interpretable ML algorithms in deriving relative importance information of the DEA criteria is experimented on a single setting and then tested for generalizability via a simulation analysis involving 1000 experiments for each of the applications that employ the PFR or the SV. The experiments concluded that PFR-aided DEA and SV-aided DEA raise matching discriminatory power over the standard DEA models and produce accessible and objective data-driven ordinal rankings of the DEA-input criteria, which computes a complete set of efficiency scores when translated into weight restrictions.

### Keywords

Artificial Neural Networks, Deep Learning, Data Envelopment Analysis, Discrimination Power, Interpretable Machine Learning, Input Perturbation Feature Ranking, Shapley Values

## İÇİNDEKİLER

<b>KABUL VE ONAY</b> .....	i
<b>YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI</b> .....	ii
<b>ETİK BEYAN</b> .....	iii
<b>TEŞEKKÜR</b> .....	v
<b>ÖZET</b> .....	vi
<b>ABSTRACT</b> .....	vii
<b>İÇİNDEKİLER</b> .....	viii
<b>TABLolar DİZİNİ</b> .....	xii
<b>ŞEKİLLER DİZİNİ</b> .....	xiii
<b>GİRİŞ</b> .....	1
<b>1. BÖLÜM: VERİ ZARFLAMA ANALİZİ</b> .....	6
<b>1.1. ETKİNLİK TÜRLERİ</b> .....	6
<b>1.2. İLK VERİ ZARFLAMA ANALİZİ ÇALIŞMASI ve ÖNERİLEN MODELLER</b> .....	7
<b>1.3. VERİ ZARFLAMA ANALİZİNDE AYRIŞTIRMA GÜCÜ SORUNU ve</b> <b>AĞIRLIK KISITLARI</b> .....	10
1.3.1. Ayrıştırma Gücünü Artırmaya Yönelik Yaklaşımlar.....	11
1.3.2. Ağırlık Kısıtlama Yaklaşımlarına Genel Bir Bakış.....	13
1.3.3. Ağırlık Kısıtlama Yöntemleri .....	15
1.3.3.1. Ağırlıkları Doğrudan Sınırlandırma Yaklaşımları .....	16
1.3.3.2. Girdi-Çıktı Düzeylerini Değer Yargılarına Göre Uyarlama Yaklaşımları .....	17

1.3.3.3. Ağırlık Belirleme Serbestisini Ağırlıklandırılmış Girdilerle Veya Çıktılarla Sınırlandırma Yaklaşımları .....	19
<b>2. BÖLÜM: YAPAY SİNİR AĞLARI .....</b>	<b>21</b>
<b>2.1. MAKİNE ÖĞRENMESİNİN TEMELLERİ .....</b>	<b>22</b>
<b>2.2. İLERİ BESLEMELİ DERİN YAPAY SİNİR AĞLARI .....</b>	<b>23</b>
<b>2.3. DERİN YAPAY SİNİR AĞLARI İÇİN OPTİMİZASYON ALGORİTMALARI .....</b>	<b>26</b>
2.3.1. Türev Temelli Öğrenme .....	26
2.3.1.1. Geri Yayılım Algoritması.....	27
2.3.1.2. Kaybolan Eğim Sorunsalı .....	29
2.3.1.3. Gradyan İniş ve Stokastik Gradyan İniş Algoritması.....	39
2.3.1.4. Momentum ve Nesterov Momentumu .....	39
2.3.1.5. Öğrenme Hızını Uyarlama Yaklaşımları .....	40
<b>3. BÖLÜM: LİTERATÜRDE VERİ ZARFLAMA ANALİZİ-YAPAY SİNİR AĞLARI ÇALIŞMALARI .....</b>	<b>43</b>
<b>4. BÖLÜM: DERİN ÖĞRENME DESTEKLİ VERİ ZARFLAMA ANALİZİNDE AYRIŞTIRMA GÜCÜ İYİLEŞTİRMESİ .....</b>	<b>51</b>
.....	51
<b>4.1. UYGULAMADA KULLANILAN MODELLER ve YÖNTEMLER .....</b>	<b>53</b>
4.1.1. Ağırlık Kısıtlı Veri Zarflama Analizi .....	54
4.1.2. Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması .....	56
4.1.3. Shapley Değerleri ile Öznitelik Sıralama .....	57
<b>4.2. ÖZNİTELİK ÖNEM BİLGİSİ ile AĞIRLIK KISITLI VERİ ZARFLAMA ANALİZİ ÜZERİNE BİR DENEY .....</b>	<b>58</b>
4.2.1. Araştırma Tasarımı.....	61
4.2.2. Veri Kümesi .....	62

4.2.3. Derin Öğrenme ile Genel Üretim Fonksiyonun Modellenmesi .....	65
4.2.4. Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması Kullanılarak VZA Girdi Kriterleri Arasındaki Önem Bilgisinin Edinilmesi.....	68
4.2.5. Shapley Değerleri Algoritması Kullanılarak VZA Girdi Kriterleri Arasındaki Önem Bilgisinin Edinilmesi .....	72
4.2.6. Öznitelik Önem Sıralaması ile Ağırlık Kısıtlı Veri Zarflama Analizi	78
<b>4.3. ÖZİNİTELİK ÖNEM BİLGİSİ ile AĞIRLIK KISITLI VERİ ZARFLAMA ANALİZİ ÜZERİNE 1000 DENEY İÇEREN SİMÜLASYON ANALİZİ .....</b>	<b>82</b>
4.3.1. Simülasyon Analizinde Araştırma Tasarımı .....	83
4.3.1.1. Simülasyon Analizinde Veri Kümeleri.....	83
4.3.1.2. Simülasyon Analizinde Derin Öğrenme ile Genel Üretim Fonksiyonlarının Modellenmesi.....	83
4.3.1.3. Simülasyon Analizinde Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması Kullanılarak VZA Girdi Kriterleri Arasındaki Önem Bilgilerinin Edinilmesi.....	84
4.3.1.4. Simülasyon Analizinde Shapley Değerleri Algoritması ile Öznitelik Önem Sıralaması Kullanılarak VZA Girdi Kriterleri Arasındaki Önem Bilgilerinin Edinilmesi.....	89
4.3.2. Simülasyon Bulguları.....	92
<b>4.4. DERİN ÖĞRENME DESTEKLİ VERİ ZARFLAMA ANALİZİNDE AYRIŞTIRMA GÜCÜ İYİLEŞTİRME ARAŞTIRMASININ SONUÇLARI .....</b>	<b>96</b>
4.4.1. Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması ve Shapley Değerleri Algoritmasının Karşılaştırması .....	97
4.4.2. Veri Zarflama Analizinde Ayırt Etme Gücünün Artırılması Bakımından PÖS Destekli Ağırlık Kısıtlı VZA ve SDA Destekli Ağırlık Kısıtlı VZA .....	100
4.4.3. Tartışma ve Öneriler .....	101
<b>SONUÇ .....</b>	<b>103</b>
<b>KAYNAKÇA .....</b>	<b>110</b>

<b>EK 1. ORİJİNALLİK RAPORU .....</b>	<b>129</b>
<b>EK 2. ETİK KURUL / KOMİSYON İZİNİ YA DA MUAFİYET FORMU.....</b>	<b>131</b>

## TABLOLAR DİZİNİ

<b>Tablo 1:</b> YSA-VZA Çalışmaları .....	47
<b>Tablo 2:</b> Veri Kümesine Ait CD Üretim Fonksiyonu için Girdi Üs Değerleri Verisi .....	62
<b>Tablo 3:</b> VZA Kriterleri ve Etkinlik Skorları .....	64
<b>Tablo 4:</b> Çıktı ve Tahminlenen Çıktı Değerleri Karşılaştırması .....	66
<b>Tablo 5:</b> Model Başarım Performansı Metrikleri .....	67
<b>Tablo 6:</b> Pertürbe Edilmiş Öznitelik (VZA Girdi Kriteri) Verisi .....	69
<b>Tablo 7:</b> Pertürbe Veri Kümeleri için Model Performans Metrikleri .....	71
<b>Tablo 8:</b> Özniteliklere Ait Shapley Değerleri .....	76
<b>Tablo 9:</b> Global Shapley Değerleri .....	77
<b>Tablo 10:</b> Deney Bulguları .....	80
<b>Tablo 11:</b> 1000 Veri Kümesi için Model Başarım Performansı Metrikleri .....	84
<b>Tablo 12:</b> İlk 10 Veri Kümesi için PÖS Bulguları ve Öznitelik Sıralaması .....	86
<b>Tablo 13:</b> PÖS Destekli VZA'da Sıralama Frekans Bilgileri .....	89
<b>Tablo 14:</b> İlk 10 Veri Kümesi için SDA Bulguları .....	90
<b>Tablo 15:</b> SDA Destekli VZA'da Sıralama Frekans Bilgileri .....	91
<b>Tablo 16:</b> İlk 10 Veri Kümesi için Analiz Bulguları .....	92
<b>Tablo 17:</b> 1000 Veri Kümesi için Analiz Bulguları .....	96

## ŞEKİLLER DİZİNİ

<b>Şekil 1:</b> Rosenblatt'ın (1958) Perseptronu.....	24
<b>Şekil 2:</b> Derin Yapay Sinir Ağı .....	25
<b>Şekil 3:</b> Bir Zincirleme Bileşke Fonksiyon Olarak YSA .....	28
<b>Şekil 4:</b> Eşik Değer Aktivasyon Fonksiyonu (Step Function).....	32
<b>Şekil 5:</b> Sigmoid Fonksiyonu .....	32
<b>Şekil 6:</b> Tanh Ve Sigmoid Fonksiyonları.....	34
<b>Şekil 7:</b> Katı-Hiperbolik Tanjant ve Hiperbolik Tanjant Fonksiyonları .....	35
<b>Şekil 8:</b> Katı Sigmoid ve Sigmoid Fonksiyonu .....	37
<b>Şekil 9:</b> ReLU Aktivasyon Fonksiyonu ve Sigmoid Fonksiyonu .....	38
<b>Şekil 10:</b> Derin Öğrenme Destekli Ağırlık Kısıtlı VZA Yöntemi için Görsel Özet .....	53
<b>Şekil 11:</b> Tek Veri Kümesi ile Deney Görsel Özeti .....	60
<b>Şekil 12:</b> Pertürbe Veri İle Orijinal Veri İçin Korelasyon Grafiği .....	71
<b>Şekil 13:</b> SDA Özet Grafiği.....	77
<b>Şekil 14:</b> Ağırlık Kısıtlı VZA için PÖS ve SDA Bulguları .....	81
<b>Şekil 15:</b> Simülasyon Analizi Görsel Özeti .....	82
<b>Şekil 16:</b> PÖS Destekli VZA'da Önem Sırasına Göre Öznitelik Dağılımları .....	88
<b>Şekil 17:</b> SDA Destekli VZA'da Önem Sırasına Göre Öznitelik Dağılımları.....	91
<b>Şekil 18:</b> 1000 Veri Kümesi için Etkinlik Skorları Ortalamaları .....	93
<b>Şekil 19:</b> 1000 Veri Kümesi için Etkin KVB Sayıları.....	95



## GİRİŞ

Dünyada bilgisayarlar için işlemci üreten, bilinirliği en yüksek işletmenin kurucularından Gordon Moore, 1965 yılında yaptığı çalışmada her 18 ayda tümleşik devrelere yerleştirilebilecek bileşen sayısının ikiye katlanacağını savunmuştur. 21. yüzyılın başlarına kadar geçerli olan bu eğilimle gelişen işlem yeteneği bulut bilişimle birleşerek veri depolama ve veri işleme olanaklarını daha önceden hayal edilemeyen noktalara taşımıştır. Basitçe çok sayıda işlem birimi üzerinde görev paylaşımını olarak tanımlanabilecek paralelizasyon teknolojisi, özellikle de Yapay Sinir Ağları (YSA) gibi karmaşık yapay zeka teknolojilerinin yaygınlaşmasını ve demokratikleşmesini sağlamıştır.

Analistler YSA ve benzeri makine öğrenmesi tekniklerini temel olarak iki amaca yönelik kullanırlar. Bunlardan ilki bu teknikler aracılığıyla yüksek maliyetle erişilebilen ya da erişimi mümkün olmayan verinin kestirimiyeen ikincisi de kurulan ve istatistik bilimini temel alan modellerin değerli çıkarımların türetiminde değerlendirilmesidir. Ancak; 21. yüzyılın ilk çeyreğine dek YSA gibi yüksek esnekliğe sahip makine öğrenmesi yöntemleri çıkarım elde edilemeyecek kadar karmaşık (*black box*) kabul edilmişlerdir. Veri temelli karar vermenin (*data-driven decision-making*), ana arterlerinden olan model çıkarımlarını makine öğrenmesi tekniklerinde elde etmeye yönelik yorumlanabilir makine öğrenmesi (*interpretable machine learning*) algoritmalarının gelişmesiyle makine öğrenmesi tekniklerinin kara kutusu deşifre edilebilmiştir.

Bu tez çalışması performans ölçümü araştırmalarında en çok kabul gören ve en yaygın bir yöntem olan güncel literatürde de örneklerine rastlanılan “Veri Zarflama Analizi ile Yapay Sinir Ağlarının beraber kullanımı” üzerinedir. Veri Zarflama Analizi (VZA) 20. yüzyılın son çeyreğinde ortaya çıkan, gözlemlenen birimlerin görelî performanslarını hesaplamakta yaygın kullanılan ve son

derecede yalın bir matematiksel modelden türetilmiş bir yöntemler ailesi olarak tanımlanabilir. Ancak; performans ölçümünde etkinsizliği saptamaya odaklı bu yöntem durumsal bir yaklaşımdır ve değerlendirmelerini vakaya özel olarak kurgulamaktadır. Bu nedenlerle yüksek performansın derecelendirilmesinde geliştirilmeye açık olan VZA'da performans kriterlerinin veri temelli görelî etkileri bilgisine erişim son derece zordur. Veri temelli tam bilgiye erişim için yorumlanabilir makine öğrenmesi algoritmalarından yararlanılan bu tez çalışması kapsamında gerçekleştirilen deneylerin temel motivasyonu, VZA'nın;

- Analiz tekniğinin karakteristik yapısı nedeniyle özellikle yüksek performanslı (etkin) olarak saptanan gözlem birimleri ve diğer tüm gözlem birimleri için etkinlik skorları üzerinden ayrıştırma gücünün düşük olması,
- VZA'nın ayrıştırma gücünü iyileştirmeye yönelik yaklaşımların; tüm gözlem birimleri için nesnel bilgi temelinde çözümlenememesi,
- Ayrıştırma gücünü iyileştirmeye yönelik öznel bilgi kaynaklarının sınırlı ve erişilebilirliğinin düşük olması,
- Yine, VZA'da ayrıştırma gücüne yönelik öznel bilgi kaynaklarının sorgulanabilir olması ve bu yargılardaki değişkenliğin analiz sonucunu dramatik biçimde etkileyebilmesi,

gibi olguları oluşturmaktadır. Yapılan araştırmalar YSA'nın bu problematik olgulara çözüm sunabileceği inancıyla sürdürülmüş ve olumlu sonuçlar elde edilmiştir. VZA ile birleştirilecek bir yöntem olarak YSA'nın seçimi YSA'nın;

- Anakütle verisi öğrenme sürecine sunulduğunda indirgenebilir hata düzeyini minimize edebilmesi,
- Homojenite aksiyomundan yola çıkarak girdiler ve çıktılar arasında bir genel örüntüyü tespit edebilmesi,
- Bir makine öğrenmesi yöntemi olarak, yorumlanabilir makine öğrenmesi algoritmalarıyla birleştiğinde nesnel bilgi kaynaklarının yokluğunda nesnel bilgi üretebilme yeteneği

gibi üstünlüklere sahip olmasına dayanmaktadır. VZA-YSA üzerine mevcut çalışmalar doğrulama kümesi içermeyen VZA etkinlik skoru tahminleme arařtırmaları ve VZA'ya yardımcı YSA uygulamaları biçiminde sınıflandırılabilir. Son derece nadir rastlanabilen ve keşif çalışmalarına açık olan YSA'nın VZA'yı destekleyici arařtırmalarına bir örnek niteliğindeki bu tez çalışması “VZA'da ayrıştırma gücünü iyileştirmede YSA nesnel bir kılavuz olarak kullanılabilir mi?” sorusuna yanıt aramaktadır.

Bu tezde yapılan arařtırma iki faza bölünmüş bir uygulama içermektedir. Her iki fazda da YSA'ya ilave edilen iki ayrı makine öğrenmesi yorumlama algoritması, VZA kriterleri arasında nesnel ilişki bilgilerini üreten yöntemler olarak ele alınmıştır. İlk alt uygulamada iki ayrı yöntemle edinilen bilginin kılavuzluğunda oluşturulan ağırlık kısıtlı VZA modellerinde standart VZA'ya göre önemli düzeyde ayrıştırma gücü iyileşmesi gözlemlenmiştir. İkinci alt uygulamada da ilk bulgunun genellenebilirliği 1000 ayrı veri kümesi içeren bir simülasyon analizi ile sınanmış ve önerilen her iki yöntemin de genellenebilir olduğu sonucuna varılmıştır.

VZA'da ayrıştırma gücünün iyileştirimini ele alan arařtırma;

- VZA-YSA çalışmalarında yorumlanabilir makine öğrenmesi algoritmalarını kullanan ilk çalışmayı gerçekleştirmiştir,
- Üretim olanakları kümesinin homojenite aksiyomu gereği VZA girdi kriterleri ile VZA çıktı kriterlerinin tahminlenebileceğini varsaymıştır. Bu varsayım üzerinden parametrik olmayan VZA verisi için ilk defa bir “*genel üretim fonksiyonu*” modelini YSA ile kurmuştur ve homojen veri kümelerinde yüksek model başarımı elde etmiştir,
- Ağırlık kısıtlı VZA için VZA kriterleri arasındaki ilişkiye dair nesnel bilgi kaynağı olarak üretim fonksiyonlarından türetilen marjinal dönüşüm hızı (*marginal rate of transformation*) yerine kullanılacak bir nesnel bilgiyi üretim fonksiyonları bilinmezken üretebilmiştir. VZA arařtırmalarında ilk defa ağırlık sınırlandırırken YSA ve yorumlanabilir makine öğrenmesi algoritmaları beraber kullanılmış ve global öznitelik sıralaması, VZA girdi

kriterleri arasında görelî önem bilgisinin yalnızca eldeki veriye dayalı olarak edinilmesine olanak sunmuştur,

- Kullanılan yorumlanabilir makine öğrenmesi algoritmalarından olan girdi pertürbasyonu ile öznitelik sıralama yöntemi geliştirilmiş, düşük kardinaliteli veri kümelerinde rassallıktan kaynaklı dengesiz bozunumlar optimizasyona dayalı bozunumla denkleği garanti edilen bozunumlara dönüştürülmüştür.

Bu tez çalışması, bilime ve uygulamaya sayılan katkıları sunması nedeniyle önemlidir. Bu katkıları yeniden vurgulamak gerekir. Yapılan araştırma; VZA ilk defa açıklanabilir yapay zeka (*explainable AI*) yöntemleri ile buluşturularak 44 yıllık VZA çalışmaları birikiminde ayrıştırma gücü sorunsalına eksiksiz, veri temelli ve nesnel bir çözüm yöntemi önererek katkı sunmaktadır.

Çalışmanın ilk bölümünde, Veri Zarflama Analizi anlatılmaktadır. Bu anlatım sırasıyla etkinlik türleri; ilk Veri Zarflama Analizi çalışması ve önerilen modeller; Veri Zarflama Analizinde ayrıştırma gücü sorunu ve ağırlık kısıtları başlıkları altında organize edilmiştir.

Çalışmanın ikinci bölümünde, Yapay Sinir Ağları anlatılacaktır. Ele alınacak başlıklar arasında; makine öğrenmesinin temelleri, ileri beslemeli Yapay Sinir Ağları, derin Yapay Sinir Ağları için optimizasyon algoritmaları ile türev temelli öğrenme konularına değinilmiştir. Çalışmanın üçüncü bölümünde ise literatürde Veri Zarflama Analizi ve Yapay Sinir Ağları üzerine yapılan çalışmalara yer verilmektedir.

Çalışmanın dördüncü bölümünde derin öğrenme destekli Veri Zarflama Analizinde ayrıştırma gücü iyileştirmesi üzerine bir keşif deneyi, keşfin genellenebilirliğine dair 1000 deney içeren bir simülasyon analizi ve araştırma sonuçları sunulmuştur.

Tez çalışmasının son bölümü ise genel sonuçların ve bu sonuçlara dair tartışmaların yer aldığı, mevcut çalışmaları takip edecek gelecek araştırmalara önerileri içeren kapanış bölümüdür.

## 1. BÖLÜM

### VERİ ZARFLAMA ANALİZİ

Veri Zarflama Analizi (VZA), Charnes, Cooper ve Rhodes (1978) tarafından, Farrell'in 1957 yılında yaptığı çalışmadan esinlenilerek önerilmiş girdiler ile çıktılar arasında fonksiyonel ilişkinin aranmadığı (parametrik olmayan) bir performans ölçüm yöntemidir (Cooper vd., 2011). VZA, literatürde karar verme birimi (KVB) olarak temsil edilen veri kümesindeki girdilerin çıktılara dönüşümünden görelî etkinliğini hesaplamak üzerine geliştirilmiş bir tekniktir (Coelli vd., 2005, s.161-164) ve bu tekniğin amacı etkin sınırı belirleyerek etkin ve etkin olmayan KVB'lerin ayrıştırılmasıdır. Çalışmanın bu bölümünde etkinlik türleri, Veri Zarflama Analizi modelleri ve Veri Zarflama Analizinde ayrıştırma gücü sorunu ve ağırlık kısıtları anlatılmıştır.

#### 1.1. ETKİNLİK TÜRLERİ

Etkinlik, belirli girdi birleşimi ile en çok çıktıyı üretmek veya belirli çıktı birleşimini en az girdi ile üretmek olarak tanımlanabilir (Farrell, 1957; Lovell, 1993; Thanassoulis, 2001). Farrell'e (1957) göre etkinlik kendi içinde 3 türde incelenmektedir: teknik etkinlik, toplam etkinlik (*overall efficiency*) ve ölçek etkinliği (*price efficiency*).

Temel olarak teknik etkinlik ölçeğe göre değişken getiri varsayımı altında VZA etkinlik ölçümünü ifade ederken (bkz. Banker, 1984; Banker vd., 1984) toplam etkinlik ise ölçeğe göre sabit getiri varsayımı altında VZA etkinlik ölçümünü (Charnes vd., 1978) ifade etmektedir ve ölçek etkinliği toplam etkinliğin teknik etkinliğe oranıdır (Ulucan, 2002).

Bu tez çalışmasının uygulama bölümlerinde ölçeğe göre sabit getiri varsayımı altında VZA modelleri (CCR modeli, standart model) ve bu modellerin uzanımları kullanılmıştır. Standart modelde ölçülen etkinlik toplam etkinliktir ve etkin KVB'ler aynı zamanda teknik etkin ve aynı zamanda da ölçek etkindir.

## 1.2. İLK VERİ ZARFLAMA ANALİZİ ÇALIŞMASI ve ÖNERİLEN MODELLER

Yazında bilinen ilk VZA çalışması Charnes, Cooper ve Rhodes (1978) tarafından sunulmuştur. Bu köken çalışma, kar amacı gütmeyen organizasyonların (devlet okulları) kamu hizmetleri bakımından performanslarını karşılaştırmak amacı ile gerçekleştirilmiştir. Önerilen ilk model bir oran maksimizasyonu modelidir (Charnes vd., 1978) :

$$\text{maks} \quad \frac{\sum_{r=1}^s u_r y_{r0}}{\sum_{i=1}^m v_i x_{i0}} \quad (1.1)$$

ş. k. g.

$$\frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{i=1}^m v_i x_{ij}} \leq 1 \quad , \quad j = 1, \dots, n. \quad (1.2)$$

$$u_r \geq 0 \quad , \quad r = 1, \dots, s \quad (1.3)$$

$$v_i \geq 0 \quad , \quad i = 1, \dots, m \quad (1.4)$$

(1.1) – (1.4) önerilen oran maksimizasyon modelidir ve sırasıyla; ağırlıklı çıktıların ağırlıklı girdilerin oranını en büyükleme biçimindeki amaç fonksiyonunun, etkinliğin %100'ü aşamayacağına dair kısıtın ve karar değişkenlerinin (VZA kriter ağırlıkları) negatif olmama kısıtlarının matematiksel bir sunumudur.

KVB'lerin etkinlik skoru çıktıların ağırlıklı toplamının girdilerin ağırlıklı toplamına oranlanması ile hesaplanır. Bu oran sanal dönüşüm hızları aracılığıyla etkinlik skorunun hesaplanmasında kullanılır (Coelli ve Rao, 2005). VZA'da Sanal dönüşüm ile kastedilen ağırlıklandırılmış VZA kriterleridir (ör.  $y_{rj}$  j. KVB'ye ait r. çıktı verisini göstermek üzere  $u_r y_{rj}$ ). Her bir KVB için hesaplanabilecek en yüksek etkinlik skoru ilgili KVB'ye en uygun girdi ve çıktı ağırlık değerlerinin ( $u_r$ 'ler ve  $v_i$ 'ler) atanması ile bulunur. Bir KVB için geçerli olan ağırlıklar

kıyaslanan tüm kümeye uygulandığında etkinlik skorları (0,1] aralığında olacaktır (Golany, 1988). Çözülen modelde amaç fonksiyonun 1 değerini alabildiği KVB'ler etkin birimler iken, amaç fonksiyonun 1'den küçük değer aldığı KVB'ler etkin olmayan birimlerdir. VZA'da veri kümesindeki girdi ve çıktı değerlerine göre etkin sınır belirlenir bu etkin sınıra göre etkin olmayan birimlerin etkinsizlik durumları analiz edilir (Golany ve Roll, 1989).

Standart modelin ilk hali (1.1)'deki amaç fonksiyonu ve (1.2)'deki kısıt nedeniyle bir doğrusal olmayan programlama modelidir ve bu nedenle doğrusallaştırılmıştır. Doğrusal dönüşüm amaç fonksiyonu için payın ya da paydanın 1'e eşitlendiği bir kısıtın sisteme ilave edilmesine göre iki ayrı model üretmiştir. Bu modeller belirli bir çıktıyı üreten en az girdiyi kullanım bakımından etkinliğin ölçüldüğü girdi yönelimli model, bkz. (1.5) – (1.9), ve belirli bir girdiyi tüketerek en fazla çıktıyı üretmek bakımından etkinliğin ölçüldüğü çıktı yönelimli model olarak önerilmiştir.

- **Ölçeğe Göre Sabit Getiri Varsayımı Altında Girdi Yönelimli VZA Modeli (Charnes vd., 1978):**

$$\text{maks} \quad \sum_{r=1}^s u_r y_{ro} \quad (1.5)$$

ş. k. g.

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0 \quad , \quad j = 1, \dots, n. \quad (1.6)$$

$$\sum_{i=1}^m v_i x_{io} = 1 \quad (1.7)$$

$$u_r \geq 0 \quad , \quad r = 1, \dots, s \quad (1.8)$$

$$v_i \geq 0 \quad , \quad i = 1, \dots, m \quad (1.9)$$

Bu model, kıyaslanan benzer KVB'lerin her biri için ayrı ayrı çözülmektedir. Kıyaslanan KVB'ler n tanedir ve s çeşit çıktıyı m çeşit girdi tüketerek üretmektedir. Bu üretim, KVB'lerin her biri için kendine has ancak; benzer yöntemlere tabidir ve nedenle genel bir üretim fonksiyonu tanımlanmamakta, VZA verisi de parametrik



olmayan bir karakter kazanmaktadır. Modelde kullanılan  $y_{rj}$  j. KVB için r. çıktı verisini,  $x_{ij}$  j. KVB için i. girdi verisini temsil ederken  $u_r$ 'ler, çıktı ağırlıklarını ve  $v_i$ 'ler de girdi ağırlıklarını belirlemek üzere tanımlanan karar değişkenleridir.

- **Ölçeğe Göre Sabit Getiri Varsayımı Altında Çıktı Yönelimli VZA Modeli (Charnes vd., 1978):**

$$\min \sum_{i=1}^m v_i x_{io} \quad (1.10)$$

ş. k. g.

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0 \quad , \quad j = 1, \dots, n. \quad (1.11)$$

$$\sum_{r=1}^s u_r y_{ro} = 1 \quad (1.12)$$

$$u_r \geq 0 \quad , \quad r = 1, \dots, s \quad (1.13)$$

$$v_i \geq 0 \quad , \quad i = 1, \dots, m \quad (1.14)$$

Bu tez çalışmasında çıktı yönelimli modeller tercih edilmiştir. (1.10) – (1.14)'te sunulan çıktı yönelimli model VZA girdi kriterlerine, KVB'ye en yüksek etkinlik skorunu hesaplayacak en uygun VZA ağırlık kriterlerinin seçimine yönelik olan ve KVB'lerin etkinlik skorlarında hangi kriterlerin etkili olduğunu ve ne kadar etkili olduğunu gösteren çarpan (primal) modeldir. Örneğin bir kriter ağırlığı olarak r. çıktının çarpanı olan  $u_r$ 'nin 0 veya 0'a yaklaşık değerli olması ilgili kriterin etkinlik skoru hesaplamasında kullanılmadığını ima ederken bir diğer  $u_r$ 'nün en yüksek değerli çıktı kriter ağırlığı olması da etkinlik skoru hesaplamasında  $r'$ . çıktının en etkili unsur olduğunu ima etmektedir. Ağırlık belirlemede modelin özgür olması, bu kritik çıkarımların karar vericilerin ve uzman görüşlerine aykırı hatta bazen de somut olgularla (kriterlere ait fiyat bilgileri, marjinal ikame hızı, marjinal dönüşüm hızı, vb.) çelişki içinde olmasına zemin hazırlamaktadır.

Charnes vd., (1978) çarpan modelin dual biçimini de önermiştir:

$$\begin{array}{ll} \text{maks } \emptyset & (1.15) \\ \text{\textit{\textless k. g.}} & \end{array}$$

$$\sum_{j=1}^n \lambda_j y_{rj} \geq \emptyset \cdot y_{r0} \quad , \quad r = 1, \dots, s \quad (1.16)$$

$$\sum_{j=1}^n \lambda_j x_{ij} \leq x_{i0} \quad , \quad i = 1, \dots, m \quad (1.17)$$

$$\lambda_j \geq 0 \quad , \quad j = 1, \dots, n \quad (1.18)$$

$$\emptyset \quad \textit{serbest} \quad (1.19)$$

(1.15) – (1.19)'da sunulan model, çıktı yönelimli zarflama (dual) modelidir. Bu model, KVB'lerin etkin sınır üzerindeki projeksiyonlarını karar değişkeni ( $\lambda_j$ ) değerlerinin birer konveks kombinasyonu cinsinden adresleyerek etkin olmayan birimlere örnek alınacak referans KVB'ler önermektedir.  $\emptyset$ , KVB'nin etkinlik skoru değerini hesaplamak için kullanılan karar değişkenidir.  $\emptyset$  'nin 1 değerli olması ilgili KVB'yi etkin olarak tanımlarken 1'den düşük değerler için ilgili KVB'nin etkinsiz olduğu söylenebilir.

Bu tez çalışmasının uygulama bölümü çarpan modelde ağırlık belirleme üzerine nesnel kurallara göre sınırlandırmalar getirerek VZA'da ayırıştırma gücünü artırmaya yönelik yeni iki yöntemin önerilmesi üzerinedir. Bu nedenle uygulama bölümlerinde zarflama modelleri kullanılmamıştır ancak; zarflama modeli, etkinlik skorlarının tahminlendiği ilk uygulama bölümü ile uyumludur ve çarpan model ile denk sonuçlar ürettiği için kullanılabilir.

### 1.3. VERİ ZARFLAMA ANALİZİNDE AYRIŞTIRMA GÜCÜ SORUNU ve AĞIRLIK KISITLARI

VZA, girdilerin ve çıktıların kendi aralarında mükemmel ikameleri olduğu varsayımı altında her bir KVB için en yüksek etkinliğe yönelik bir optimizasyon modelidir. Geleneksel VZA modelleri, KVB'ler için en yüksek etkinlik değerlerini hesaplayabilmek adına kriter ağırlıklarını belirlemede temel iki kısıtlama

(ağırlıkların pozitif olması ve 1'i aşmaması) dışında sınırlandırılmamış bir özgürlük tanımaktadır.

Ağırlık belirleme özgürlüğü, pratik olarak toplam etkinliği yüksek olmayan KVB'ler için başarısız olduğu kriterler hesaba katılmaksızın değerlendirilerek performansların abartılı ölçümüne yol açabilmektedir.

Ayrıca, standart VZA modellerinde etkin olmayan birimler (0,1) aralığında etkinlik skorları alırken etkin birimlerin tümü 1 etkinlik skor almaktadır. Benzer biçimde klasik toplamsal VZA modellerinde de etkin olmayan birimler pozitif toplam pay (slack) değerleri alırken etkin birimlerin tümü 0 toplam pay değerlidir. Bu durum VZA'nın KVB'leri etkin ve etkin olmayan biçiminde ikili bir sınıflandırmayla değerlendirebilmesi ve etkin birimlerin kendi içlerinde kıyaslanmaması sonuçlarını doğurabilmektedir.

Eksik veride analiz yapıldığında etkinlik skorlarının yüksek ölçülebilmesi ve etkin birimlerin kendi içlerinde karşılaştırılmama olguları VZA'nın ayrıştırma gücünün düşük olması sorununu tanımlayan alt bileşenlerdir. Bu bileşenlere yönelik çeşitli yaklaşımlarla ayrıştırma gücünü iyileştirme araştırmaları literatürde önemli bir yere sahiptir.

### **1.3.1. Ayrıştırma Gücünü Artırmaya Yönelik Yaklaşımlar**

VZA'nın ayrıştırma gücünü artırmak adına kullanılan iki ana yaklaşım vardır. Bunlardan ilki kriter sayısını değiştirmeksizin karşılaştırılan KVB sayısının artırılması yaklaşımları iken ikincisi de değerlendirme kriterlerinin sayısını azaltma yaklaşımlarıdır (Podinovski ve Thanassoulis, 2007).

Eldeki KVB'lere ait çoklu kesit veri ya da zaman serisi verisi kullanmakta ve KVB'lere ait farklı gözlemleri yeni KVB'ler olarak analize eklemektedir. Burada temel varsayım KVB'nin farklı gözlemleri arasında teknolojik değişimin olmaması,

yavaş olması ya da analize konu olan esas KVB performanslarının altında performans üretmesidir (Charles ve diğerleri, 2019; Hughes ve Yaisawarnng, 2004; Podinovski ve Thanassoulis, 2007). Bu varsayım analiz öncesi doğrulanması gereken zayıf bir mantığa dayanmaktadır.

İkinci yaklaşım ise genel olarak kovaryans analizi üzerinden kriterlerin azaltımı (bkz. Jenkins ve Anderson, 2003) ya da temel bileşen analizini (*principal component analysis*) VZA ile birleştirme (bkz. Adler ve Golany, 2001; 2002; Adler ve Yazhensky, 2010) gibi yöntemlere dayanır. Ancak; bu yöntemler analizden çıkarılan kriterlerin bilgisinin yitirilmesi sorununu doğurmaktadır.

İkinci yaklaşımın motivasyonu “*curse of dimensionality*” sorunsalıdır. Analiz için değerlendirilen her bir kriter karar değişkeni uzayında yeni bir boyut oluşturmakta ve genel performansı düşük KVB’ler bile bu çok boyutlu uzayın bir boyutunda etkin sınırdaki konumlanabilmektedir. Bu sorunu gidermek için yine kriterler üzerinden geliştirilmiş diğer yaklaşımlar ise ağırlık kısıtlarını VZA modellerine eklemek (Allen ve diğerleri, 1997) ve tercih değiştirme yöntemleridir (Meng vd., 2008; Zhang vd., 2019). Bu yöntemler uzman görüşüne dayanmaktadır (Charles, vd., 2019; Thanassoulis, Portela ve Allen, 2004) ve uzman görüşünü edinmek sıklıkla zor ya da olanaksızdır (Doyle ve Green, 1994).

Diğer yaklaşımlar arasında Doyle ve Green’in (1994) çapraz etkinlik yöntemi, Andersen ve Petersen’in (1993) süper-etkinlik yöntemi ve etkin sınır ile beraber anti-etkin sınıra karşı konumun değerlendirilmesi yöntemi (Shen vd., 2016) bulunmaktadır.

Çapraz etkinlik yöntemi negatif etkinlik skorları üretebilmektedir (Wu, Liang ve Chen, 2009). Süper etkinlik yönteminde ise çözümsüzlük ya da sınırsız çözüm sorunları ortaya çıkabilmektedir (Seiford ve Zhu, 1999).

### 1.3.2. Ağırlık Kısıtlama Yaklaşımlarına Genel Bir Bakış

Geleneksel VZA'da ağırlık belirlenmesinde sınırlandırma konulmaması iki sav ile açıklanabilir. Birincisi, yüksek performans belirleme yönelimli bir analize rağmen etkin KVB olarak tanımlanmayan gözlemlerin performans düşüklüğünün tartışılmazlığıdır. İkincisi ise, her bir KVB'nin ayrı koşullara tabi oluşunun ancak kendilerine has bir sanal girdi ve sanal çıktı kombinasyonu ile temsil olunabileceğidir (Kabnurkar, 2001). Sanal girdi ve sanal çıktı kavramları sırasıyla ağırlıklandırılmış girdi ve çıktı anlamına gelmektedir. Ancak; bu ağırlık belirleme özgürlüğünün üç temel olumsuzluğu vardır:

- i. VZA etkinliği ideal bir etkin sınıra göre değil analize katılan diğer KVB'lere göre görece olarak hesaplamaktadır. Dolayısıyla yalnız bir kriterde üstün olan bir KVB üstün olduğu kriterde çok yüksek ağırlıklandırılarak etkin olarak tanımlanabilir. Diğer bir ifade ile etkinlik genel performansı yansıtmamaktadır. Ayrıca görece önemsiz girdilerin verimli kullanımı veya görece önemsiz çıktıların verimli üretimi üzerindeki bir olası vurgu, KVB'lerin önemli faaliyetlerdeki verimsizliklerini perdeleyebilir (Pedraja ve diğerleri, 1997).
- ii. Ağırlık belirleme özgürlüğü aynı kriterde farklı KVB'ler için çok farklı ağırlıkların belirlenmesine neden olabilir. KVB'ler arası koşulların farklılığına bağlı olarak bir kriterin görece önemi değişkenlik gösterebilir ancak; homojenite varsayımı altında KVB'lerin benzer teknolojilerle, benzer maliyetler ödeyerek aynı girdileri kullandığı ve benzer amaçlarla aynı çıktıları ürettiği bir yapıda ağırlık belirleme özgürlüğünün sınırlandırılmaması mantıklı değildir (Pedraja ve diğerleri, 1997).
- iii. Standart hali ile VZA'da analiz öncesi (*a priori*) bilgilere dayalı olarak kriterlerin önemlerinin analize aktarılması olanağı yoktur (Kabnurkar, 2001).

VZA modellerine ağırlık kısıtlarının eklenmesi, yukarıdaki olumsuzlukların giderilmesi motivasyonunun yanı sıra şu gerekçelerle de açıklanabilir:

- **Analizde tüm kriterlerin değerlendirilmesinin sağlanması:** Kriter ağırlıklarına alt ve üst sınırlar tanımlayarak tüm kriterlerin analizde değerlendirilmesi sağlanabilir.
- **Girdi fiyatlarının, çıktı değerlerinin ve a priori bilginin analize aktarımı:** Analiz öncesi bilgi, Chilingirian ve Sherman (1997) örneğindeki gibi kriter ağırlıklarının ortak koşulları yansıtan bir konikle sınırlandırılması veya Dyson ve Thanassoulis (1988) örneğindeki gibi KVB'lerin tabi olduğu bir düzenleme makamının görüşlerini yansıtmak üzere ağırlık kısıtları aracılığı ile analize aktarılabilir.
- **Girdi-çıktı etkileşiminin tanımlanması:** Thanassoulis vd. (1995) örneğinde, girdi ve çıktının göreceli önemlerini yansıtmak üzere eklenen bir ağırlık kısıtı girdinin ve çıktının ağırlıklarını birbirlerine eşitlemiştir.
- **Analiz öncesi yüksek ve düşük performanslı KVB sezgilerinin (*intuition*) analize aktarımı:** Çoğunlukla karar vericilerin analiz öncesinde iyi ve kötü performanslı KVB'lere dair bir sezgisi vardır. Charnes vd. (1990), orijinal CCR modelinin son derece zayıf performans gösteren bazı KVB'leri etkin olarak tanımladığını gözlemleyerek konik oran ağırlık kısıtlarını önermiştir. Bu yöntemde KVB'ler, önceden belirlenen ve çok iyi performansı olduğuna inanılan 3 KVB'ye göre kıyaslanarak değerlendirilmiştir. Chilingirian ve Sherman (1997) de bu yöntemi geliştirerek seçilen referans KVB'lerin koşullarını temsil eden ağırlık kısıtlı bir konik oran modeli önermiştir.
- **Teknik etkinlik yerine toplam etkinliğin ölçümü:** Farrell'e göre (1957) etkinlik teknik etkinlik ve ölçek etkinliğinden oluşmaktadır. Ölçek etkinliği, bir KVB'nin girdi kombinasyonunu toplam maliyeti en aza indirgeyecek biçimde

seçmesiyle ilgilidir. Dolayısıyla ölçek etkinliğinin ölçümü için kriterlerin fiyat bilgisine ihtiyaç vardır. Ancak; bu fiyat bilgisi her zaman tek değerli olamayacağı ve bazen bir değer aralığı biçiminde bulunacağı için Thompson vd. (1990) güven aralığı yöntemini geliştirmiştir. Bu modele göre ağırlıklar dual modelde girdi ve çıktılarının fiyatlarına denk gelmektedir ve fiyat aralıklarına dair edinilen bilgi ağırlıklara üst sınır ve alt sınır tanımlayan kısıtlar olarak analize eklenebilir. Öte yandan Zhu (1996) bu fiyat bilgisinin çoğu zaman kolayda bulunmadığını ve bu nedenle de bu bilginin ancak uzman görüşüyle edinilebileceğini savunmuştur. Zhu (1996) bu fiyat bilgisinin üretiminde analitik hiyerarşi süreci (AHP) kullanmıştır.

- **Bireysel KVB koşulları yerine genel bir koşulun dikkate alınması:** Roll vd. (1991), çoğu zaman KVB'lerin hemen hemen aynı koşullara tabi olduğunu savunarak her bir KVB için ağırlıklarda büyük farklılıklara olanak sağlayan ağırlık belirleme özgürlüğünü eleştirmiş ve tüm KVB'ler için her bir kritere özgü birer ağırlıkla değerlendirilmesini önermiştir.
- **Etkin KVB'ler arasında ayrıştırma yapılabilmesi:** Thompson vd. (1986), ilk analizinde altı KVB'yi performansları bakımından değerlendirmiş ve beşini etkin olarak saptamıştır. Etkin KVB'ler arasında ayrıştırmayı sağlamak üzere, uzman görüşüne dayalı güven aralığı ağırlık kısıtlarını analize eklemiş ve etkin KVB sayısını bire indirmiştir. Böylece modelin ayrıştırma gücünü artırmıştır.

### 1.3.3. Ağırlık Kısıtlama Yöntemleri

Burada sayılan yöntemler Allen ve diğerlerinin (1997) sınıflandırması temel alınarak sunulmuştur. Buna göre VZA'ya ağırlık kısıtı eklemek için üç ana yaklaşım vardır.

- i. Ağırlıkları doğrudan sınırlandırma yaklaşımları

- ii. Girdi-çıktı düzeylerini değer yargılarına göre uyarlama yaklaşımları
- iii. Ağırlık belirleme özgürlüğünü sanal girdi ve çıktılar üzerinden sınırlama yaklaşımı

Mutlak ağırlık kısıtlamaları, *Güven Aralığı 1* ve *Güven Aralığı 2* tipi ağırlık kısıtları ilk sınıfta yer almaktadır. Ordinal ilişkiler tanımlama ve konik oran yaklaşımları ise ikinci sınıfta yer almaktadır. Ağırlık kısıtlama yaklaşımları içinde yer alan yöntemler tanıtılacak olursa;

### 1.3.3.1. Ağırlıkları Doğrudan Sınırlandırma Yaklaşımları

#### ***Mutlak ağırlık kısıtlama yöntemi***

Bu yöntemde kriter ağırlıklarına alt ve üst sınır belirlenerek ağırlık kısıtları modele eklenir (bkz. Roll vd., 1991; Roll ve Golany, 1993). Roll ve Golany (1993) alt sınır ve üst sınır parametrelerinin belirlenmesinde üç öneride bulunmuştur:

- Ağırlık kısıtları olmaksızın çözülen VZA modelinde kriterler için ağırlık ortalamaları hesaplanır. Bu ortalama değerlerden izin verilen sapma öznel olarak belirlenir ve ilgili kısıtlar VZA modeline eklenerek bilgiye dayanmayan genel bir sınırlandırma yapılabilir,
- Analiz öncesi bilgi veya sezgiye dayanan değer yargılarını sınırlandırılmamış VZA modelinden elde edilen ağırlık ortalamaları ile karşılaştırarak sapma değerleri belirlenebilir,
- Analiz öncesi kriterlerin görelî önemine dair mutlak bilgi ağırlıkların yayılımını sınırlandırmak üzere modele yansıtılabilir.



### ***Tip 1 Güven Aralığı Yöntemi***

Bu yöntem, kriterlerin önem sıralarını modele aktarmak ya da kriter fiyatları bilgisini modelde tanımlamak için kullanılır. Tip 1 güven aralığı, kriter ağırlıklarının oranları için alt sınır ve üst sınır tanımlanmasına dayanır. Bu yöntemde yalnızca girdi ağırlıkları girdi ağırlıklarıyla ya da çıktı ağırlıkları çıktı ağırlıklarıyla karşılaştırılır. Thompson vd. (1990); (1996a); (1996b) ve Taylor vd., (1997) alt ve üst sınırları belirlerken kriterlere dair piyasa fiyatlarını kullanmışlardır. Ancak; Zhu (1996), fiyat bilgisine her zaman ulaşamayabileceğini ve bu verinin uzman görüşüyle de oluşturulabileceğini tartışmıştır.

### ***Tip 2 Güven Aralığı Yöntemi***

Bu yöntemde girdi ve çıktı ağırlıkları birbirleri ile karşılaştırılırlar ve çıktı ağırlıklarının girdi ağırlıklarına oranları için alt sınır ve üst sınırlar belirlenerek ağırlık kısıtları tanımlanır. Bu yöntemde amaç ya çıktıların girdilere görelî önemini modele aktarmak (Thanassoulis ve Allen, 1998) ya da KVB'lerin karlılığının belirlenebilmesidir (Thompson vd., 1996b). Eğer amaç KVB'lerin karlılığının belirlenmesi ise alt sınır ve üst sınırlar piyasa fiyatları temel alınarak belirlenir.

#### **1.3.3.2. Girdi-Çıktı Düzeylerini Değer Yargılarına Göre Uyarlama Yaklaşımları**

Bu sınıfa ait yöntemlerde VZA modeline ağırlık kısıtları ekleyerek ağırlık belirleme özgürlüğünün sınırlandırılması yerine kriterler verisinin bir faktörle çarpılarak değiştirilmesi ele alınmıştır.

#### ***Konik oran modeli***

Konik oran yöntemi Charnes vd. (1990) tarafından geliştirilmiştir ve uzman görüşünün VZA'ya yansıtılması için bir alternatif yaklaşımdır. Bu yöntem "negatif

olmayan ortant'tan (birinci bölge) daha küçük ve optimal ağırlıkların tümünü kapsayan bir koni oluşturarak karar vericilerin değerlendirmelerinin modele aktarılması olarak tanımlanabilir.

Bölüm 1.3.3.1.'de ele alınmış olan güven aralığı yöntemleri aslında yarı-uzayların kriter ağırlıklarını kapalı konveks konilerde sınırlandırıldığı özel durum kesişimleridir. Tip 1 güven aralığı yöntemlerinde girdilerin birbirlerine oranları ya da çıktılarının birbirlerine oranları için alt ya da üst sınırlar tanımlanır:

$$as_r \leq \frac{\mu_t}{\mu_{t'}} \leq \text{üs}_r \quad (1.20)$$

$$as_i \leq \frac{v_i}{v_{i'}} \leq \text{üs}_i \quad (1.21)$$

(1.20) ve (1.21)'de verilen sırasıyla çıktı ağırlıklarına ve girdi ağırlıklarına yönelik kısıtlar sırasıyla kesişim formunda ve matris formunda yazılacak olursa;

$$F = \begin{bmatrix} \text{üs}_r & -1 \\ -as_r & 1 \end{bmatrix}, \quad M =: \{\vec{\mu} \vee F \cdot \vec{\mu} \geq \vec{0}, \vec{\mu} \geq \vec{0}\}, \quad \vec{\mu} \in M \quad (1.22)$$

$$C = \begin{bmatrix} \text{üs}_i & -1 \\ -as_i & 1 \end{bmatrix}, \quad N =: \{\vec{v} \vee C \cdot \vec{v} \geq \vec{0}, \vec{v} \geq \vec{0}\}, \quad \vec{v} \in N \quad (1.23)$$

(1.20) ile (1.22) ve (1.21) ile de (1.23) denk ifadelerdir ve her iki yazım tarzında da sırasıyla çıktı kriteri ağırlıkları ve girdi kriteri ağırlıkları oranları için alt ve üst sınırlar aracılığıyla tanımlanan koniler içinde sınırlandırılırlar. Ancak; Charnes vd. (1990) bu gösterimlere alternatif oluşturmak üzere toplam formunu tanımlamış, çıktıları için ve girdiler için iki ayrı maske matrisini şöyle göstermiştir:

$$B^T = (F^T \cdot F)^T \cdot F, \quad A^T = (C^T \cdot C)^T \cdot C \quad (1.24)$$

Toplam formu ile elde edilen A ve B matrisleri daha sonra girdi ve çıktı verisini maskelemekte kullanılır ve maskelenmiş olan veri ( $X' = A \cdot X$ ,  $Y' = B \cdot Y$ )

standart VZA modeli ile çözüldüğünde örtük olarak konik oran kısıtları ile uzman görüşleri de veri içinde işlenmiş olur.

### ***Ordinal İlişki Yaklaşımı***

Golany'e (1988) göre VZA ağırlıkları arasında  $v_1 \geq \dots \geq v_m \geq \varepsilon$  ilişkisi için veride  $\vec{x}_1$ 'i koruyup,  $\vec{x}_2$  yerine  $\vec{x}_1 + \vec{x}_2$ ,  $\vec{x}_m$  yerine de  $\sum_{i=1}^m \vec{x}_i$  dönüşümü yapıldığında VZA'da modele ilave kısıt eklenmeden VZA kriterleri için değerlendirilen ordinal önem ilişkisi modele taşınmış olacaktır.

Golany'e (1988) göre veri dönüşümü ordinal ilişki kısıtları ile denktir. Ancak; ordinal ilişki kısıtları ile elde edilecek optimal ağırlık vektörü tek değerli olmak durumunda değildir (çoklu optimal çözüm mümkün olabilir). Bu durumda verideki dönüşüm ordinal önem ilişkisini sağlayan ağırlık vektörleri kümesinin yalnızca bir elemanı ile eşleşecektir. Ayrıca bu yöntem, en önemli bir kaç kriter hariç diğer tüm kriterlerin yüksek olasılıkla standart VZA modelince değerlendirilmeye katılmaması sonucunu doğuracaktır. Diğer bir ifade ile önerilen yöntem önemsiz kriter verisinin analizden atılması ile denktir oysa ki tanımlı ordinal önem ilişkisi en önemsiz kriterin en çok en önemli kriter kadar önemli olabileceği anlamına da gelmektedir ve bu koşul sağlandığında önerilen yöntem eşit önemdeki kriterlerin son sıralarda anılanlarını analiz dışı bırakabilecektir.

### **1.3.3.3. Ağırlık Belirleme Serbestisini Ağırlıklandırılmış Girdilerle Veya Çıktılarla Sınırlandırma Yaklaşımları**

Son ağırlık kısıtı tanımlama yöntemleri ailesi de kriter ağırlıklarını doğrudan kullanmak ya da kriter ağırlıklarını sınırlandırmaya denk gelen veri dönüşümlerini uygulamak yerine kriter verisini ağırlıklandırılmış biçimde sınırlandırma yaklaşımlarıdır. Bu alt başlık içinde Pedraja ve diğerleri'nin (1997) durumsal ağırlık kısıtlama yaklaşımı ile Wong ve Beasley'in (1990) ağırlıklı terimin göreceli önemi yaklaşımına değinilmiştir.

### ***Durumsal Ağırlık Kısıtlama Yaklaşımı***

Pedraja ve diğerleri (1997), her bir KVB için girdi ve çıktı düzeylerini hesaba katarak VZA'nın öneme göre girdi ve çıktıları analizde değerlendirmesini sağlayabileceklerini tartışmıştır. Diğer bir ifadeyle önerilen yöntemde düşük değerli girdiler, verimli tüketildikleri kabulüyle, yüksek ağırlıklandırılırken yüksek değerli girdiler, etkinlik skorunu düşürecekleri değerlendirilerek, düşük ağırlıklandırılırlar.

Pedraja ve diğerleri (1997) modellerinin girdi ve çıktı fiyatlarına göre ağırlık kısıtı tanımlanmasına göre daha yüksek etkinlik skoru ürettiğini savunmuşlardır. Önerilen modele ait kısıtlar için bir örnek formüle edilecek olursa;

$$c_i V_1 X_{1j} \leq V_i X_{ij} \leq d_i V_1 X_{1j} \quad (1.25)$$

Burada  $c_i$  ve  $d_i$  karar verici tarafından belirlenen değerlerdir. Bu kısıt; ilgili girdi kriterinden üretilen faydanın birinci girdiden üretilen faydanın  $c_i$  katından az veya  $d_i$  katından fazla olmayacağını ifade etmektedir.

### ***Ağırlıklı Terimin Görelî Önemi Yaklaşımı***

Wong ve Beasley (1990), bir KVB'ye göre belirli bir çıktının öneminin o çıktı için toplam çıktı miktarından ayrılan oran olduğunu savunmuştur.

$$as_r \leq \frac{u_r y_{rj}}{\sum u_r y_{rj}} \leq \bar{u}_s \quad (1.26)$$

(1.26)'da  $as_r$  ve  $\bar{u}_s$  karar vericilerin benzer durumların modelleri inceleyerek uzlaştığı değerlerdir.

## 2. BÖLÜM

### YAPAY SİNİR AĞLARI

Geleneksel bilgisayar programlama, tasarımcının belirlediği bir algoritmayı hesaplama gücünden yararlanmak üzere makine kodları aracılığıyla işlemciye aktarılması iken, yapay zeka en basit tanımıyla bilgisayarların işler için gerekli algoritmayı kendi başına tasarlayabilmesidir. Bu yetenek yapay zeka ve alt disiplinleri için öğrenme kavramı ile eşleştirilmiştir. Öğrenen bir sistem değişen koşullarda dışarıdan bir tasarımcının müdahalesi gerekmeksizin uyum sağlayabilmektedir.

Bu tez çalışmasının tüm uygulama süreçlerinde bir makine öğrenmesi yöntemi olan Yapay Sinir Ağları kullanılmıştır. Yapay Sinir Ağları (YSA) ise 1980'de paralel hesaplama teknolojisine olanak sağlayacak donanım tasarımlarının geliştirilmesiyle gerekli hesaplamaların çok sayıdaki işlem parçacığına dağıtılabilmesi ile yeniden doğmuştur (Bishop, 1995, s.116-117). YSA, örnekler üzerinden öğrenmeye dayalı bir gözetimli öğrenme yöntemidir ve bu tez çalışmasının kapsamına giren modeller, sürekli değerlerin tahminlenmesi (regresyon) için kullanılmıştır.

Yapay Sinir Ağları kendi içinde branşlaşmalara tabi olan makine öğrenme disiplini içerisinde incelenmektedir. Ve YSA, makine öğrenmesi disiplini içerisindeki bu branşlardan gözetimli öğrenme disiplini içerisindeki yöntemler ailesinin bir ferdidir. Bu nedenle YSA'nın anlatıldığı bölümde sistematik, makine öğrenmesine bir giriş niteliğindeki bilgilerin sunumu ve tez çalışması içindeki uygulamalarda kullanılan ileri beslemeli YSA teknolojisinin ayrıntılı bir anlatımı biçiminde oluşturulmuştur.

## 2.1. MAKİNE ÖĞRENMESİNİN TEMELLERİ

Yapay zekanın bir alt disiplini olan makine öğrenmesi (bkz. Russel ve Norvig, 1995), bilgisayar performansının belirli bir kriteri ve örnek veri veya geçmiş tecrübeler aracılığıyla optimizasyonudur (Alpaydın, 2004, s. 3).

Makine öğrenmesi temel olarak gözetimli öğrenme (*supervised learning*) ve gözetimsiz öğrenme (*unsupervised learning*) disiplinleri altında örgütlenmiştir. Gözetimli öğrenmede değeri, sınıfı, sırası tahminlenen gözlemler için doğru değerlerin (etiket) bilindiği ve model çıktısının etiket değerleri ile karşılaştırıldığı yaklaşımlar kullanılırken gözetimsiz öğrenmede etiket değerleri bilinmediği için temel olarak öznitelik verisinde gözlemlerin benzerlikleri ve farklılıkları üzerinden kümeleme yöntemleri kullanılmaktadır. Bu tez çalışmasında kullanılan modeller gözetimli öğrenme ailesine aittir ve bu nedenle gözetimsiz öğrenme bu tez çalışmasının kapsamı dışında tutulmuştur.

Gözetimli öğrenmede modele sunulan etiket değerleri sürekli ise modelle başarılmaya çalışılan bir regresyon görevi iken etiket değerleri kesikli değişkenler ise modelle başarılmaya çalışılan bir sınıflandırma görevidir. Bu tez çalışmasının uygulama bölümlerinde Veri Zarflama Analizi verisi kullanılmakta ve sürekli değerler tahminlenmektedir.

Temel ve basit makine öğrenmesi yaklaşımlarından (doğrusal regresyon, destek vektör makineleri, karar ağaçları, vb.) derin Yapay Sinir Ağları gibi karmaşık modeller regresyon görevlerinde kullanılabilir ancak; Occam Usturası (Hamilton, 1852) prensibine göre benzer başarımlar elde eden çok sayıda model alternatifi arasından en basit yöntem seçilmelidir. Bu yaklaşımın altında basit modellerin hesaplama maliyetinin düşük olması, eldeki veriyi açıklama başarımı zayıf değilken (yetersiz öğrenme yokken) genelleme yeteneğinin yüksek oluşu gibi nedenler yatmaktadır. Öte yandan karmaşık modeller veriye ait doğrusal olmayan örüntüler de dahil olmak üzere karmaşık ilişkileri yakalayabilmekte ve bu sayede basit modellerin yetersiz öğrenme yapabildiği hallerde yüksek model

başarımlarına ulaşabilmektedir. Eldeki veriyi yüksek başarıyla açıklayabilen karmaşık modellerde aşırı öğrenme (*overfitting*) dikkat edilmesi gereken bir sorundur. Aşırı öğrenmeyi önlemek adına modelin optimizasyon sürecine doğrudan dahil olmayan bir başka (genel) veri üzerinden performansın izlenmesi ve modelin genelleme yeteneği zayıflamaya başladığında optimizasyon sürecinin erken sonlandırılması yaygın bir yaklaşımdır.

K bölümlü çapraz doğrulama (Hastie vd., 2009); eldeki veri örnelemi, bir kısmı öğrenme kümesi dışında tutulacak biçimde feda edilemeyecek kadar küçük olduğunda modelin aşırı öğrenme örüntüsünün incelenmesi ve YSA optimizasyon süreci için bir iterasyon sayısı sınırının belirlenmesi için uygun bir yaklaşımdır.


Yetersiz öğrenme ve aşırı öğrenme arasındaki dengeyi sağlayabilecek model seçimi için genelgeçer bir kural konulamaz (bkz. no free lunch, Wolpert, 1976). Diğer bir ifadeyle her temadan veri ve verinin farklı örneklemi için bulunacak uygun model farklılaşabilecektir. Aşırı öğrenmenin önlenmesi temel olarak model başarımından (bias) ödün vererek model varyansını düşürmektir. Burada model başarımı, eldeki veri için etiket değerlerinden beklenen sapmayı ifade ederken model varyansı ise farklı veri örneklemi için modelin tahmin yeteneğindeki değişkenlik yani modelin genelleme yeteneğidir. Öğrenme süreci boyunca model başarımı artarken model varyansı ise modelin eldeki veride aşırı uzmanlaşması ile artmakta ve modelin genelleme yeteneği düşmektedir.

## 2.2. İLERİ BESLEMELİ DERİN YAPAY SİNİR AĞLARI

Derin Yapay Sinir Ağlarının anlatımından önce bu ağların temel birimi olan sinir hücrelerinin anlatılması uygun olacaktır. Rosenblatt'ın (1958), Hebbian teori (Hebb, 1949) ve McCulloch ve Pitts (1943)'in "*Threshold Logic Unit*"'inden ilham alarak geliştirdiği perseptron'u farklı özneliliklerin belirli bir gözlem için verisini temsil eden bir girdi vektörünün ağırlıklı toplamına eklenen bir sapma değerinin bir fonksiyonu biçimindedir:

$$a_l = f(\vec{w}^{lT} \cdot \vec{a}^{l-1} + b) \quad (2.1)$$

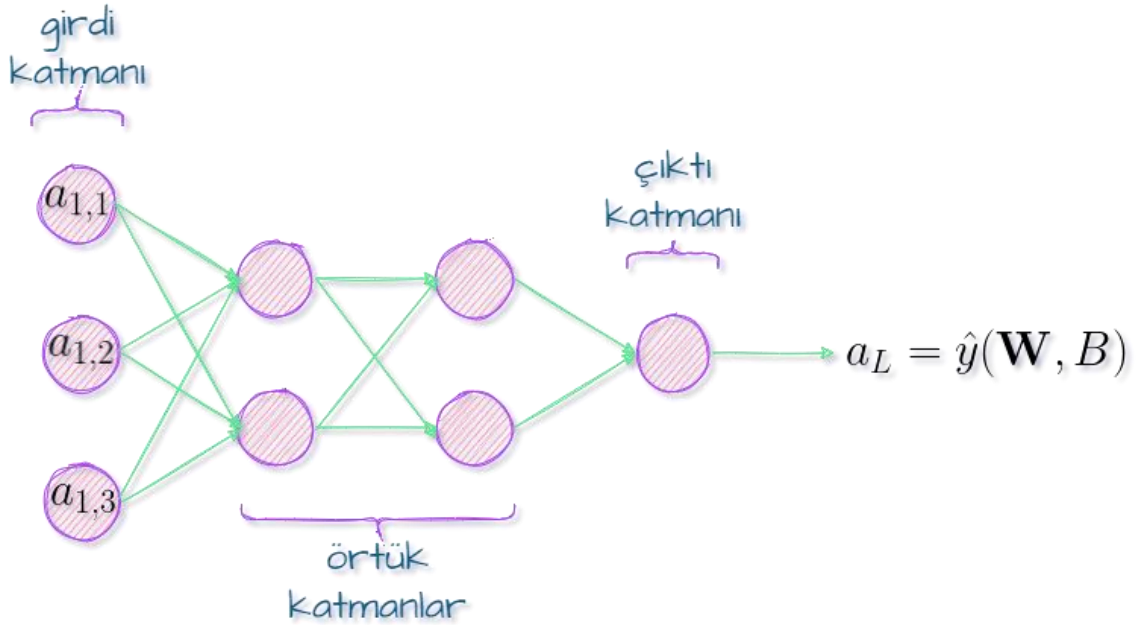
(2.1)'de  $\vec{a}^{l-1}$  modelin girdilerini,  $\vec{w}^l$  model ağırlıklarını,  $b$  modelin sapma parametresini,  $f(\vec{w}^l, b)$  aktivasyon fonksiyonunu ve  $a_l$  da modelin aktivasyon değerini (çıktısını) göstermektedir. Şekil 1 perseptron'un şematik bir gösterimidir:



**Şekil 1:** Rosenblatt'ın (1958) Perseptronu

Perseptron biyolojik bir sinyal işleme ve sinyal iletim birimi olan sinir hücrelerinden esinlenilerek geliştirilmiş basit bir modeldir. Bu sinir hücrelerinin paralel ve seri bağlanmaları ile oluşturulan kapsamlı modeller ise çok katmanlı perseptron (yapay sinir ağı, YSA) olarak anılmaktadır. Şekil 2 iki örtük katmanlı basit bir derin yapay sinir ağının şematik temsidir.





**Şekil 2:** Derin Yapay Sinir Ağı

YSA modellerinin derinliği örtük katman sayısı (sinir hücresi zincirlerinin uzunluğu) ile genişliği de örtük katmanlarda tanımlanan sinir hücresi sayısı ile ifade edilmektedir. Derin ağlarda birden çok örtük katman bulunmaktadır. Derin YSA modelleri ise ardışık katmanlardaki tüm sinir hücrelerinin birbirleri ile bağlantılı olması, model çıktılarının bir ileri bildirim sinyali ile modele yeniden girdi olarak sunulması, vb. yapısal farklılıklara göre sınıflandırılmaktadırlar.

Bu tez çalışmasında kullanılan YSA modelleri yoğun (ardışık katmanlarda tüm sinir hücrelerinin birbirleri ile bağlantılı olduğu) yapıdadır. Yoğun ağlar, özellikle çok derin ağlarda, hesaplama maliyetini artıran bir unsur olmakla birlikte modelin örüntü yakalama yeteneği için olumlu bir altyapıdır. Yoğun olmayan YSA mimarileri için evrişimli ağlar (*convolutional neural network*, bkz. Fukushima, 1988; LeCun ve diğerleri, 2015; Schmidhuber, 2015) incelenebilir.

Doğal dil işleme ya da zaman serisi analizi gibi temalara daha uygun olan özyineli sinir ağlarda (*recurrent neural network*, bkz. Jordan, 1986; Rumelhart ve diğerleri, 1985) farklı veri noktaları için model çıktıları yeni tahminlenen değerler için bir ileri bildirim sinyali ile girdi olarak kullanılmaktadır ancak; bu tez çalışması

kapsamında yalnızca bu mekanizmanın yer verilmediği ileri beslemeli YSA modelleri kullanılmıştır.

### 2.3. DERİN YAPAY SINIR AĞLARI İÇİN OPTİMİZASYON ALGORİTMALARI

Çok sayıda değişkenin olduğu yapılarda ikinci türev bilgisinin işleme maliyeti nedeniyle genel olarak YSA modellerinde yitim fonksiyonu için iyi bir yerel minimumun arandığı optimizasyon algoritmaları birinci türev bilgisine dayanmaktadır. Meta-sezgisel algoritmaların YSA optimizasyonunda kullanıldığı örneklere rastlamak da mümkündür (bkz. Carvalho vd., 2011; Göçken vd., 2016; Han vd., 2019).

#### 2.3.1. Türev Temelli Öğrenme

Arama algoritmaları mevcut değerlerin bir yön ve adım büyüklüğü aracılığıyla güncellenmesine dayanır. (2.2)'deki eşitlik bir  $\vec{w}^{t-1}$  noktasından  $\vec{w}^t$  noktasına geçişin hesaplanmasını göstermektedir.

$$\begin{bmatrix} \vec{w} \\ b \end{bmatrix}^t = \begin{bmatrix} \vec{w} \\ b \end{bmatrix}^{t-1} - \nabla_c(\vec{w}, b) \cdot \alpha \quad (2.2)$$

Burada  $\nabla_f(\vec{w}, b)$  yönü,  $\alpha$  ise öğrenme hızını (adım büyüklüğünü) göstermektedir. Algoritmanın her bir iterasyonunda karar uzayındaki bir noktadan diğerine geçiş mevcut konumdan “gradyan·alpha” kadar uzaklaşarak gerçekleşecektir. Doğru yönde ve makul öğrenme hızları seçilerek karar uzayında iyi çözümlere ulaşmak mümkündür.

Bir gözetimli öğrenme yöntemi olarak YSA modellerinin başarımı yitim fonksiyonu üzerinden izlenmektedir. Yitim fonksiyonu model tahminleri ile etiket değerleri arasındaki uzaklığın bir ölçütüdür. Konveks yapısı sayesinde sağladığı görece hesaplamaya maliyeti avantajı ve tüm hataların eşit değerlendirildiği doğrusal

uzaklığın aksine yüksek hataların doğal olarak önceliklendirilmesi nedenleriyle en yaygın kullanılan yitim fonksiyonu L2-norm temelli hata kareleri ortalamasıdır:

$$C(W, B) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2.3)$$

(2.3)'teki hata kareleri ortalamasına alternatif olarak sunulan yitim fonksiyonu yaklaşımları da vardır (bkz. ortalama mutlak hata, maksimum hata, vb.). (2.2)'de bahsi geçen arama algoritması için yön temel olarak yitim fonksiyonunun birinci türev bilgisi (gradyan vektörü) ile elde edilir. Gradyan, yitim fonksiyonu değerini fonksiyonun mevcut değeri komşuluğunda en çok artıran yöndür; negatif gradyan ise benzer mantıkla yitim fonksiyonu değerini mevcut değeri komşuluğunda en çok azaltan yöndür. Dolayısıyla negatif gradyan yönünde ve yeterince küçük öğrenme hızlarıyla yitim fonksiyonu için yerel minima değerlerini bulmak mümkündür. Ancak; arama algoritmasının durdurulma kriterlerinden biri iterasyonlar arasında yitim fonksiyonu değerinin değişmemesidir. Bu durumun en genel kaynağı ise gradyan vektörünün sıfıra yakınsamasıdır. Gradyanı sıfır yapan senaryo alternatifleri arasında fonksiyonun yerel minimasında olmak olduğu gibi bir eyer noktasında olmak ya da bir yerel maksimumda olmak da vardır. Ayrıca arama algoritması ile bir yerel minima bulunabilse bile bu noktanın bir sığ (görece yüksek değerli) bir yerel minima olmayacağını bir garantisi de yoktur.

### 2.3.1.1. Geri Yayılım Algoritması

Geri yayılım (*backpropagation*) algoritması Rumelhart ve diğerleri (1986) tarafından geliştirilmiştir. Geri yayılım algoritması, arama algoritmalarında yön için kullanılan birinci türev bilgisinde yitim fonksiyonunun yalnızca son örtük katmanda yer alan ağırlık ve sapmalara göre kısmi türevlerinin hesaplanması yerine bu katmana girdileri oluşturan aktivasyon değerlerinin de önceki katmanların ağırlık ve sapmalarının birer fonksiyonu olduğu düşüncesiyle zincir kuralı üzerinden yitim fonksiyonunun tüm katmanlardaki sinir hücrelerine ait ağırlıkları ve sapmalarına göre kısmi türevinin alınması yaklaşımıdır. Geri yayılım algoritmasının kullanımı YSA model başarımında çığır açıcı etki yaratmıştır.

Bir YSA'da verideki örüntüyü yakalayabilmek adına bazı sinir hücreleri aktifken ( $|a| \gg 0$ ) bazıları pasif ( $|a| \approx 0$ ) olacaktır. Hebb Kuramının (bkz. Hebb, 1949) Yapay Sinir Ağlarına uyarlanmış versiyonu, aktif sinir hücrelerinin birbirleri ile güçlü bağları olacağını (zincir üzerindeki ağırlıkların ve sapmaların sıfır komşuluğunda olmayacağını) ifade eder. Diğer bir ifadeyle model çıktısı ilişkili aktivasyonların yani ilişkili ağırlıkların ve sapmaların bir fonksiyonudur. Ve bu nedenle modelin verideki örüntüye uyumlandırılması (optimizasyonu), sürecinde ağda ilgili zincirler İleriye yayılarak ve bu zincirler üzerindeki ağırlıklar ve sapmalar güncellenerek yapılmaktadır.

$$\begin{array}{c}
 \vec{x}^i \\
 \downarrow \\
 \vec{a}^1 \\
 \downarrow \\
 f(W^2 \cdot \vec{a}^1 + \vec{b}^2) = \quad \vec{a}^2 \\
 \downarrow \\
 \vdots \\
 \downarrow \\
 f(W^{L-1} \cdot \vec{a}^{L-2} + \vec{b}^{L-1}) = \quad \vec{a}^{L-1} \\
 \downarrow \\
 f(W^L \cdot \vec{a}^{L-1} + \vec{b}^L) = \vec{a}^L \\
 \downarrow \\
 \vec{y}^i
 \end{array}$$

**Şekil 3:** Bir Zincirleme Bileşke Fonksiyon Olarak YSA

Şekil 3, model çıktısının bir zincir ilişkisi (bileşke fonksiyon) içinde modeldeki tüm ağırlıkların, tüm sapmaların ve model girdisinin bir fonksiyonu olduğunu ifade etmektedir. Bunun sonucu olarak geri yayılım algoritmasına göre ağırlıklar ve sapmalar iterasyonlar arasında (2.4)'te sunulan formül üzerinden güncellenmektedir.

$$\mathbf{W}^t, \mathbf{B}^t = \mathbf{W}^{t-1}, \mathbf{B}^{t-1} - \mathbf{J}_C(\mathbf{W}^{t-1}, \mathbf{B}^{t-1}) \cdot \alpha \quad (2.4)$$

(2.4)'te Jacobean Matrisi ( $J$ ), gradyan vektörü gibi çok boyutlu bir eğimler bilgisidir ancak; gradyan vektörünün aksine birinci türevler bilgisinin vektör biçiminde değil matris biçiminde yazımıdır. Burada  $W$  ve  $B$  sırasıyla ağırlıklar tensörünü ve sapmalar matrisini göstermektedir.

### 2.3.1.2. Kaybolan Eğitim Sorunsalı

Bölüm 2.3.1'de optimizasyon algoritmalarının yitim fonksiyonu değerinde belli sayıda iterasyon boyunca anlamlı değişim olmadığında durdurulduğundan bahsedilmiş ve bunun bir nedeni olarak gradyan değerinin sıfıra yakınsaması anlatılmıştır. Gradyan çok boyutlu eğitim bilgisidir; gradyanın sıfır değerli olması ise eğimin kaybolmasıdır. Eğitim kaybolduğunda ağırlık ve sapmalar güncellenemeyecek ve yitim fonksiyonunun değeri iterasyonlar arasında korunacaktır.

Bu olguya neden çok sayıda faktör sayılabilir. İlk olarak sapma kullanılmayan YSA modellerinde sinir hücrelerinde girdiler sıfır değerli ise aktivasyon fonksiyonu sıfırların ağırlıklı toplamının bir fonksiyonu olacaktır. Diğer bir ifade ile aktivasyon değeri tüm ağırlık değerleri için sabit kalacaktır (aktivasyon fonksiyonunun ağırlıklara göre kısmi türevi sıfır olacaktır). Sapma kullanımı girdiler sıfır değerli olsa bile sinir hücrelerinde aktivasyon üzerinde kontrolü sağlayabilmek içindir. Bu tez çalışmasında kullanılan modellerin verisi, VZA verisi olduğu için pozitif değerlidir ve seçilen model mimarilerinde girdilerin sıfır değerli olma olasılığı yoktur; hesaplama maliyetini artırmamak adına modellerde sapma kullanılmamıştır. İkinci bir neden ise normalize edilmemiş veri kullanıldığında veride büyük değer farklarının yitim fonksiyonunun mevcut değeri için birinci türev bilgisi değerlendirilirken çok küçük değerlerin hesaplanmasına yol açabilmesidir. İlk olarak Hochreiter (1998) tarafından ele alınan bu sorun Ioffe ve Szegedy'nin (2015) önerdiği demet normalizasyonu ile büyük ölçüde ortadan kalkmıştır. Demetler üzerinden öğrenme aynı zamanda modelin sürekli farklı veri

örneklemi üzerinden hesaplanan yitim fonksiyonları için optimize edilmesi aracılığıyla aşırı öğrenmeyi de engelleyen bir yaklaşımdır (Wilson ve Martinez, 2003). Kaybolan eğitim sorunsalı için bir diğer neden ise modelde kullanılan aktivasyon fonksiyonlarının ağırlık ve sapmanın belli değerleri için sifıra yakınsayan eğimler içeren yapısallığı olabilmektedir. Seçilen aktivasyon fonksiyonları öğrenme hızını ciddi biçimde etkileyebilmektedir (Agarap, 2018).

### ***Bazı Aktivasyon Fonksiyonları ve Karşılaştırılmaları***

Yapay Sinir Ağlarının programlanmasında, aktivasyon veya transfer fonksiyonları, nöronların çıktısı için sınırlar oluşturur (Heaton, 2015). Sinir ağları birçok farklı aktivasyon fonksiyonunu kullanabilir. Tez çalışmasının bu alt bölümünde uygulamalarda en yaygın olarak kullanılan ve bu tez çalışması içerisindeki uygulamalara uygun olduğu değerlendirilen seçilmiş bazı aktivasyon fonksiyonları öncelikle tanıtılmıştır ve ardından da söz konusu fonksiyonlar öğrenme hızı ve kaybolan eğitim sorunsalı bakış açılarından değerlendirilmiştir.

Aktivasyon fonksiyonlarının seçimi YSA'da en önemli hiperparametredir (Heaton, 2015). Bu bakımdan YSA'nın tahminlediği değer ve YSA'nın öğrenme hızı bakımından hiperparametre optimizasyonu sürecinde veriye ve yonteme uygun aktivasyon fonksiyonlarının seçimi model başarımında önemli rol almaktadır.

Aktivasyon fonksiyonu ilgili nöronun aktivasyon değerine (çiktısına) o nöronun girdileri ve model parametrelerinin (ağırlıklar ve sapma) değerleri aracılığıyla biçim verir. Aktivasyon fonksiyonları aracılığıyla bir YSA'da katmanlar arası etkileşim kurulur ve YSA kendisini meydana getiren alt birimlerin (nöronların, aktivasyon fonksiyonlarının) dev bir bileşke fonksiyonu biçimini alır. Böylece ağ üzerindeki hangi fonksiyonların aktive edileceğine karar verilerek çıktı tahminlemede yüksek başarıma ulaşan bir model öğrenme sürecinde tasarlanabilir.

YSA'nın, doğrusal regresyon gibi basit yapılı tek bir fonksiyondan farklı olarak, alt birimleri aktivasyon fonksiyonları olan dev bir bileşke fonksiyon oluşu doğrusal olmayan ilişkilerin taklit edilebilmesine olanak sağlamaktadır. Verideki ilişkinin karmaşıklığına bağlı olarak örüntünün YSA tarafından iyi yakalanabilmesi için örtük katman sayısı artırılarak bileşke fonksiyona daha fazla alt fonksiyon sunulabilir.

Bu alt bölümde anlatılmak üzere seçilen aktivasyon fonksiyonları sırasıyla eşik değer, sigmoid, hiperbolik tanjant, katı hiperbolik tanjant, katı sigmoid ve rektifiye doğrusal birim (ReLU) fonksiyonlarıdır. Bu fonksiyonlar takip eden alt başlıklarda tanıtılmış ve modelin öğrenme hızına etkileri kaybolan eğim sorunsalı bakımından tartışılmıştır.

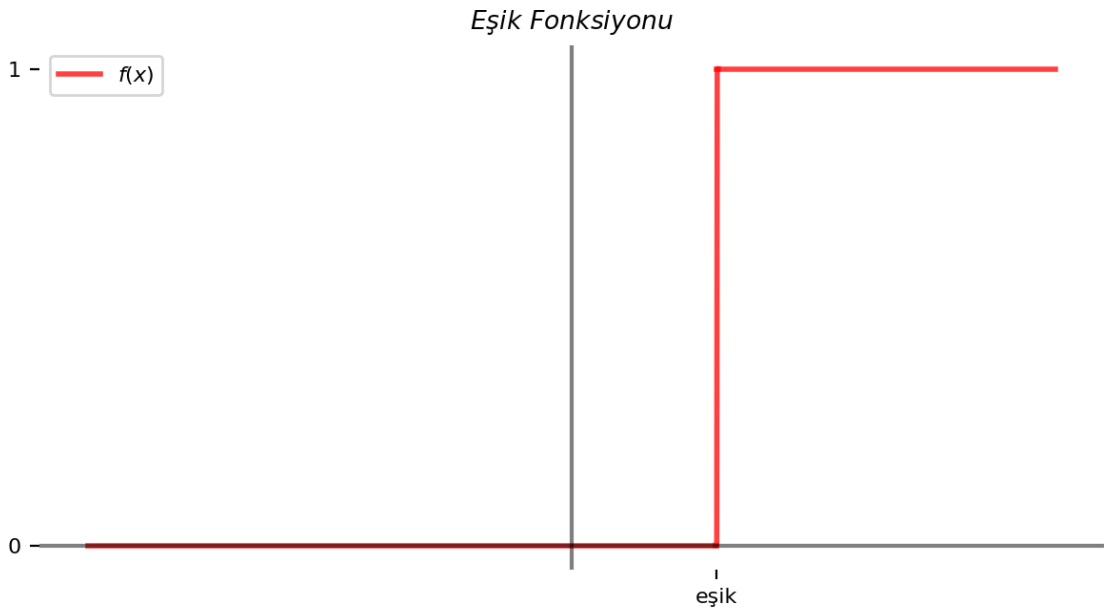
#### ***i. Step (Eşik Değer) Aktivasyon Fonksiyonu:***

Bilinen ilk matematiksel sinir hücresi olan McCulloch ve Pitts (1943) modelinde ve bu modelin geliştirilmiş versiyonu olan Rosenblatt (1958) perseptron modelinde aktivasyon fonksiyonları eşik değer fonksiyonu (step function, level function) olarak tanımlanmıştır:

$$f(z) = \begin{cases} 1 & , z \geq 0.5 \\ 0 & , \text{diğer} \end{cases} \quad (2.5)$$

$$f'(z) = 0 \quad (2.6)$$

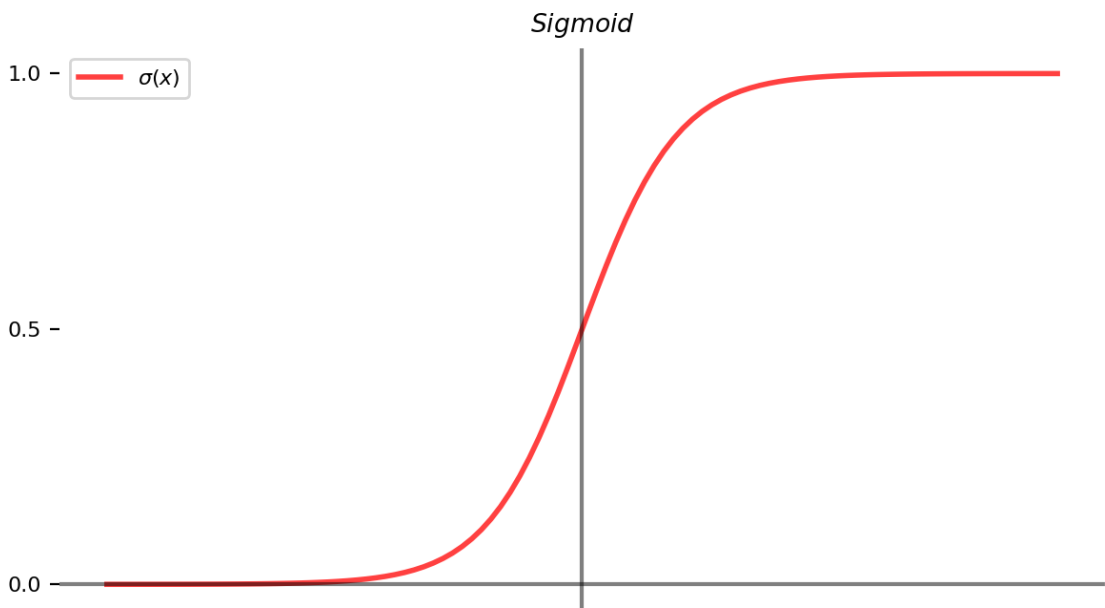
Sırasıyla (2.5) ve (2.6)'da eşik değer aktivasyon fonksiyonunun formülü ve birinci türev bilgisi sunulmuştur. Son derece basit bir parçalı doğrusal fonksiyon yapısındaki bu aktivasyon fonksiyonu erken modellerde kullanılmış olsa da türev bilgisinin 0 değerli olması nedeniyle türev temelli optimizasyon algoritmalarında öğrenmeyi engelleyebilmektedir. Ve bu nedenle sınıflandırma problemleri dahil olmak üzere günümüz uygulamalarında bu aktivasyon fonksiyonuna yer verilmemektedir. Şekil 4, eşik değer fonksiyonunun bir görselidir:



**Şekil 4:** Eşik Değer Aktivasyon Fonksiyonu (Step Function)

**ii. Sigmoid (Lojistik) Aktivasyon Fonksiyonu:**

Sigmoid fonksiyonu ya da diğer adıyla lojistik fonksiyonu,  $(0,1)$  aralığında değer alan "S" biçimli bir fonksiyondur. Şekil 5 sigmoid fonksiyonunun bir görsel sunumudur:



**Şekil 5:** Sigmoid Fonksiyonu



Sigmoid fonksiyonu geleneksel olarak YSA hiperparametre tercihinde varsayılan aktivasyon fonksiyonudur. Bunun nedeni ileri beslemeli ağlarda yalnızca pozitif çıktı değeri üretmesi ve türevlenebilir yapısıdır. Ancak; sigmoid, düşük negatif girdi değerlerinde 0'a ve yüksek pozitif girdi değerlerinde de 1'e asimptotik yakınsayan bir fonksiyondur. Dolayısıyla bu bölgelerde eğimi 0'a yakınsayan bu fonksiyon için de kaybolan eğim sorunsalı devam etmektedir:

$$\sigma(z) = 1/(1 + e^{-z}) \quad (2.7)$$

$$\sigma'(z) = \sigma(z) \cdot (1 - \sigma(z)) \quad (2.8)$$

(2.7) ve (2.8) sırasıyla sigmoid fonksiyonu ve fonksiyonun birinci türevidir. (2.8)'den net olarak görülebildiği üzere fonksiyonun değerini 0'a ya da 1'e yakınsatan girdi değerleri için fonksiyonun birinci türevi 0'a yakınsamaktadır. Türevin 0'a yakınsaması ise öğrenmeyi, türev temelli optimizasyon yöntemlerinde (ör. gradyan alçalma algoritması) yavaşlatmaktadır.


### **iii. Hiperbolik Tanjant (TanH) Aktivasyon Fonksiyonu:**

Hiperbolik tanjant fonksiyonu (tanh), (-1,1) aralığında değerler üreten ve türevlenebilir yapıda bir diğer popüler aktivasyon fonksiyonudur. Tanh, YSA'da girdi değerlerinin örtük katmanlarda genelde 0 etrafında dağıldığı gözlenerek ve 0 girdisi etrafında yüksek değerli (sigmoid'e göre yaklaşık 4 kat) birinci türev değerine sahip olan bir aktivasyon fonksiyonu alternatifidir. Tanh, sigmoid'den farklı olarak yalnızca pozitif değerler değil negatif değerler de üretebilmektedir. Ancak; her iki fonksiyon için de kaybolan eğim sorunsalı uç değerlerde gözlenmektedir:

$$\tanh(z) = (1 - e^{-2z})/(1 + e^{-2z}) \quad (2.9)$$

$$\tanh'(z) = 1 - (\tanh(z))^2 \quad (2.10)$$

(2.9) ve (2.10)'da sırasıyla hiperbolik tanjant fonksiyonunun matematiksel ifadesi ve bu fonksiyonun türevi verilmiştir. Buna göre fonksiyonun girdileri 0 etrafındayken türev değeri 1 civarındadır (sigmoid için bu değer 0.25 civarındadır). 0 etrafında dağılan girdi değerleri için tanh, sigmoid'e göre öğrenme hızı avantajı sağlamakla beraber sigmoid fonksiyonu gibi düşük negatif girdi değerleri için ve yüksek pozitif girdi değerleri için türev fonksiyonun değeri 0'a yakınsamakta ve bu nedenle öğrenmeyi yavaşlatabilmektedir. Şekil 6, tanh fonksiyonunun bir görsel temsili ve sigmoid fonksiyonu ile karşılaştırmasıdır:



**Şekil 6:** Tanh Ve Sigmoid Fonksiyonları

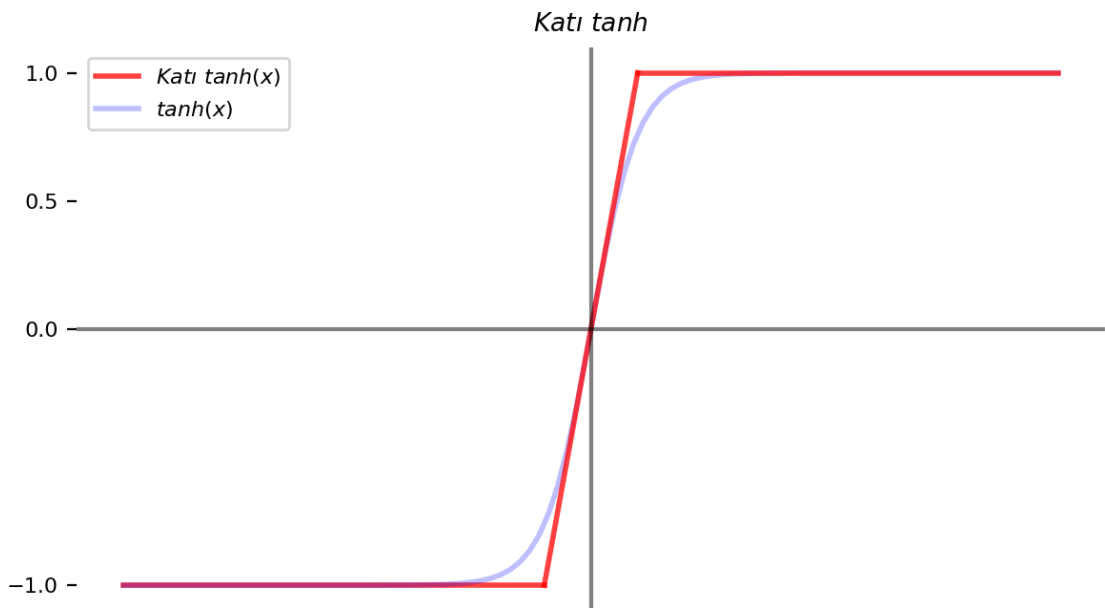
**iv. Katı-Hiperbolik Tanjant Aktivasyon Fonksiyonu:**

Hiperbolik tanjant fonksiyonunda gözlenebilen kaybolan eğim sorunsalına bir çözüm olarak geliştirilen katı hiperbolik tanjant (katı-tanh) fonksiyonu (Nair ve Hinton, 2009), tanh fonksiyonunu için bir parçalı doğrusal yakınsamadır:

$$\text{katı-tanh}(z) = \begin{cases} 1 & , & z \geq 1 \\ z & , & 1 > z \geq -1 \\ -1 & , & \text{diğer} \end{cases} \quad (2.11)$$

$$\text{katı-tanh}'(z) = \begin{cases} 0 & , & z \geq 1 \\ 1 & , & 1 > z \geq -1 \\ 0 & , & \text{diğer} \end{cases} \quad (2.12)$$

Katı-tanh fonksiyonu ve türevi sırasıyla (2.11) ve (2.12)'de sunulmuştur. Buna göre girdi değerleri  $[-1,1]$  aralığında olduğu sürece öğrenme sürecinde kaybolan eğim sorunsalı yaşanmayacaktır. YSA veri önışleme sürecinde girdi verisinin normalize edilmesi son derece yaygın bir yaklaşımdır ve normalize edilmiş veri ile çalışıldığında katı-tanh girdi değerlerinin  $[-1,1]$  aralığının dışına çıkmayacağı söylenebilir.



**Şekil 7:** Katı-Hiperbolik Tanjant ve Hiperbolik Tanjant Fonksiyonları

Şekil 7, katı-tanh ve tanh fonksiyonlarının görsel bir karşılaştırmasıdır ve katı-tanh fonksiyonunun parçalı doğrusal yapısını net olarak ortaya koymaktadır.

**v. Hard-Sigmoid Aktivasyon Fonksiyonu:**

Sigmoid fonksiyonu (0,1) aralığında değerler üretmektedir. Dolayısıyla etkin birimlerin (etkinlik skoru 1) hiç biri tam olarak tahminlenemeyecektir. Bu değer aralığını [0,1] yapabilmek adına ve katı-tanh fonksiyonundan esinlenerek katı-sigmoid fonksiyonu düşünülmüştür:

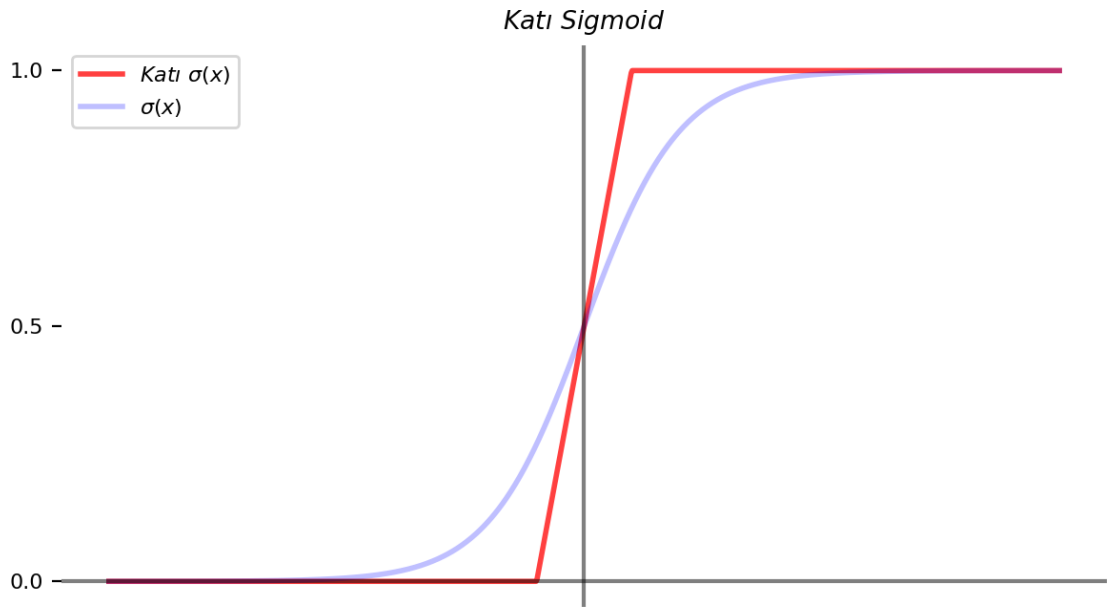
$$katı - \sigma(z) = maks\left(0, \min\left(1, \frac{z+1}{2}\right)\right) \quad (2.13)$$

$$katı - \sigma'(z) = \begin{cases} 0 & , z \geq 1 \\ 0.5 & , 1 > z \geq -1 \\ 0 & , diğ er \end{cases} \quad (2.14)$$

(2.13) ve (2.14)'de katı sigmoid fonksiyonu ve bu fonksiyonun türevi için matematiksel gösterim verilmiştir. [-1,1] aralığındaki girdiler için yüksek türev değerli (0.5) ve [0,1] aralığında değerler üreten katı sigmoid fonksiyonu VZA etkinlik skorunun tahmin değerinin olduğu çıktı katmanı için ideal yapıdadır.

Katı sigmoid fonksiyonu da normalize girdiler kullanıldığında katı-tanh fonksiyonu gibi kaybolan eğim sorunsalına neden olmamaktadır.

Şekil 8, katı sigmoid ve sigmoid fonksiyonlarının görsel bir karşılaştırmasını sunmaktadır:

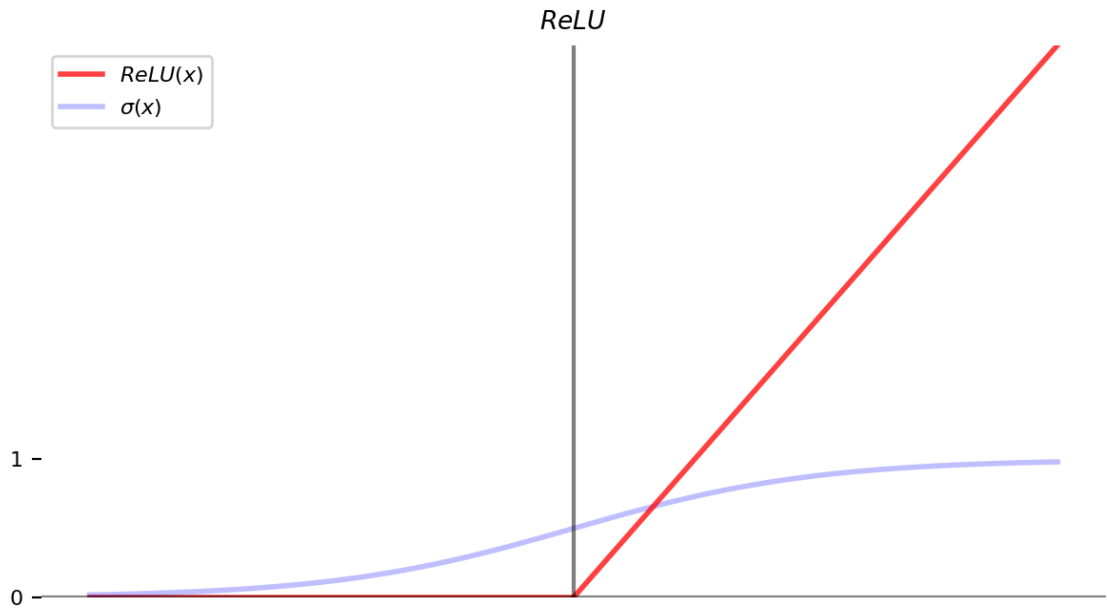


**Şekil 8:** Katı Sigmoid ve Sigmoid Fonksiyonu

**vi. ReLU Aktivasyon Fonksiyonu:**

ReLU (rektifiye doğrusal birim, *rectified linear unit*) aktivasyon fonksiyonunun YSA'da kullanımı ilk defa Teh ve Hinton (2000) tarafından önerilmiş ve Agarap (2018) tarafından bu fonksiyonun YSA'da en hızlı öğrenmeyi sağladığı tartışılmıştır.

ReLU, negatif olmayan değerler için  $f(x)=x$  fonksiyonu iken negatif tüm girdiler için 0 değerlidir. Parçalı doğrusal yapılı bu fonksiyonun görsel sunumu Şekil 9'da verilmiştir:



**Şekil 9:** ReLU Aktivasyon Fonksyonu ve Sigmoid Fonksyonu

Şekil 9'a göre negatif olmayan girdilerin olduğu her bölgede ReLU, sigmoid fonksiyonundan daha dik bir eğime sahiptir. Diğer bir ifade ile yüksek türev değerine sahiptir ve bu sayede YSA öğrenme sürecini hızlandırmaktadır.

$$ReLU(z) = maks(0, z) \quad (2.15)$$

$$ReLU'(z) = \begin{cases} 0 & , z < 0 \\ 1 & , diğer \end{cases} \quad (2.16)$$

(2.15) ve (2.16)'da sırasıyla ReLU fonksiyonu ve türevi gösterilmiştir. (2.16)'ya göre ReLU'nun türevi, negatif girdi değerlerinin yer aldığı bölgede 0 değerlidir. Bu olgu "ölü ReLU" olarak bilinmektedir ve çözümü için ReLU'ya benzer parçalı fonksiyon biçiminde alternatifler önerilmiştir. Ancak; bu tez çalışmasında girdi katmanında VZA kriterleri verisi kullanılmaktadır. Örtük katmanların tümünde ise aktivasyon fonksiyonları ReLU olarak seçilmiştir ve dolayısıyla hiç bir nöronun girdisi negatif değerli değildir, ölü ReLU sorunu ile ona bağlı olarak kaybolan eğitim sorunsalı bu tez çalışmasındaki modellerde gözlenmemektedir.

### 2.3.1.3. Gradyan İniş ve Stokastik Gradyan İniş Algoritması

Gradyan iniş yöntemi (Gİ), ağırlıkların ve sapmaların bir başlangıç çözümünden başlayarak yitim fonksiyonunun tüm ağırlıklara ve sapmalara göre kısmi türevlerinin bu ağırlık ve sapmaların mevcut değerinde değerlendirilmesi ile elde edilen yönler ile adım büyüklüğü çarpımı kadar ağırlıkların ve sapmaların azalmasını içeren iterasyonları tekrarlamasına dayanmaktadır.

Gİ, birinci türev bilgisinin sıfır'a yakınsamasıyla ağırlıkları ve sapma değerlerini güncelleme gücünü kaybedecektir ve genel olarak algoritma için durdurma kriteri belli sayıda iterasyon boyunca yitim fonksiyonu değerinin değişmemesi olarak belirlenmektedir. Birinci türev bilgisinin sıfıra yakınsadığı, eğimin olmadığı bölgeler yitim fonksiyonunun yerel minima noktaları, yerel maksima noktaları veya eyer noktalarıdır. Gİ, ikinci türev bilgisini kullanmayan bir algoritma olduğu için bir yerel maksimada ya da bir eyer noktasında da sonlanabilecektir.

Ayrıca belirlenen başlangıç çözümünden başlayarak bir yerel minima bulunsa bile bu yerel minimanın global minima ya da iyi (görece düşük değerli) bir yerel minima olmasının da bir garantisi yoktur. Bu nedenle birden çok ve rassal başlangıç çözümü ile arama yapılması, Stokastik Gradyan İniş Algoritması (SGİ), iyi bir yerel minima bulma olasılığını artıran bir diğer yaklaşım olarak önerilmiştir (Saad, 1998).

### 2.3.1.4. Momentum ve Nesterov Momentumu

SGİ'nin öncelikle yerel maksimalarda durma olasılığını elimine etmek için ve daha sonra da eyer noktalarında durma olasılığını düşürmek için Polyak (1964) önceki iterasyonlardaki eğim bilgilerinin yeniden eskiye doğru üstel olarak azaltılarak toplandığı bir yön bilgisini önermiştir. Yön, artık yalnızca ağırlıkların ve sapmaların mevcut değeri için birinci türev bilgisi fonksiyonun önceki eğim bilgilerini de taşıdığı için birinci türev bilgisinin sıfır değerli olduğu bir noktada önceden kazandığı "momentum" ile ağırlıkları ve sapmaları güncellemeye devam

edebilecektir. Böylece yitim fonksiyonu eğimini bir yerel maksimumda veya yerel minimumda yitirse bile momentumlu bir algoritmanın bu noktanın komşuluğunda aramaya devam etme olanağı olacaktır. Eğimin yitirildiği nokta bir konveks bölgeyse model birkaç iterasyon sonra yerel minimuma yakınsayacak; bir konkav bölgeyse yerel maksimumdan kaçabilecek ve eğer bir yerel minimum (plato) ise aramayı sürdürerek (ancak; güncellemeler giderek küçülerek) düz bölgeden kaçma olasılığına sahip olacaktır.

Polyak'ın (1964) önerdiği yöntem, momentumu doğrudan yön bilgisi olarak kullanması nedeniyle konveks bölgelerde salınımı yavaş sönmülenebildiği için çözüm süresini uzatabildiği için momentumu mevcut hıza bir düzeltme faktörü olarak eklemek düşüncesi geliştirilmiştir (Nesterov, 1983; Sutskever vd., 2013). Yazında Nesterov momentumu olarak anılan bu yaklaşım, konveks bölgelerde salınımın çok daha hızlı sönmülmesini sağlamış ve yerel minimum değerlerine çok daha hızlı yakınsama imkanı vermiştir.

### 2.3.1.5. Öğrenme Hızını Uyarlama Yaklaşımları

Birinci türeve dayalı yön bilgisi ile aramaya getirilen momentum kökenli iyileştirmelere ek olarak algoritmayı hızlandırmak üzere öğrenme hızını uyarlamak üzerine çeşitli yöntemler geliştirilmiştir. Tez çalışmasında YSA uygulamalarında kullanılan Adam Optimizasyon Algoritması (Adam; Kingma ve Ba, 2014); türev temelli stokastik ve öğrenme hızı uyarlaması içeren bir yaklaşımdır. Adam; AdaGrad (Asi ve diğerleri, 2011) yönteminin hızlandırılmış versiyonu olan RMSprop (Hinton vd., 2012) algoritmasının Nesterov momentumu eklenmiş versiyonu olarak düşünülebilir.

AdaGrad algoritması, öğrenme hızını tüm geçmiş iterasyonlardaki karesi alınmış (ikinci dereceden) eğimler bilgisini kullanarak azaltmaktadır. Bu nedenle de bir konveks bölgeye ulaşmadan adım büyüklüğünü fazla küçülebilecek ve iyi bir çözüme ulaşamayabilecektir. Ancak; AdaGrad algoritması konveks bölgelerde yerel minimumlara çok hızlı yakınsayabilen bir yöntemdir.



RMSprop algoritması, Asi ve diğerlerinin (2011) önerdiği AdaGrad algoritmasını konveks olmayan bölgelerde hızlandıracak bir öneri ile geliştirmiştir. Hinton vd. (2012), RMSprop algoritmasında tüm geçmiş iterasyonlardaki eğimlerin karesi bilgisi yerine üstel olarak ağırlıklandırılmış bir hareketli ortalama yaklaşımını önermiştir. Böylece RMSprop, önemsiz geçmişte (uzak geçmişte) kalan eğitim bilgilerinin güncellemeleri yavaşlatan etkisini ortadan kaldırılmıştır ve algoritmanın neredeyse AdaGrad'ın bir konveks bölgede başlangıç çözümü verilmiş versiyonu gibi davranmasını sağlamıştır. Ancak; RMSprop'da ikinci dereceden momentum içermesi nedeniyle optimizasyon sürecinin başlarında çok düşük model başarımları gözlemlenebilmektedir.

Adam, RMSprop algoritmasını Nesterov momentumu ile birleştirerek çözümlerin yerel maksima ya da eyer noktalarında takılıp kalması olasılığını azaltmıştır. Adam'da momentum, eğimlerin üstel olarak ağırlıklandırılmış birinci dereceden momentum bilgisinin bir tahmini olarak doğrudan uygulanmaktadır. Ayrıca RMSprop'a doğrudan momentum eklemek ölçeklendirilmiş eğimlerle momentum hesaplamak anlamına geleceğinden kuramsal olarak güçlü bir temele sahip değildir (Goodfellow ve diğerleri, 2016, s.305-306).

Adam (Kingma ve Ba, 2014) algoritması kısaca sunulacak olursa;

- Öğrenme kümesinden N gözlem içeren bir örneklemini etiket bilgileri ile birlikte al,
- Bir başlangıç yönü ile öğrenme hızı kadar başlangıç çözümünde kullanılan ağırlıkları ve sapmaları güncelle,
- Birinci türev bilgisini hesapla,
- Eğimleri topla (momentum hesapla):  $\vec{r} = \rho \vec{r} + (1 - \rho) \nabla \odot \nabla$ ,
- Yön bilgisini hesapla:  $\alpha \vec{v} - \frac{\epsilon}{\sqrt{\vec{r}}} \odot \nabla$   
( $\frac{1}{\sqrt{\vec{r}}}$  faktörü eğimin tüm elemanlarına uygulanır)
- Ağırlıkların ve sapmaların mevcut değerlerine yönde karşılık gelen değerleri ekleyerek ağırlıkları ve sapmaları güncelle

Burada  $\rho$  sönümlenme hızı (decay rate),  $\epsilon$  genel öğrenme hızıdır. Adam algoritmasını uygulayabilmek için bir başlangıç çözümü ve başlangıç yönü ( $\vec{v}$ ) bilgisine de ihtiyaç duyulmaktadır. Bazı veri kümelerinde Adam'ın yüksek performans sergileyebilmesi için genel öğrenme hızı hiperparametresini değiştirmek gerekebilecektir, bu tez çalışmasındaki her iki YSA uygulamaları ailesinde de bu değer değiştirilmiştir.

### 3. BÖLÜM

## LİTERATÜRDE VERİ ZARFLAMA ANALİZİ-YAPAY SİNİR AĞLARI ÇALIŞMALARI

Tez çalışmasının bu bölümü; Yapay Sinir Ağları ve Veri Zarflama Analizinin beraber kullanımının amaç, yöntem, kullanılan verinin teması bakımından ele alındığı bir yazın incelemesini içermektedir.

YSA-VZA çalışmalarında öncü çalışma olan Athanassopoulos ve Curram (1996) VZA'yı ve YSA'yı bir Cobb-Douglas üretim fonksiyonuna bağlı olarak türetilmiş KVB'lerin etkinliğini ölçebilmek bakımından karşılaştırmıştır. Daha sonra Santin vd., (2004) de VZA ve stokastik sınır analizini (SSA) YSA ile karşılaştırmıştır. Her iki çalışmada da YSA'nın etkinlik analizinde VZA için uygun bir alternatif olduğu değerlendirilmiştir. YSA-VZA alanında ilk uygulama çalışması Costa ve Markellos'un (1997) 1970-1994 yılları verisini kullanarak Londra'da yıllık metro performansı ölçümüdür ve bu çalışmada da YSA'nın ölçeğe göre sabit getiri (Charnes vd., 1978) ve ölçeğe göre değişken getiri (Banker vd., 1984) altında VZA modelleri ile benzer sonuçları ürettiği ortaya konmuştur. Yine Wu, Yang ve Liang (2006) bankacılık sektörüne uyguladıkları bir YSA-VZA çalışmasında YSA'nın ölçeğe göre sabit getiri altında VZA skorlarını iyi tahminleyebildiğini tartışmıştır. Ve Emrouznejad ve Shale (2009) da beş ayrı 10000 gözlemlili türetilmiş veri kümesi üzerinde yaptıkları deneylerde YSA'nın VZA'yı tahminlemede iyi bir yöntem olduğunu doğrulamışlardır. Benzer biçimde Hanafizadeh vd. (2014) yatırım fonlarının değerlendirilmesi üzerine yaptığı çalışmada büyük veri kümelerinde YSA ile başarılı etkinlik skoru tahminleri elde etmiştir ve analizin hızlanması ile yatırımcı tepki sürelerini kısaltabileceğini öne sürmüştür. Kwon (2017) Amerika'da 2040'a kadar demiryolları üzerinden navlun performansı üzerine yaptıkları çalışmada VZA'nın tahmin fonksiyonu olmamasını

gerekçe göstererek bu açığı mevcut olan 2005-2012 yılları verisi üzerinden eğitilmiş bir YSA ile etkinlik skorlarının tahminlenmesi ile gidermeyi önermişlerdir. Ayrıca YSA ve VZA'yı beraber kullanan çalışmalar da (bkz. Azadeh vd., 2007; Azadeh, Saberi ve Anvari, 2010; Azadeh, Saberi, Anvari ve Mohamadi, 2011; Azadeh vd., 2011; Misiunas vd., 2016) vardır. Bu çalışmalarda KVB'lerin girdileri ile çıktıları arasındaki ilişkiler incelenmiştir.

YSA kullanarak VZA etkinlik skoru tahmin etmenin en önemli eksikliği, KVB'ler için VZA etkinlik skorlarının değişmez nitelikte olmayışı ve etkin sınıra uzaklığa göre tanımlanması yapısallığını YSA'nın hesaba katmayışıdır (Koronakos ve Sotiropoulos, 2020). Diğer bir ifade ile yalnızca verinin genel örüntüsünü veya bir gözlemler altkümesi için hesaplanan VZA etkinlik değerlerini temel alan bir yöntemin etkin sınır değişimlerini sağlayan üstün yeni KVB'ler olasılığı düşünüldüğünde etkinlik skorlarını abartılı tahmin edebileceğidir. Bu sorunun yumuşatılabilmesi için yazında tartışılmış veri önışleme yöntemleri (bkz. Dula, 2011) bulunmaktadır. Veri önışlemeye tabi tutulan YSA'nın ölçeğe göre sabit getiri ve ölçeğe göre değişken getiri altında VZA modelleri ile hesaplanan etkinlik skorlarını başarılı tahminlediğini raporlanmıştır (Koronakos ve Sotiropoulos, 2020).

YSA modellerini kullanırken analiz başarısını etkileyen önemli bir unsur hiperparametre (model tasarımı) optimizasyonudur. Genel olarak YSA mimarisinin deneme yanılma ile belirlenebileceği değerlendirilse de (Hoang ve Kang, 2018; Mateus vd., 2021; Oyamada, 2018; Zhang vd., 2019) Singpai ve Wu (2020), YSA mimarisi optimizasyonu süreci için "AutoML" (Otomatik makine öğrenmesi, OtoMÖ) yöntemini önermiş ve özellikle yayılımı düşük veri içeren durumlarda İleri yayımlı ağların performansı düşerken OtoMÖ yönteminin bu durumdan etkilenmediğini tartışmıştır. Ancak; yine kendi çalışmalarında modelin açıklama gücü üzerinde önemli farklar oluşmadığını da belirtmişlerdir (Singpai ve Wu, 2020).

Henriques vd., (2020) bankacılık alanında çalışılmış 59 makaleyi inceleyerek YSA-VZA yaklaşımlarını iki sınıfa ayırmıştır. Bunlardan ilki girdilerin çıktılar ile ilişkisini açıklanabilir hale getirmek üzere üretim sürecini aşamalara bölerek ara değişkenlerin tanımlandığı içsel yaklaşımdır. İkinci yaklaşım ise VZA sonrası etkinlik skorlarını temel alarak ve etkinliği belirleyen faktörleri açıklamaya yönelik ikincil yöntemlerin uygulanmasıdır.

YSA ile VZA yöntemlerini beraber kullanmak üzerine çalışmalar YSA'yı VZA'yı tamamlayan bir yöntem olarak kullanmak ya da YSA'yı VZA'nın yerini alacak bir yöntem olarak kullanmak üzerinedir. YSA'yı VZA'nın bir alternatifi olarak gören çalışmalar genel olarak sınıflandırma, sıralama ve tahmin gücü üzerinde durmaktadır (bkz. Azadeh vd., 2007; Mousavi vd., 2019; Samoilenko ve Osei-Bryson, 2010; Santin vd., 2004; Wang, 2003; vb.). VZA'yı desteklemek ve analizi güçlendirmek üzerine olan çalışmalar ise YSA'yı VZA ile beraber kullanma bakış açısını benimsemektedir (bkz. Çelebi ve Bayraktar, 2008; Kwon, 2014; Shabanpour vd., 2017; Shokrollahpour vd., 2016; vb.) ve bu alandaki ilk çalışma Athanassopoulos ve Curram'ın (1996) VZA ile YSA'yı karşılaştırmasıdır.

Ayrıca iki aşamalı YSA-VZA çalışmalarını amaçlarına göre de ayrıştırılabilir. Aralarında Emrouznejad ve Shale (2009), Kheirkhah vd., (2013), Kwon ve Lee (2015), Tsolas vd., (2020) ve Wu vd.'nin, (2006) de olduğu bazı çalışmalarda etkinlik skoru tahminlemek üzere ilk aşamada VZA modelleri çözülerek YSA'ya bir öğrenme kümesi oluşturulmuş ve ardından YSA ile analize katılacak olan KVB'lerin etkinlik skorları tahminlenmiştir. Diğer bazı çalışmalarda da YSA, KVB'lerin hangi etkinlik sınıfına ait olduğunun sınıflandırılmasında kullanılmıştır (bkz. Çelebi ve Bayraktar, 2008; Shokrollahpour vd., 2016; Wang, 2003).

YSA modeli amaçlarına göre de çalışmalar simülasyon (Samoilenko ve Osei-Bryson, 2010), etkinliğe göre sınıflandırma (Mostafa, 2009a; 2009b; 2009c; Wu vd., 2006) ya da etkinlik skorlarının tahminlenmesi (Emrouznejad ve Shale, 2009; Kwon ve Lee, 2015; Omar vd., 2017; Shokrollahpour vd., 2016) için sınıflandırılabilir.

Büyük ölçekli verilerde VZA yerine YSA çalışmalarında genel olarak motivasyon analiz toplam süresini kısaltarak karar sürecini daha çevik hale getirmektedir. Dula ve Lopez (2013), kredi kartı yolsuzluklarının belirlenmesi üzerine yaptıkları çalışmada modelin çözüm hızına duyulan ihtiyaç sonucu geleneksel VZA modelleri yerine YSA-VZA modellerine yönelmiştir. Özellikle veri hacmi büyüdükçe analizi hızlandırmak için yapılan veri ön işleme sürecinin değeri artmaktadır ve yazında etkin ve etkin olmayan KVB'lerin ayrıştırılması için yapılmış prosedürler (Chen ve Cho, 2009; Dula, 2011; Dula ve Lopez, 2006) tanımlanmıştır.

Yazındaki çalışmalar YSA-VZA yaklaşımlarının küçük veri kümelerinde de (Kwon ve Lee, 2015) büyük veri kümelerinde de (Emrouznejad ve Shale, 2009; Zelenyuk, 2020) avantajlar sağladığını ortaya koymuştur (Mousa ve Kamel, 2021).

**Tablo 1: YSA-VZA Çalışmaları**

No	YSA Kullanım Amacı ve Biçimi	Çalışmalar	Kullanılan Modeller	Analiz Edilen Veri
1		Athanassopoulos ve Curram (1996)	VZA, İleri Beslemeli YSA	250 Banka için türetilmiş 16 veri kümesi
2		Liao vd., (2007)	VZA, İleri Beslemeli YSA	7 ülkeye ait 35 yıllık veri
3	Etkinlik Tahmini: Modellerin Karşılaştırılması	Liu vd., (2013)	VZA, İleri Beslemeli YSA	29 Yarı iletken üretim işletmesine ait 6 yıllık veri
4		Santin (2008)	VZA, İleri Beslemeli YSA	100 gözlemden oluşan türetilmiş veri
5		Santin vd., (2004)	VZA, İleri Beslemeli YSA	50-300 gözlemlili türetilmiş veri
6		Wang (2003)	VZA, İleri Beslemeli YSA	Beden eğitimi programında (physical fitness test, PFT) tanımlı 49 eğitim düzeyi
7		Azadeh vd., (2010)	VZA, İleri Beslemeli YSA	19 Enerji santrali için 8 yıllık veri
8		Azadeh vd., (2011)	VZA, İleri Beslemeli YSA	102 Banka şubesi verisi
9	Etkinlik Tahmini: Modellerin Tamamlayıcı Kullanımı	Kwon (2014)	VZA, İleri Beslemeli YSA	8 işletmeye ait 8 yıllık veri
10		Sreekumar ve Mahapatra (2011)	VZA, İleri Beslemeli YSA	49 işletme bölümü (Üniversite)
11		Ülengin vd., (2011)	VZA, İleri Beslemeli YSA	45 ülke
12		Vaninsky (2004)	VZA, İleri Beslemeli YSA	50 firmaya ait 4 günlük hisse verisi
13		Mostafa (2009a)	VZA, Olasılıklı YSA	43 Banka
14		Mostafa (2009b)	VZA, Olasılıklı YSA	85 Banka
15	Etkinlik Skoru Gruplarına Göre Sınıflandırma: Modellerin Tamamlayıcı Kullanımı	Mostafa (2009c)	VZA, Olasılıklı YSA	62 işletme
16		Wu (2009)	VZA, İleri Beslemeli YSA	23 Tedarikçi firma
17		Wu vd., (2006)	VZA, İleri Beslemeli YSA	142 Banka şubesi
18	Öğrenme Kümesinin İncelenmesi: Modellerin Tamamlayıcı Kullanımı	Emrouznejad ve Shale (2009)	VZA, İleri Beslemeli YSA	10000 gözlemden oluşan türetilmiş veri
19		Pendharkar (2005)	VZA, İleri Beslemeli YSA	275 Hastane
20		Pendharkar ve Rodger (2003)	VZA, İleri Beslemeli YSA	100 Hastane
21		Çelebi ve Bayraktar (2008)	VZA, İleri Beslemeli YSA	20 Tedarikçi işletme
22		Kheirkhah vd., (2013)	VZA, İleri Beslemeli YSA	130 aylık elektrik verisi
23	Veri İşleme: Modellerin Tamamlayıcı Kullanımı	Kuo vd., (2010)	VZA, İleri Beslemeli YSA	12 Tedarikçi işletme
24		Liao ve Li (2008)	VZA, "Self Organizing Feature Map"	43 gözlemlili türetilmiş veri
25		Pendharkar (2011)	VZA, Radyal Tabanlı YSA	30 gözlemlili türetilmiş veri
26		Samoilenko ve Osei-Bryson (2013)	VZA, İleri Beslemeli YSA	18 ülkeye ait 10 yıllık veri

Tablo 1, 5 ayrı kategori içerisinde her bir kategori için seçilen çalışmalar üzerinden YSA-VZA yazını özetlemektedir. Her bir satırda çalışmaların künyesi numaralar ile tanımlanmış ve künye başlığını takip edecek şekilde öncelikle çalışmanın ait olduğu kategori, çalışmanın yazarları ve yayınlandığı yıl sonrasında ise çalışmada kullanılan modeller ve analize konu olan veri kümesi bilgisi sunulmuştur.

[1-6] no'lu çalışmalar, çalışmalara ait tablo 1'de verilmiş olan veri kümesi üzerinden etkinlik tahmini yapılarak VZA ve YSA modellerini ve sonuçlarını karşılaştırmak üzerinedir. Bu kategoriyi temsilen 2 no'lu çalışmada 1963-1998 yılları arasında 7 Doğu Asya ülkesinin performans ölçümü için YSA, VZA'ya alternatif bir yaklaşım olarak kullanılarak elde edilen sonuçlar her iki yöntem için karşılaştırılmıştır.

[7-12] no'lu çalışmalar, VZA ve YSA modellerinin birlikte tamamlayıcı nitelikte kullanıldığı çalışmalardır. Örneğin, 9 no'lu çalışmada birleştirilmiş performans modelleme yaklaşımında iki farklı ancak birbirini tamamlayıcı yöntem olan VZA ve YSA'nın iki aşamalı bir analizi yapılmıştır. Bu analizin ön işleme kısmında VZA, öğrenme ve tahminleme kısmında ise YSA modeli kullanılarak söz konusu iki yöntemin performans ölçümünde birbirlerini tamamlayıcı bir formu önerilmiştir.

[13-17] no'lu çalışmalar benzer biçimde VZA ve YSA modellerinin tamamlayıcı nitelikte fakat etkinlik skor değerlerine göre sınıflandırılması üzerinedir. 14 no'lu çalışmada 85 adet bankanın göreceli etkinliklerini modellemek ve sınıflandırmak üzere VZA ve olasılıklı YSA birlikte kullanılmıştır. Benzer biçimde 17 no'lu çalışmada ise ilk modülde VZA kullanarak, tedarikçileri etkinlik skorlarına göre; etkinler ve etkin olmayanlar şeklinde sınıflandıran, ikinci modülde ise eğitilmiş karar ağaçları ve YSA yöntemleri kullanan tedarikçi seçimi üzerine iki modüllü hibrit bir model önerilmiştir.

[18-20] no'lu çalışmalarda VZA ve YSA modellerinin hibrit kullanım örnekleri görülmektedir. 18 no'lu çalışmada büyük ölçekli veri kümelerinde VZA'nın çok



fazla bilgisayar kaynağı gereksinimi sorunu üzerine bir yöntem önerisi olarak geri yayımlı YSA modeli 10000 KVB'li 5 ayrı veri kümesinde etkinlik skoru ölçümü yapılarak aynı veri kümelerinde geleneksel VZA ölçümü ile elde edilmiş etkinlik skorları ile karşılaştırılmıştır. 19 no'lu çalışmada ise benzer şekilde VZA ve YSA'nın bir hibrit modeli kullanılarak sağlık ve yazılım mühendisliği verisi ve monotonluk varsayımı üzerinden YSA ile tahminleme modeli kurulmuştur. Bu kategorideki çalışmalarda YSA ile etkinlik skorunun tahminlenebileceği tartışılmış ancak; bir doğrulama kümesi üzerinden bu sav test edilmemiştir.

[21-26] no'lu çalışmalar çeşitli karakteristiklerdeki veri kümelerinde VZA ile YSA hibrit modellerinin kullanımı üzerinedir. 21 no'lu çalışma tedarikçi değerlendirme ve seçme sürecine orijinal bir katkı sunmak adına değerlendirme kriterlerinin eksik bilgisi altında VZA ve YSA modellerinin yeni bir entegrasyonunu araştırmak üzerinedir. Bu çalışmada eksik VZA kriterleri verisi YSA modellemesi ile tahminlenerek tamamlanmış ve veri kümesi VZA'ya hazır hale getirilmiştir. 25 no'lu çalışmada ise sınıflandırma problemleri için hibrit radyal tabanlı VZA-YSA modeli önerilerek, farklı karakteristikteki sınıflandırma problemleri için simülasyon verisi kullanarak radyal tabanlı VZA-YSA modeli ile bu sorunun nasıl çözüleceği anlatılmış ek olarak da radyal tabanlı VZA-YSA modelinin ileri beslemeli ve olasılıksal YSA ile karşılaştırması yapılmıştır.

VZA-YSA çalışmaları büyük ölçekli veride VZA kaynak gereksinimlerinin üstel artış örüntüsü nedeniyle analizin hızlandırılabilmesi adına YSA ile etkinlik skoru tahminlenmesi etrafında odaklanmıştır. Ancak; paralel hesaplama ve VZA'nın bölünebilir programlamaya (*separable programming*; Stefanov, 2001) uygun olmasına değinilmemiştir ve çalışmalarda sinama veya doğrulama kümeleri üzerinden model performansı sunulmamıştır. Modelin elde olmayan veri üzerindeki performansını kanıtlamak yerine potansiyel faydaları tartışılmıştır (bkz. Emrouznejad ve Shale, 2009; Misiunas vd., 2016; vb.). Bu genel akımın dışında YSA ile VZA'nın beraber kullanımına dair özgün çalışmalar da vardır. Örneğin; Çelebi ve Bayraktar (2008), Atıcı vd.'nin (2018) önerdiği VZA'da eksik veriye yönelik bulanık mantık yaklaşımına bir alternatif olarak YSA ile eksik VZA

kriterleri verisinin tahminlenmesi yaklaşımını önermiştir. Bu çalışmada YSA'nın eksik veride çalışabilme avantajından yararlanılmış ve Podinovski ve Thanssouli'sin (2007) önerdiği eksik veri doldurma yöntemlerinin (eksik girdi verisi yerine büyük pozitif değerler atama ve eksik çıktı verisi yerine de 0 atama) aksine girdilerle çıktılar arasında bir örüntü varsayarak eksik veriyi kestirim yolu ile tamamlamıştır.

YSA'nın VZA'ya olası alternatif katkılarının arayışı içinde bu tez çalışmasında YSA, yazında daha önce kullanılmamış bir biçimde VZA'da ayrıştırma gücünü iyileştirmek üzere kullanılmıştır. Bu önerilen yeni yöntemlerin VZA'yı tutarlı ve veri temelli nesnel kurallara dayanan;

- süperetkinlik (Andersen ve Petersen, 1993) yöntemine kıyasla üstün biçimde tüm KVB'ler için etkinlik skorlarını elde edilebilen,
- çapraz etkinlik (Doyle ve Green, 1994) yöntemine kıyasla üstün biçimde hiçbir KVB için negatif etkinlik değerleri hesaplamayan,
- geleneksel ağırlık kısıtlama yaklaşımlarına kıyasla da üstün biçimde nesnel tam bilgiye erişen ve öznel bilgi kullanmayan

bir çerçeve önermesi bakımından önemli olduğu düşünülmektedir. Önerilen yöntemler yorumlanabilir makine öğrenmesi algoritmalarına dayanmaktadır ve bu tez çalışması, kardinalitesi düşük veri kümelerinde kullanılan yöntemin algoritma çıktılarında değişkenliği tamamen indirgeyerek iyileştirildiği bir teknik katkı da içermektedir.

## 4. BÖLÜM

### DERİN ÖĞRENME DESTEKLİ VERİ ZARFLAMA ANALİZİNDE AYRIŞTIRMA GÜCÜ İYİLEŞTİRMESİ

Kıyaslanan gözlemlerin (Karar Verme Birimleri, KVB) performans analizi için yaygın olarak kullanılan Veri Zarflama Analizi, KVB'ler için mümkün olan en yüksek etkinlik skorunun hesaplanmasına yönelik kriter ağırlıklarının belirlenmesine dayalıdır. VZA'da kriterlerin etkinlik skoru içindeki payını temsil eden ağırlıkların her bir KVB'ye has farklı değerler alabilmesine ağırlık belirleme serbestisi denir.

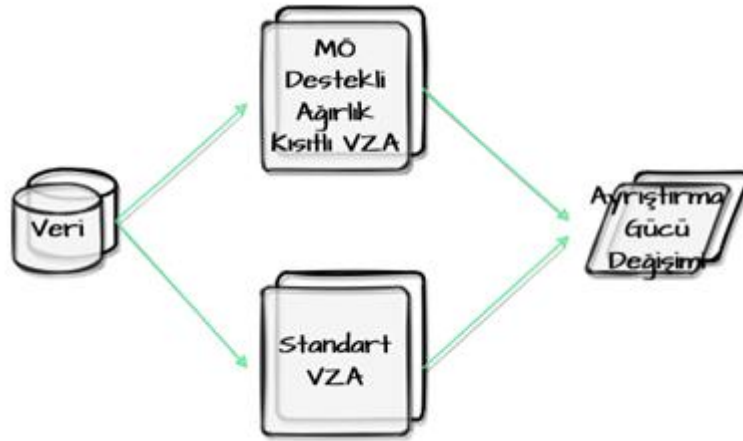
Belirlenen kriter ağırlıklarına göre her bir KVB'ye (0,1] aralığında etkinlik skoru değerleri tanımlanır ve etkinlik skoru 1 değerli KVB'lere etkin birimler denirken etkinlik skoru 1'den düşük olan KVB'lere de etkin olmayan birimler denir. Ağırlık belirleme serbestisi, KVB'ler arasında yapılan ayrıştırmada aslında önemli olduğu halde hesaplamada kullanılmayan kriterler nedeniyle etkin bulunma veya aslında çok önemli olmadığı halde etkinlik skorunda baskın unsur haline gelerek etkin KVB tanımlama gibi sorunlara yol açabilmektedir. Bu olguya ayrıştırma gücü sorunsalı denmektedir.

VZA ile performans ölçümü araştırmalarında ayrıştırma gücünü iyileştirmeye yönelik bir çok yöntem önerilmiştir (bkz. Bölüm 1.3.1). Tez çalışmasının bu bölümünde ayrıştırma gücünü iyileştirmek üzere seçilen yöntem ağırlık kısıtlı VZA'dır. Ağırlık kısıtlı VZA'da kriterlerin pazar değerleri, girdi kriterleri için marjinal dönüşüm hızı, çıktı kriterleri için marjinal ikame hızı, analistin veya karar vericilerin kriter önemlerine dair öznel yargıları gibi bilgiler standart VZA modeline ilave edilecek ağırlık kısıtları biçiminde formüle edilmektedir.

Ağırlık kısıtlı VZA’da genel olarak nesnel bilgilere ulaşmak zor ya da olanaksız olabileceği için ve öznel yargıların kullanımı da analiz sonunda ulaşılan “etkinlik” kavramını subjektif ve tartışmaya açık hale getirdiği için bu yöntem geliştirilmeye açıktır. Bu uygulama bölümünde ağırlık kısıtlarının oluşturulmasına kılavuzluk etmesi için derin öğrenmeden yararlanılan yeni bir yöntem önerilmiştir.

Derin öğrenme, temel olarak birden çok örtük katmanı olan YSA modellerine verilen genel bir addır. Derin öğrenme yapısal olarak karmaşıklık düzeyi oldukça yüksek modellerin yer aldığı bir yöntemler ailesidir ve makine öğrenmesi yöntemlerinde model karmaşıklık düzeyi arttıkça modellerin yorumlanabilirliği düşmektedir. Bu nedenle uzun bir süre derin öğrenme modelleri bir kara kutu olarak düşünülmüş, modelden kullanılan özniteliklerin model çıktısına etkilerine dair yorumlar yapılmasının son derece zor olduğu değerlendirilmiştir ve bu nedenle eleştirilmiştir (bkz. Alain ve Bengio, 2016). Ancak; 2000’lerden itibaren yorumlanabilir makine öğrenmesi başlığı altında yapılan araştırmalar modelden bağımsız olarak özniteliklerin model çıktısına olan etkisini ve model çıktısını açıklamada görece önemlerini hesaplamak üzerinde durmuşlardır.

Bu uygulama bölümünde, bir derin öğrenme modeli ile VZA’da etkinlikleri ölçülen KVB’lerin, üretim olanakları kümesinin homojenite aksiyomunu sağladığı varsayımı ile genel bir üretim fonksiyonu modellenmiş ve ardından bu modelin özniteliklerini oluşturan VZA girdi kriterleri için iki ayrı makine öğrenmesi yorumlama algoritması ile kriterlerin görece önemlerine dair ordinal yargılar üretilmiştir. Son olarak bu yargılar ağırlık kısıtlarına dönüştürülerek KVB’lerin etkinlik ölçümü yapılmış ve standart model çıktıları ile elde edilen bulgular, ayrıştırma gücü bakımından karşılaştırılmıştır.



**Şekil 10:** Derin Öğrenme Destekli Ağırlık Kısıtlı VZA Yöntemi için Görsel Özet

Şekil 10'da bu uygulama bölümünde önerilen yöntemin ve yapılan çalışmanın görsel bir özeti sunulmuştur. Yapılan çalışma; kullanılan model ve yöntemlerin anlatımı, Bir deney üzerinden önerilen yöntemin ilk sınaması, yöntemin geçerliliğinin araştırıldığı 1000 deneyli bir simülasyon ve elde edilen sonuçların tartışıldığı son bir alt bölüm biçiminde organize edilmiştir.

#### 4.1. UYGULAMADA KULLANILAN MODELLER ve YÖNTEMLER

Tez çalışmasının bu bölümünde derin öğrenmenin VZA'da ayrıştırma gücünü artırmaya yönelik katkılarına dair iki ayrı yöntem önerilmiştir. Bu uygulama çerçevesi içerisinde önerilen yöntemlerin karşılaştırması standart VZA'ya üstünlükleri üzerinden tartışılmıştır. Dolayısıyla bu uygulama bölümünde standart VZA modeli ve standart VZA modeline ağırlıkların sınırlandırımına yönelik olarak ek kısıtlarla oluşturulan ağırlık kısıtlı VZA modelleri kullanılmıştır.

Veri Zarflama Analizi homojenite varsayımı ile KVB'lerin benzer teknolojilerle, benzer maliyetler ödeyerek aynı girdileri kullandığı ve benzer amaçlarla aynı çıktıları ürettiğini kabul eder. Pedraja ve diğerleri (1997), her ne kadar karar verme birimleri arasında homojenite varsayımını ihlal etmeyen farklı koşullara göre kriterlerin göreceli önemleri değişiklik gösterebilecek olsa da homojenite varsayımı altında sınırlandırılmamış bir ağırlık belirleme özgürlüğünün farklı karar

verme birimleri için aynı kritere çok farklı ağırlıkların atanabileceği düşünüldüğünde sorunlu olabileceğini savunmuştur. Ağırlık sınırlandırımı bu rasyonaliteye dayanmaktadır.

Charles ve diğerleri (2019) ile Thanassoulis vd. (2004), Zhu (1996); ağırlık kısıtlı Veri Zarflama Analizinde kriterlerin göreceli önem bilgisinin modele aktarılması için oluşturulan ve standart modele eklenen ağırlık kısıtlarının uzman görüşü sonucu oluşturulduğunu savunmuştur. Bu sav; çok sayıdaki karar verme birimi için genel geçer bir üretim fonksiyonunun belirlenme gücü, piyasa fiyatlarının ulaşılamazlığı ya da çok değerli olması, vb. nedenlere dayandırılmıştır. Doyle ve Green (1994) ise uzman görüşünün edinilmesinin zor veya olanaksız olabileceğinden bahsetmiştir. Benzer nedenlerle Zhu (1996) da çalışmasında ağırlık kısıtlarının elde edilmesine kılavuzluk etmesi için analitik hiyerarşi sürecini kullanmıştır. Bu tez çalışmasında, VZA kriterleri arasında nesnel önem ilişkilerinin edinimi için iki ayrı yöntem kullanılmıştır. Daha sonra da yöntemlerden edinilen önem ilişkileri ayrı iki ağırlık kısıtlı VZA modelinin formülasyonunda kullanılmıştır.

#### **4.1.1. Ağırlık Kısıtlı Veri Zarflama Analizi**

Ağırlık Kısıtlı VZA, çok çeşitli biçimlerde formüle edilebilen genel modeller ailesinin adıdır ve bu uygulama bölümünde VZA girdi kriterleri arasındaki önem çıktıları açıklayabilmek bakımından önem ilişkisi VZA ağırlıklarının sınırlandırımına kılavuzluk etmesi bakımından kullanılmıştır. Böylece kurulan ağırlık kısıtlı VZA modellerinde standart VZA modeline eklenen kısıtlar VZA girdi kriterleri arasındaki ordinal önem bilgisini yansıtacak biçimde ilgili ağırlıkların birbirleri ile karşılaştırılmasına dayanmaktadır. Diğer bir ifade ile kullanılan modellerde Tip 1 Güven Aralığı (bkz. Bölüm 1.3.3.1.) kısıtları kullanılmıştır:

**Standart VZA Modeli: Ölçeğe Göre Sabit Getiri Varsayımı Altında Çıktı Yönelimli Çarpan Model (Charnes vd., 1978):**

$$\min \quad \vec{v}^T \cdot \vec{x}_o \quad (4.1)$$

ş. k. g.

$$\vec{v}^T \cdot \vec{x}_j - \vec{\mu}^T \cdot \vec{y}_j \geq \vec{0} \quad , \quad \forall j \quad (4.2)$$

$$\vec{\mu}^T \cdot \vec{y}_o = 1 \quad (4.3)$$

$$\vec{v}, \vec{\mu} \geq \vec{0} \quad (4.4)$$

**Bir Ordinal Önem İlişkisi Örneği ve Karşılık Gelen Ağırlık Kısıtları:**

- Ordinal önem ilişkisi:

$$v_i \succcurlyeq v_{i+1} \quad (4.5)$$

(4.5)'e göre i'inci VZA girdi kriteri, en az i+1'inci VZA girdi kriteri kadar önemlidir.

- Doğrusal ağırlık kısıtı: Tip1 Güven Aralığı kısıtı örneği

$$v_i \geq v_{i+1} \quad (4.6)$$

(4.6), (4.5)'te verilen ordinal önem ilişkisinin doğrusal programlama ile uyumlu bir kısıta transferidir.

**Elde Edilen Ağırlık Kısıtlı VZA Modeli:**

$$\min \quad \vec{v}^T \cdot \vec{x}_o \quad (4.7)$$

ş. k. g.

$$\vec{v}^T \cdot \vec{x}_j - \vec{\mu}^T \cdot \vec{y}_j \geq \vec{0} \quad , \quad \forall j \quad (4.8)$$

$$\vec{\mu}^T \cdot \vec{y}_o = 1 \quad (4.9)$$

$$\vec{v}, \vec{\mu} \geq \vec{0} \quad (4.10)$$

$$v_i \geq v_{i+1} \quad (4.11)$$

(4.7) – (4.10), standart VZA modeline ait amaç fonksiyonu ve kısıtlardır. (4.11) ise (4.5) ve (4.6)'da sırasıyla önem ilişkisi tanımlanmış ve daha sonrada da bir doğrusal programlama kısıtı biçimi verilmiş halde bir ağırlık kısıtıdır. Standart modele ağırlık kısıtlarının eklenmesi ile elde edilmiş olan bu ve benzer modellere ise genel bir isim olarak ağırlık kısıtlı VZA modelleri denmektedir.

VZA kriterlerinin arasındaki uzman görüşünün yerini alacak nesnel çıkarımlar; VZA'nın üretim olanakları kümesi içinde bir örüntüyü yakalayarak girdilerin çıktılara dönüşümünü tahminleyen bir derin öğrenme modeli üzerinden Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması ve Shapley Değerleri Algoritması kullanılarak edinilmiştir.

#### **4.1.2. Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması**

Tahmin modellerinde özniteliklerin görelî önemlerinin tanımlanması için en çok kullanılan yöntemlerden biri Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritmasıdır (*Input Perturbation Feature Ranking*). Bu yöntemle buradan sonra kısaca PÖS denilmiştir. PÖS, veri kümesinde betimsel istatistikleri değiştirmeksizin özniteliklerin tahmin gücünü yok ederek model performansı kayıplarından yola çıkarak özniteliklerin görelî önemlerini hesaplayan bir yöntemdir.



PÖS'te her bir öznitelik için ilgili öznitelik vektörünün, vektör bileşenlerinin bir permütasyonu biçimindeki vektörle değiştirildiği ve diğer öznitelik verisinin sabit tutulduğu öznitelik sayısınınca veri kümesi hazırlanır. Bu veri kümelerinde model performansları (yitim fonksiyonu, hata kareleri toplamı, açıklanabilir varyans skoru, vb.) kaydedilir ve doğru veri kümesinin model performansı ile karşılaştırılır. Referans performansa göre en kötü performans gösteren veri kümesi için ilgili öznitelik en önemli; en az kötü performans gösteren veri kümesi içinse ilgili öznitelik en az önemli olacak biçimde tüm özniteliklerin önem dereceleri sıralanır (Heaton, 2018; Heaton ve diğerleri, 2017 ).

Özellikle az sayıda gözlem içeren veri kümelerine PÖS uygulandığında; pertürbe edilmiş öznitelik vektörlerinin olasılık uzayında doğru öznitelik vektörleri ve doğru öznitelik vektörlerine çok benzer vektörler de yer aldığı için öznitelikler çok iyi bozunuma uğramış ya da özniteliklerin görece model çıktısına etkisi korunmuş olabilmektedir. Bu tez çalışmasında özniteliklerin denk bozunumlara tabi tutulduğunu garanti altına almak için rassal bozunum yerine tasarlanmış yeniden dağıtım uygulanmıştır.

#### **4.1.3. Shapley Değerleri ile Öznitelik Sıralama**

Öznitelik önemi için önemli kavramlardan biri olan Shapley Değerleri (Shapley, 1953), her bir özneliğin model sonucuna katkısını yansıtmaktadır. Shapley değeri bir işbirlikçi oyun kuramı kavramıdır. Kavram ilk defa Lloyd Shapley tarafından 1951'de ortaya atılmış ve bu fikrine 2012'de Nobel iktisat ödülü verilmiştir.

Shapley değerleri, her bir oyunda üretilen kazancı oyunculara belli biçimde dağıtır. Çok sayıda oyuncunun işbirliği sonucu oyun sonunda elde edilen kazanımdan kazanıma katkılarına göre her bir oyuncu ne kadar pay istemelidir sorusuna Shapley değerleri olası bir adil yanıt sunmaktadır (Crowe, 2022).

Model agnostik (model tipinden bağımsız) yapısı sayesinde makine öğrenmesi modellerinin yorumlanabilirliği için uyarlanan Shapley değerleri, her bir özneliğin model sonucuna (tahmine) olan katkısını tanımlamakta kullanılmaktadır (Lundberg ve Lee, 2017; Pyrcz, 2021a; 2021b). Burada oyuncular, veri kümesinde tanımlı özneliklere; kazanım, modelin tahminlediği sınıf veya değere ve oyun ise modele denk gelmektedir. Bir referans model çıktısına (ortalama tahmin değeri vb.) göre ilgili özneliği girdi olarak kullanmayan bir modelin farklı senaryolarda (diğer özneliklerin katılım yapısına göre) ne kadar çok ya da ne kadar az kazanım elde edildiği bir Shapley değerleri vektörü olarak her bir öznelik için kaydedilir. Daha sonra bu Shapley değerleri vektörleri için mutlak değerler ortalamaları hesaplanarak her bir özneliğin model çıktısına göreli katkısı belirlenir (Pyrcz, 2021a; 2021b).

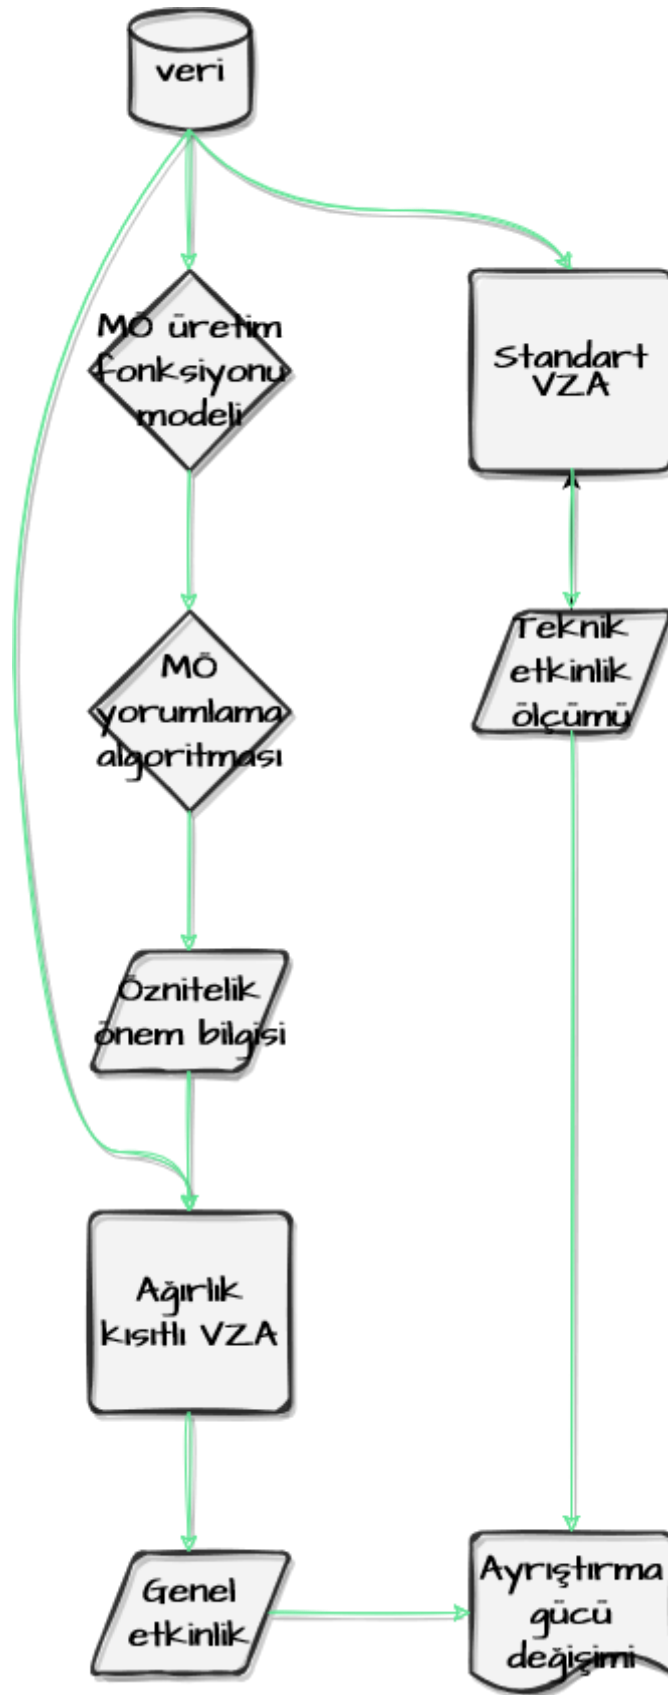
Uzman görüşü yerine Shapley değerleri temelli olarak VZA kriterlerinin görelî önemleri ordinal bir bilgi olarak ağırlık kısıtları olarak standart VZA modeline eklenir.

Shapley değerleri ile desteklenmiş ağırlık kısıtlı Veri Zarflama Analizi, girdilerin çıktılara dönüşümüne dair genel bir belirsiz üretim fonksiyonunda girdi kriterlerinin görelî önemleri bilgisine dayalı olarak VZA'da ağırlık belirleme serbestisini sınırlandırır ve böylece VZA'da ayrıştırma gücünü artırır.

#### **4.2. ÖZNEİİK ÖNEM BİLGİSİ ile AĞIRLIK KISITLI VERİ ZARFLAMA ANALİZİ ÜZERİNE BİR DENEY**

Bu uygulama alt bölümü, VZA'da ayrıştırma gücünü iyileştirme yöntemlerinden olan ağırlık kısıtlı VZA'da ağırlık kısıtlarının formülasyonu için nesnel veri üreten derin öğrenme ve makine öğrenmesi yorumlama algoritması tabanlı yeni iki yöntemin tanıtımı ve pilot uygulaması üzerinedir.

Pilot uygulama, VZA etkin birim sayısının çok sayıda olduđu tek bir veri kümesinde öncelikle bir genel üretim fonksiyonunun modellenmesi ve ardından da sırasıyla PÖS ve SDA algoritmalarıyla (makine öğrenmesi yorumlama algoritmalarıyla) elde edilen öznitelik önem bilgileri ışığında VZA kriterleri arasında önem ilişkisine dayalı ağırlık kısıtlarının formülasyonu ile bir ağırlık kısıtlı VZA modelinin elde edilmesi biçimindedir. Pilot uygulamada elde edilen model, standart VZA modeli ile performans bakımından karşılaştırılarak önerilen yöntemlerin ayrıştırma gücünü iyileştirme potansiyeli araştırılmaktadır. Şekil 11’de pilot uygulamanın görsel özeti sunulmuştur.



Şekil 11: Tek Veri Kümesi ile Deney Görsel Özeti

#### 4.2.1. Araştırma Tasarımı

Ağırlık kısıtlı VZA'da kriterler ağırlıklarına yönelik eklenen kısıtlara genel olarak üç kaynak kılavuzluk etmektedir:

- Uzman görüşü ya da karar vericilerin sezgileri,
- Girdilerin ya da çıktılarının pazar fiyatları,
- Üretim fonksiyonundan elde edilen marjinal değişim hızları ya da marjinal dönüşüm hızları.

Tez çalışmasının bu bölümünde bu üç kaynağın yerine makine öğrenmesi temelli bir yöntem önerilmektedir. Bu yöntem üç fazlıdır. İlk fazda VZA girdi kriterleri ile çıktı kriterinin tahminlendiği ve yüksek başarımla elde edilen bir model kurulur. İkinci fazda modelden bağımsız bir öznitelik önem sıralama algoritması kullanılarak üretim fonksiyonunu taklit eden modelden VZA kriterlerinin göreceli önem bilgilerine dair bir çıkarımda bulunulur. Ve son fazda da önceki aşamalarda edinilen VZA kriterlerine dair önem ilişkileri ağırlık kısıtlarına dönüştürülerek ve standart VZA modeline eklenerek bir ağırlık kısıtlı VZA modeli elde edilir.

Elde edilen ağırlık kısıtlı VZA modeli VZA girdi kriterleri arasındaki genel bir önem ilişkisine dayanan tek tip yapıdadır. Ve bu model tüm KVB'lere uygulanmıştır. Bu alt araştırma VZA'da ayrıştırma gücünü artırmak üzere makine öğrenmesi temelli bir deneyden yola çıkarak öznitelik önem bilgilerinin VZA'da ağırlık kısıtlarının formülasyonuna kılavuzluk edip edemeyeceği üzerinedir.

Bu alt araştırmanın anlatımı sırasıyla verinin tanıtımı, genel bir üretim fonksiyonunun modellenmesi, iki ayrı makine öğrenmesi yorumlama algoritmasının işletimi ve ulaşılan ağırlık kısıtlı VZA modellerinin sunumu biçiminde organize edilmiştir.

#### 4.2.2. Veri Kümesi

Uygulama zemini olarak türetilen veri kümesi (seed=1000, bkz. Bölüm 4.3), 4 girdili 1 çıktılı 30 gözlem (KVB) içermektedir. Veride homojenlik ve tutarlılığı sağlamak adına [1,100] aralığında rassal girdi değerleri ölçeğe göre sabit getiri varsayımını sağlayan ve girdi üsleri yaklaşık [0.21, 0.31] aralığında 0,02 standart sapma olacak biçimde ve toplamları bir olacak biçimde rassal türetilen Cobb-Douglas tipi üretim fonksiyonlarına sunulacak çıktı değerleri elde edilmiştir.

Üretim fonksiyonlarında girdi üslerinin dar aralıklı tutulmasının nedeni VZA'da üretim olanakları kümesinin homojenite aksiyomunu, KVB'ler arasında benzer üretim fonksiyonları ile üretim yapılması yolu ile sağlamaktır.

Tablo 2 veri kümesine ait 30 KVB için CD üretim fonksiyonlarında kullanılan üs değerlerini göstermektedir:

**Tablo 2:** Veri Kümesine Ait CD Üretim Fonksiyonu için Girdi Üs Değerleri Verisi

KVB	ü1	ü2	ü3	ü4
1	0.26632	0.24413	0.23058	0.25897
2	0.24912	0.25329	0.24004	0.25755
3	0.24830	0.24252	0.25151	0.25767
4	0.28309	0.24699	0.23677	0.23315
5	0.22242	0.24697	0.27148	0.25914
6	0.24516	0.23434	0.24848	0.27202
7	0.23321	0.28681	0.24366	0.23632
8	0.25793	0.29236	0.22455	0.22516
9	0.23570	0.22326	0.23471	0.30633
10	0.21942	0.24117	0.28592	0.25349
11	0.23977	0.22429	0.30563	0.23031
12	0.27678	0.23506	0.24618	0.24198
13	0.23964	0.22517	0.29704	0.23815
14	0.28883	0.23755	0.25585	0.21776
15	0.23613	0.27092	0.24819	0.24476
16	0.28357	0.25607	0.20598	0.25437
17	0.24789	0.23808	0.26442	0.24961
18	0.25034	0.25374	0.22139	0.27453

<b>19</b>	0.22829	0.27743	0.23964	0.25464
<b>20</b>	0.25106	0.29403	0.21909	0.23583
<b>21</b>	0.26915	0.27379	0.24097	0.21609
<b>22</b>	0.25006	0.27733	0.23992	0.23269
<b>23</b>	0.22136	0.22927	0.24228	0.30709
<b>24</b>	0.30419	0.24428	0.22113	0.23040
<b>25</b>	0.27195	0.21698	0.22477	0.28631
<b>26</b>	0.21750	0.22519	0.28040	0.27691
<b>27</b>	0.24553	0.26364	0.25995	0.23088
<b>28</b>	0.24992	0.27525	0.24323	0.23160
<b>29</b>	0.24996	0.24414	0.22154	0.28436
<b>30</b>	0.30612	0.22287	0.24392	0.22710

Tablo 2'ye göre KVB9'a ait CD üretim fonksiyonu şöyledir:

$$y = 1x_1^{0,23570}x_2^{0,22326}x_3^{0,23471}x_4^{0,30633} \quad (4.12)$$

(4.12)'de ve diğer tüm CD üretim fonksiyonlarında sabit terim hesaplamada sadeliği sağlamak adına 1 değerlidir ve üsler toplamı da ölçeğe göre sabit getiri varsayımını sağlamak adına 1 değerlidir.

Cobb-Douglas tipi (CD) üretim fonksiyonu kullanılmasının gerekçesi ise CD üretim fonksiyonunda üsler toplamı 1 olduğunda standart VZA modeline uygun biçimde ölçeğe göre sabit getiri varsayımının sağlanabilmesi ve bu üretim fonksiyonu tipinin gerçek hayata uygun ve oldukça yaygın olarak kullanılmasıdır (bkz. Banker ve diğerleri, 1993; Charnes ve diğerleri, 1985; Galagedera ve Silvapulle, 2003).

Türetilen 4 girdiye ait veri, bu girdilerle beraber Tablo 2'de sunulmuş olan üsler kullanılarak formüle edilen CD üretim fonksiyonlarıyla elde edilen çıktı verisi ve bu verinin VZA'ya sunumu sonucunda elde edilen etkinlik skorları Tablo 3'te özetlenmiştir.

**Tablo 3:** VZA Kriterleri ve Etkinlik Skorları

<b>KVB</b>	<b>Girdi1</b>	<b>Girdi2</b>	<b>Girdi3</b>	<b>Girdi4</b>	<b>Çıktı1</b>	<b><math>\theta</math></b>
1	90.30620	4.06647	33.09274	29.37268	25.12723	1
2	95.75647	2.63677	46.27504	33.16864	24.63852	1
3	69.94988	69.58223	68.58196	89.32092	74.03390	1
4	94.61222	9.09895	12.57203	4.65003	16.29860	1
5	92.45523	98.20818	38.28590	7.28412	38.23745	1
6	13.65779	88.10900	45.95077	20.74962	32.02194	1
7	62.97716	77.86651	46.99027	4.99631	34.24107	1
8	38.01621	86.82493	11.21735	12.13860	28.45542	1
9	78.23327	14.36983	13.72729	24.80981	25.05552	1
10	29.88927	33.99041	79.42424	25.19035	39.03999	1
11	11.43310	12.59099	36.57576	24.16009	19.80381	1
12	82.98489	61.46798	29.70908	99.74641	62.78700	1
13	42.50493	89.57755	29.53637	32.03105	42.18145	1
14	98.07558	9.82455	88.13869	96.04044	54.99619	1
15	34.74090	91.63801	89.96522	99.93738	74.10357	1
16	12.65086	59.91579	78.80677	72.84789	42.86659	1
17	83.12836	2.92541	94.73485	17.17395	26.16609	1
18	3.71581	97.92332	19.30178	83.61117	28.85432	1
19	2.21525	4.33295	8.13236	64.05763	8.58362	1
20	25.33057	43.18521	96.37315	21.31408	38.12636	1
21	24.30916	49.18819	28.59642	52.64077	36.23126	1
22	45.65500	34.22838	2.17699	76.04409	22.86995	1
23	89.10455	36.83971	47.21504	7.00510	28.57295	1
24	74.14379	24.16752	13.96119	14.87148	26.91782	1
25	20.85629	73.25303	43.76394	70.15479	45.79289	1
26	15.01390	23.16981	82.45993	1.37740	13.77441	1
27	23.41624	83.91850	68.29145	28.12035	45.17073	1
28	82.32029	17.88298	54.68545	60.31206	45.55167	1
29	97.40184	67.70580	35.19508	51.34925	59.29317	1
30	25.50310	98.77163	41.48456	9.52554	31.04959	1

Tablo 3'te 4 girdi, 1 çıktı ve 30 KVB içeren veri kümesi gösterilmektedir. Farklı KVB'ler künye numaraları ilk sütunda sunularak satırlarda temsil edilirken VZA girdi kriterleri verisi sırasıyla G1, G2, G3, G4 sütunlarında; VZA çıktı kriteri verisi Ç1 sütununda ve VZA etkinlik skoru da  $\theta$  sütununda sunulmuştur. Örneğin KVB2 için girdi kriterleri yaklaşık olarak sırasıyla 95,75647; 2,63677; 46,27504; 33,16864 değerlerini alırken çıktı kriteri değer yaklaşık olarak 24,63852'dir ve VZA etkinlik skoru 1 olarak hesaplanmıştır.



### 4.2.3. Derin Öğrenme ile Genel Üretim Fonksiyonun Modellenmesi

Parametrik olmayan bir yöntem olan VZA, temel olarak belirli ve sabit bir üretim fonksiyonu ile girdilerin çıktılara dönüşümünü varsaymamaktadır ancak; üretim olanakları kümesinin homojenite aksiyomu gereği KVB'lerin benzer teknolojilerle, benzer maliyetler ödeyerek aynı girdileri kullandığı ve benzer amaçlarla aynı çıktıları ürettiği bir yapı öngörülmektedir (Pedraja vd., 1997). Buradan yola çıkarak VZA girdi kriterlerini öznelilikler olarak alan, VZA çıktı değerini tahminleyen bir üretimi tahminleme fonksiyonunu modellemek düşünülmüştür. Bir üretim fonksiyonunun yerini alarak ve girdilerin çıktılara dönüşüm ilişkileri bilgisini edinmek için dört nöronlu girdi katmanı; 16, 16, 8 ve 8 nöron içeren dört örtük katmanı ve VZA etkinlik skor tahmini için tek nöronlu çıktı katmanı olan bir derin yapay sinir ağı modeli tasarlanmıştır. Ayrıca hiçbir nöron için sapma (bias) kullanılmamıştır. Temel olarak sapmalar nöron girdisinin 0 değerli olması durumunda aktivasyonun tüm ağırlık değerleri için 0 değerli olacağından yola çıkarak aktivasyon üzerinde bir diğer parametre ile kontrol olanağı sağlamak için kullanılmaktadır ancak; uygulamada kullanılan VZA verisinin tümü pozitif değerlidir.

Dört örtük katman kullanımı ve örtük katmanlardaki nöron sayısı tercihlerinin yanı sıra aktivasyon fonksiyonları ve optimizasyon algoritması üzerinden de hiperparametreler optimize edilmiştir.

Bu modelde tüm nöronlar için aktivasyon fonksiyonları, kaybolan eğim sorunsalına (*Vanishing Gradient Problem*; Hochreiter, 1998) düşmemesi ve kolay öğrenme sağlaması nedeniyle ReLU olarak seçilmiştir. Yitim fonksiyonu hata kareleri ortalaması (HKO) olarak seçilmiştir. Model, Adam optimizasyon algoritması (Kingma ve Ba, 2014) kullanılarak ve öğrenme hızı  $5 \cdot 10^{-5}$  olarak ayarlanarak optimize edilmiştir. Öntanımlı adım büyüklüğü olan  $10^{-3}$ 'ten başlayarak çeşitli değerlerle yapılan deneyler sonucu seçilen değer avantajlı yerel minimumları atlamayacak kadar küçük ve modelin optimizasyon süresini makul sınırların ötesine çıkarmayacak kadar büyük olarak değerlendirilmiştir.

Adam algoritması adaptif momentum sayesinde sıg yerel minimalarda takılmadan aramaya devam edebilmesi ve alternatif optimizasyon algoritmalarına göre yerel minimalara daha hızlı yakınsaması nedeniyle tercih edilmiştir.

Aşırı öğrenmeyi engellemek için de veri kümelerinin %20'si doğrulama kümesi olarak ayrılıp 50 adım boyunca doğrulama kümesinin yitim fonksiyonu değerinde iyileşme olmadığında optimizasyon sürecinin durdurulmasına yönelik tensorflow keras api'sinde EarlyStopping (Prechelt, 1998) çağrısı (ES) kullanılmıştır ve adımlar arasında doğrulama kümesi yitim fonksiyonu için en düşük değerli olan model, en iyi model olarak kaydedilmiştir.

KVB'ler arasında homojenitenin ne derece sağlandığına bağlı olarak makine öğrenmesi modellerinin çıktı değerlerini tahminde başarımlı değişkenlik gösterecektir. Homojenitenin sağlanmadığı bir veri kümesi için çıktı kriteri değerleri neredeyse rassal olarak algılanacağı için tahmin başarımlı ciddi biçimde düşecektir. Aynı mimari ile ancak; rassal çıktı kriteri değerleri için yapılan bir deneyde model verideki değişkenliğin yalnızca yaklaşık %57'sini açıklayabilmiştir.

Veri kümesi için analizde kullanılan model, çıktı verisindeki değişkenliğin yaklaşık %100'ünü ( $R^2 = 0.9999999$ ) açıklayabilmektedir. Veri kümesindeki her bir KVB'ye ait cobb-douglas üretim fonksiyonunu gösteren çıktı değerleri (etiket değerleri) ile modelin tahminlediği çıktı değerleri ve aralarındaki fark değerleri Tablo 4'te gösterilmektedir.

**Tablo 4:** Çıktı ve Tahminlenen Çıktı Değerleri Karşılaştırması

KVB	Çıktı Değeri	Tahmin Değeri	Fark
1	25.12723	25.10576	0.02147
2	24.63852	24.63589	0.00263
3	74.03390	74.01423	0.01967
4	16.29860	16.28979	0.00881
5	38.23745	38.22174	0.01571
6	32.02194	32.00541	0.01654

7	34.24107	34.22396	0.01711
8	28.45542	28.44393	0.01149
9	25.05552	25.08871	-0.03319
10	39.03999	36.54230	2.49769
11	19.80381	19.79708	0.00673
12	62.78700	62.76734	0.01966
13	42.18145	42.16911	0.01234
14	54.99619	54.97297	0.02322
15	74.10357	74.08105	0.02252
16	42.86659	51.92142	-9.05484
17	26.16609	26.15070	0.01539
18	28.85432	34.89594	-6.04162
19	8.58362	8.57446	0.00915
20	38.12636	38.11132	0.01504
21	36.23126	36.21333	0.01794
22	22.86995	22.85305	0.01690
23	28.57295	28.55867	0.01428
24	26.91782	23.81738	3.10043
25	45.79289	45.77657	0.01632
26	13.77441	13.76245	0.01196
27	45.17073	45.15613	0.01460
28	45.55167	44.39764	1.15404
29	59.29317	59.27665	0.01652
30	31.04959	31.03525	0.01434

Ek olarak; model başarımını gösteren performans metrik değerleri Tablo 5'te sunulmuştur.

**Tablo 5:** Model Başarım Performansı Metrikleri

Performans Metrikleri		
R <sup>2</sup>	$\sqrt{HKO}$	HKO
1 – 10 <sup>-7</sup>	1.5 x 10 <sup>-2</sup>	2.4 x 10 <sup>-4</sup>

Tablo 5'ten de görüldüğü üzere R<sup>2</sup> yaklaşık 1 değerlidir. Diğer bir ifadeyle model çıktı verisindeki değişkenliğin neredeyse %100'ünü açıklayabilmektedir. Son derece düşük değerli olan hata kareleri ortalaması (HKO) ve bu değer karekökü de model başarımının yüksek olduğunu aynı şekilde vurgulamaktadır.

#### **4.2.4. Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması Kullanılarak VZA Girdi Kriterleri Arasındaki Önem Bilgisinin Edinilmesi**

Bölüm 4.1.2'de PÖS'ün özellikle az gözlem içeren veri kümelerinde denk bozunumlar üretemeyebileceğine değinilmiştir. Bunun nedeni rassal yeniden dağıtımın olasılık uzayında orijinal girdi vektörüne çok benzer ya da yüksek düzeyde bozunuma uğramış girdi vektörlerinin bulunmasıdır. Rassal yeniden dağıtım deneyinde hangi özneliğin ne düzeyde bozunuma uğradığı ve bu bozunumların denk olup olmadığı temel olarak bilinmemektedir.

Heaton'a (2018) göre iyi bir PÖS uygulaması için iki koşulun sağlanması gereklidir. İlk olarak bozunuma uğramış girdi vektörleri model başarımına mümkünse hiç ya da en azından düşük düzeyde katkı sağlamalıdır. Ve ikinci olarak PÖS'ün bozunuma uğramış vektörün model başarımına etkisini aşacak olumsuz etkilerinin olmaması temin edilmelidir. Rassal yeniden dağıtım özneliklerin ve tüm veri kümesinin betimsel istatistik değerlerini koruyarak ve yalnızca girdi değerlerini farklı gözlemlerle eşleştirerek ikinci gereksinimi sağlamaktadır. Ancak; rassallığın özneliğin taşıdığı model başarımı bakımından taşıdığı bilgiyi ne düzeyde yok ettiği belirsizdir.

Bu tez çalışmasında öznelikler için denk bozunumun temin edilmesi için özgün bir yaklaşım olarak optimizasyon temelli yeniden dağıtım ile PÖS önerilmiştir. Rassal yeniden dağıtım gibi bu yöntemde de girdi değerleri farklı gözlemlerle eşleştirilmekte ve böylece yine veri kümesinin içerdiği değerler ve betimsel istatistikler korunmaktadır. Ancak; önerilen yöntemde yeniden dağıtım, rassal olarak değil gözlemler için orijinal girdi değeri ile yeniden atanan değer arasındaki mutlak farklar toplamı maksimize edilerek yapılmaktadır:

$$\text{maks} \sum_i \left| x_i - \sum_j x_j \alpha_{ij} \right| \quad (4.13)$$

ş. k. g.

$$\sum_i \alpha_{ij} = 1, \quad \forall j \quad (4.14)$$

$$\sum_j \alpha_{ij} = 1, \quad \forall i \quad (4.15)$$

$$\alpha_{ij} \in \{0,1\}, \quad \forall i, \forall j \quad (4.16)$$

(4.13) – (4.16)'da sunulan modelde  $x_i$  ilgili veri kümesinde ilgili öznitelik vektörünün  $i$ . gözlemdeki değerini temsil eden parametre,  $\alpha_{ij}$  ise  $x_i$  yerine  $x_j$  değerinin atanıp atanmayacağını belirten ikili tam sayılı değişkendir. Model ilgili öznitelik için yeniden atanmış değerler ile orijinal değerler arasındaki L1 uzaklığını (*Manhattan distance*) maksimize ederek iyi bir bozunumu sağlamakta ve tüm öznitelikler için tekrarlandığında da yeniden dağıtımları sabit bir kurala göre yaptığı için denk bozunumları temin etmektedir. Böylece PÖS küçük hacimli veri kümelerinde makine öğrenme algoritmaları için güçlendirilmiş ve daha tutarlı hale getirilmiştir.

Tablo 6'da optimizasyon temelli PÖS algoritmasının bulguları gösterilmektedir.

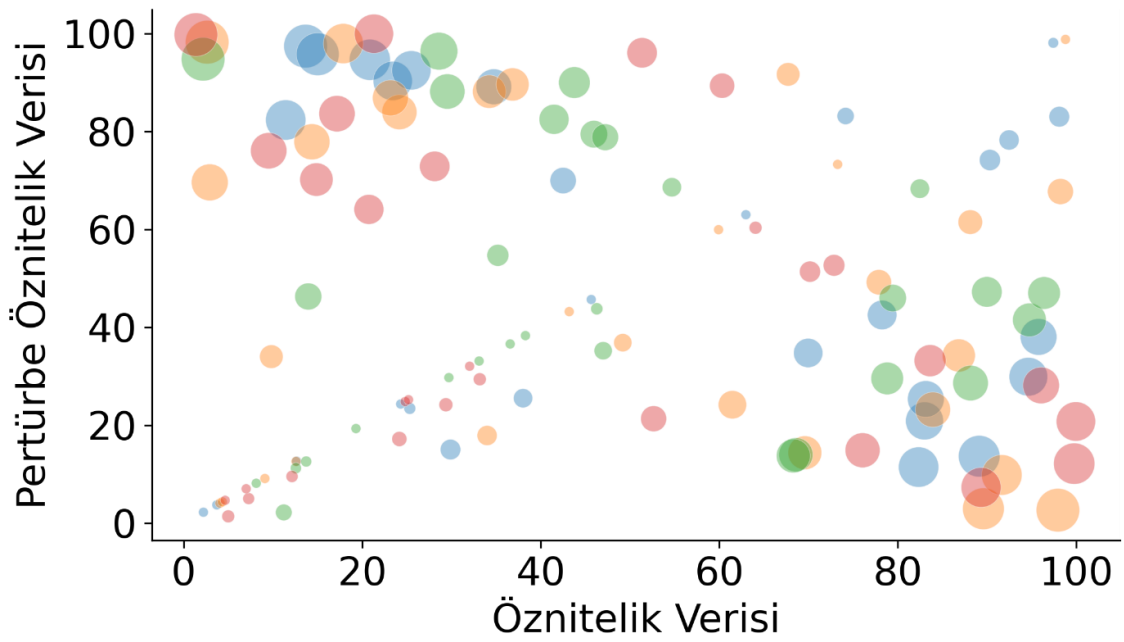
**Tablo 6:** Pertürbe Edilmiş Öznitelik (VZA Girdi Kriteri) Verisi

KVB	G1	G2	G3	G4	PG1	PG2	PG3	PG4
1	90.30620	4.06647	33.09274	29.37268	74.14379	4.06647	33.09274	24.16009
2	95.75647	2.63677	46.27504	33.16864	38.01621	98.20818	43.76394	29.37268
3	69.94988	69.58223	68.58196	89.32092	34.74090	14.36983	13.96119	7.28412
4	94.61222	9.09895	12.57203	4.65003	29.88927	9.09895	11.21735	4.65003
5	92.45523	98.20818	38.28590	7.28412	78.23327	67.70580	38.28590	4.99631
6	13.65779	88.10900	45.95077	20.74962	97.40184	61.46798	79.42424	64.05763
7	62.97716	77.86651	46.99027	4.99631	62.97716	49.18819	35.19508	1.37740
8	38.01621	86.82493	11.21735	12.13860	25.50310	34.22838	2.17699	9.52554
9	78.23327	14.36983	13.72729	24.80981	42.50493	77.86651	12.57203	24.80981
10	29.88927	33.99041	79.42424	25.19035	15.01390	17.88298	45.95077	25.19035
11	11.43310	12.59099	36.57576	24.16009	82.32029	12.59099	36.57576	17.17395
12	82.98489	61.46798	29.70908	99.74641	20.85629	24.16752	29.70908	12.13860
13	42.50493	89.57755	29.53637	32.03105	69.94988	2.92541	88.13869	32.03105
14	98.07558	9.82455	88.13869	96.04044	82.98489	33.99041	28.59642	28.12035

15	34.74090	91.63801	89.96522	99.93738	89.10455	9.82455	47.21504	20.74962
16	12.65086	59.91579	78.80677	72.84789	12.65086	59.91579	29.53637	52.64077
17	83.12836	2.92541	94.73485	17.17395	25.33057	69.58223	41.48456	83.61117
18	3.71581	97.92332	19.30178	83.61117	3.71581	2.63677	19.30178	33.16864
19	2.21525	4.33295	8.13236	64.05763	2.21525	4.33295	8.13236	60.31206
20	25.33057	43.18521	96.37315	21.31408	23.41624	43.18521	46.99027	99.93738
21	24.30916	49.18819	28.59642	52.64077	24.30916	36.83971	96.37315	21.31408
22	45.65500	34.22838	2.17699	76.04409	45.65500	88.10900	94.73485	14.87148
23	89.10455	36.83971	47.21504	7.00510	13.65779	89.57755	78.80677	7.00510
24	74.14379	24.16752	13.96119	14.87148	83.12836	83.91850	46.27504	70.15479
25	20.85629	73.25303	43.76394	70.15479	94.61222	73.25303	89.96522	51.34925
26	15.01390	23.16981	82.45993	1.37740	95.75647	86.82493	68.29145	99.74641
27	23.41624	83.91850	68.29145	28.12035	90.30620	23.16981	13.72729	72.84789
28	82.32029	17.88298	54.68545	60.31206	11.43310	97.92332	68.58196	89.32092
29	97.40184	67.70580	35.19508	51.34925	98.07558	91.63801	54.68545	96.04044
30	25.50310	98.77163	41.48456	9.52554	92.45523	98.77163	82.45993	76.04409

Tablo 6'da ilk dört sütun orijinal öznitelik verisi iken son dört sütun sırasıyla bozunuma tabi tutulmuş (pertürbe edilmiş) öznitelik verilerini göstermektedir. Satırlar ise künye numaraları başlığı ile verinin kaçınıcı gözleme ait olduğunu tanımlamaktadır. Örneğin KVB24 için girdi verisi yaklaşık 74, 24, 14 ve 15' den 83, 84, 46 ve 70'e dönüştülürken KVB19 için yalnızca dördüncü girdinin verisi değiştirilmiş ancak; diğer tüm veri korunmuştur.

Değişime uğramamış verinin bulunmasının nedeni bireysel bozunumdan ziyade topyekün bir bilgi kaybının hedeflenmesidir.



**Şekil 12:** Pertürbe Veri İle Orijinal Veri İçin Korelasyon Grafiği

Şekil 12, uzaklığa göre boyutları tanımlanmış ve her bir öznitelik için ayrı renk kodları verilmiş biçimde orijinal veri ile bozunuma uğramış (pertürbe) veriyi karşılaştırmaktadır. Grafikte mavi renk birinci öznitelik verisini, sarı renk ikinci öznitelik verisini, yeşil renk üçüncü öznitelik verisini ve kırmızı renk de dördüncü öznitelik verisini ayırt etmede tanımlanmış renk kodlarıdır. Şekil 12'den de açıkça görüleceği üzere bazı veriler korunmuş olmakla beraber genel olarak yeniden dağıtılmış veri ciddi biçimde  $x=y$  doğrusundan saptırılmış ve orijinal veri ile korelasyonu düşürülmüştür.

**Tablo 7:** Pertürbe Veri Kümeleri için Model Performans Metrikleri

Performans Metrikleri	Orijinal Veri	PG1	PG2	PG3	PG4
$R^2$	0.9999999	0.68697	0.31312	0.52783	0.16162
$\sqrt{HKO}$	0.0157681	9.87216	14.45510	12.01549	15.97000

Tablo 7, pertürbe veri kümeleri için model performans metriklerini göstermektedir. Burada, veri orijinal haldeyken  $R^2$  ve  $\sqrt{HKO}$  değerleri ile verinin bozunmuş hali ile yapılan analizin  $R^2$  ve  $\sqrt{HKO}$  değerlerinin karşılaştırılmış hali görülmektedir.

PG1'e ait  $R^2$  ve  $\sqrt{HKO}$ , birinci girdi verisinin pertürbe hali ile diğer girdilere ait verinin orijinal hali ile elde edilen analize ait performans metriklerinin değerlerini göstermektedir. Örneğin, bu veri kümesi için 0.0157681 olan performans kriteri bozunuma tabi tutulmuş veri kümeleri için sırasıyla 9.87216, 14.45510, 12.01549, 15.97000 olarak hesaplanmıştır ve dolayısıyla öznitelikler en önemliden en önemsiz  $\bar{x}^4 \succ \bar{x}^2 \succ \bar{x}^3 \succ \bar{x}^1$  biçiminde sıralanmıştır.

Şekil 12 ve Tablo 7, önerilen optimizasyon temelli PÖS algoritmasının özniteliklerin model başarımı bakımından taşıdığı bilgiyi son derece etkili biçimde yok edebildiğini sırasıyla sezgisel ve istatistiksel olarak ortaya koymuştur. Şekil 12'de öznitelik verisinin  $x=y$  doğrusu etrafından etkili bir biçimde uzaklaştırılmış olması, Tablo 7'de yaklaşık 0 olan HKO değerinin bozunuma uğramış veri kümeleri için son derece yüksek değerler almış olması görsel ve sayısal olarak önerilen optimizasyona dayalı yeniden dağıtım algoritmasının gücünü kanıtlar niteliktedir.

#### **4.2.5. Shapley Değerleri Algoritması Kullanılarak VZA Girdi Kriterleri Arasındaki Önem Bilgisinin Edinilmesi**

Bölüm 4.1.3.'te Shapley Değerleri Algoritması (SDA) ile öznitelik sıralama kavramı basitçe tanıtılmıştır. Derin öğrenmeye uyarlanmış SDA ayrıntılı olarak bu alt bölümde sunulacak ve tez çalışması içerisindeki uygulaması aktarılacaktır.

SDA, bir referans değer olarak "*naive*" değerden başlayarak ilgili öznitelik hariç tüm özniteliklerin bilgisinin belirli bir sıra ile modele sunulması ile her bir özniteliğin tahminlenen değere toplamsal etkileri izlenir ve son olarak ilgili özniteliğin toplamsal etkisi bir Shapley Değeri olarak kaydedilir. Ancak; ilgili özniteliklerin eklenme sırası, ilgili özniteliğin toplamsal etkisini etkileyebilecektir. Bunun en temel nedeni özniteliklerin arasındaki korelasyondur. Diğer bir ifade ile özniteliklerin taşıdığı ortak bilgi önce hangi özniteliğin modele sunulduğuna göre daha büyük toplamsal katkı olarak bu öznitelikle ilişkilendirilecek ve sonradan katılan korele özniteliğin katkısı daha az görünecektir. Sonuç olarak modele



katkısı araştırılan ilgili öznitelikten önce diğer özniteliklerin hangi dizilimde (permütasyon) ve kaçınıcı sırada modele sunulduğuna göre farklı Shapley değerleri hesaplanacaktır. Son aşamada belli bir özniteliğe ait tüm Shapley değerleri bilgisi birleştirilerek genel bir öznitelik önem bilgisi süzülecektir.

Bir özniteliğin katkısına dair bulunan Shapley değerleri “0” etrafında dağılacaktır. Negatif ya da pozitif değerler temel olarak uzaklık olarak değerlendirilmeli ve özniteliğin modele olan katkısı bu uzaklıkların bir fonksiyonu olarak tanımlanmalıdır (Lundberg ve Lee, 2017; Pyrcz, 2021a; 2021b). Tez çalışmasındaki uygulamada L1 uzaklığı (mutlak değerler) seçilmiştir ve özniteliklerin modele katkıları mutlak Shapley değerlerinin ortalaması üzerinden tanımlanmıştır.

SDA’da naive değer, bağımlı değişkene dair bağımsız değişkenlerin bilgisi olmaksızın bir temel tahmindir. Naive değer olarak bağımlı değişkenin ortalaması ( $\bar{y} = E(\vec{y})$ ) ya da medyanı gibi değerler kullanılabilir. Tez çalışmasındaki uygulamada naive değer olarak  $E(\vec{y})$  seçilmiştir. Benzer bir mantıkla modelden bir özniteliğin bilgisinin çıkarılması için çıkarılan j. öznitelik vektörü  $E(\vec{x}^j)$  ile değiştirilir. Böylece her gözlemden sabit değerli bir öznitelik modele sunulmuş olur ve sabit değer tahminlenen değere bir katkı sunamayacağı açıktır.

Shapley değerlerinin hesaplanması bir bağımlı değişken için bir naive değer belirlenmesiyle başlar:

$$E(\vec{y}_i) = \bar{y} , \forall i \quad (4.17)$$

(4.17)’de tüm gözlemler için naive tahmin değerinin çıktı kriteri değerlerinin ortalaması olduğu belirtilmiştir. Naive değerden başlayarak tahmin değerine marjinal katkı hesaplanırken ilgili öznitelik bilgisinin kaçınıcı sırada modele sunulduğu, ilgili öznitelikten önce hangi özniteliklerin ne sıra ile modele sunulduğu bulunan marjinal katkı değerlerini ciddi biçimde değiştirebilmektedir.

$$f(\vec{x}_i^4) = f(E(\vec{x}_i^1), E(\vec{x}_i^2), E(\vec{x}_i^3), \vec{x}_i^4) \quad (4.18)$$

$$\Delta\hat{y}_{i,1} = f(\vec{x}_i^4) - \bar{y} \quad (4.19)$$

$$f(\vec{x}_i^1, \vec{x}_i^4) = f(\vec{x}_i^1, E(\vec{x}_i^2), E(\vec{x}_i^3), \vec{x}_i^4) \quad (4.20)$$

$$\Delta\hat{y}_{i,2} = f(\vec{x}_i^1, \vec{x}_i^4) - f(\vec{x}_i^1) \quad (4.21)$$

$$f(\vec{x}_i^1, \vec{x}_i^2, \vec{x}_i^4) = f(\vec{x}_i^1, \vec{x}_i^2, E(\vec{x}_i^3), \vec{x}_i^4) \quad (4.22)$$

$$\Delta\hat{y}_{i,3} = f(\vec{x}_i^1, \vec{x}_i^2, \vec{x}_i^4) - f(\vec{x}_i^1, \vec{x}_i^2) \quad (4.23)$$

$$f(\vec{x}_i^1, \vec{x}_i^2, \vec{x}_i^3, \vec{x}_i^4) = f(\vec{x}_i^1, \vec{x}_i^2, \vec{x}_i^3, \vec{x}_i^4) \quad (4.24)$$

$$\Delta\hat{y}_{i,4} = f(\vec{x}_i^1, \vec{x}_i^2, \vec{x}_i^3, \vec{x}_i^4) - f(\vec{x}_i^1, \vec{x}_i^2, \vec{x}_i^3) \quad (4.25)$$

(4.18) ve (4.19), tek modelde diğer öznitelik bilgilerinin birer referans değerle değiştirilerek yok edilmesi ile ilgili özniteliğin tek başına tahminleyici olduğunu göstermekte ve dördüncü özniteliğin birinci derecede marjinal katkısını naive değerle model tahmini farkı olarak tanımlamaktadır.

(4.20) ve (4.21), ikinci sırada dördüncü özniteliğin bilgisinin önceden birinci özniteliğin bilgisi varken eklendiğinde marjinal katkısını göstermektedir. Önceden bilgisi modele sunulan öznitelik birinci öznitelik olduğu gibi ikinci ya da üçüncü öznitelik de olabileceği düşünülerek ikinci sırada marjinal katkının üç ayrı değeri olabileceği düşünülmelidir. Bu bakımdan (4.20) ve (4.21) yalnızca hesaplama gösterimi bakımından örnek niteliğindedir.

(4.22) ve (4.23) üçüncü sırada dördüncü özniteliğin bilgisinin önceden birinci ve ikinci özniteliğin bilgisi {1,2} sırasıyla varken marjinal katkısını göstermektedir. Önceden modele sunulan öznitelikler  $C\binom{m-1}{2}$  sayıdadır ve bu öznitelikler 2! farklı biçimde sıralanabilecektir. Bu nedenle dördüncü özniteliğin üçüncü sırada marjinal katkısının 6 ayrı değeri hesaplanabilecektir.

(4.24) ve (4.25) dördüncü sırada dördüncü özniteliğin bilgisinin önceden birinci, ikinci ve üçüncü özniteliğin bilgisi {1,2,3} sırasıyla varken marjinal katkısını göstermektedir. Önceden modele sunulan öznitelikler  $C\binom{m-1}{3}$  sayıdadır ve

bu öznitelikler 3! farklı biçimde sıralanabilecektir. Bu nedenle dördüncü özniteliğin üçüncü sırada marjinal katkısının 6 ayrı değeri hesaplanabilecektir.

Dördüncü özniteliğin farklı senaryolarda marjinal katkısı için toplamda 16 ayrı değeri hesaplanabilmektedir. Shapley değerine ulaşabilmek için bu değerlerin birleştirilmesi gereklidir. Genel bir formül olarak j. özniteliğin Shapley değeri (4.26)'da verilen eşitlikle hesaplanmaktadır.

$$\varphi_j = \sum_{S \subseteq F \setminus \{j\}} \left( \frac{|S|! (|F| - |S| - 1)!}{|F|!} \cdot [f_{S \cup \{j\}}(x_{S \cup \{j\}}) - f_S(x_S)] \right) \quad (4.26)$$

(4.26)'da F özniteliklerin kümesini; S özniteliklerin içinde j. öznitelik bulunmayan altkümeleri; |S|, S'nin eleman sayısını; |F| öznitelik sayısını (m);  $f_{S \cup \{j\}}(x_{S \cup \{j\}})$ , j. özniteliğin bilgisi dahil edilmiş biçimde model tahmin değerini;  $f_S(x_S)$  ise j. özniteliğin bilgisinin yokluğunda tahmin değerini göstermektedir. Burada kesirli ilk terim her bir marjinal katkı deneyi için birer ağırlık oluşturarak bir ağırlıklı toplam oluşturmaktayken (her bir sıra toplamını eşit ağırlıklandırmaktadır) ikinci terim (fark terimi) özniteliğin bilgisi varlığında ve yokluğunda model tahmini değişimini göstermektedir. Belirli bir gözlem verisi için Shapley değeri ( $\varphi_j$ ), j. öznitelik için (5.26)'da görüldüğü gibi marjinal katkıların bir ağırlıklı toplamı olarak hesaplanmaktadır.

$\varphi_j$  yalnızca yerel öznitelik önemi bilgisidir. Diğer bir ifade ile yalnızca modelin belli bir gözleme ait öznitelik değerleri ve tahmin değeri için bir Shapley değeri hesaplanmaktadır ve yerel öznitelik bilgilerini genel (global) bir bilgi olarak birleştirmek için her bir öznitelik için mutlak Shapley değerlerinin ortalamaları hesaplanır ve karşılaştırılır.

Derin öğrenme modellerinde marjinal katkılar için sıra alternatifleri ve sıra alternatifleri için permütasyonlar çok sayıda olabileceği için Lundberg ve Lee (2017) ShAP-DeepExplainer algoritmasını önermişlerdir. Bu algoritma Shapley

değerleri ile özniteliklerin model çıktısına toplamsal katkılarının tam olarak hesaplanması yerine bu değerlere yaklaşık değerleri hızlı hesaplayan bir algoritmadır (bkz. Lundberg ve Lee, 2017; Crowe, 2022). Hesaplama maliyetini azaltmak için bu algoritma tüm gözlemler için Shapley değerlerini hesaplarken bu marjinal katkıların tümünü kullanmak yerine, marjinal katkıların geneli temsil edici bir altkümesi ile Shapley değerlerini hesaplamaktadır. Bu biçimde 30 ayrı Shapley değeri hesaplanmıştır. Tablo 8'de dört ayrı öznitelik için hesaplanan Shapley değerleri gösterilmektedir:

**Tablo 8:** Özniteliklere Ait Shapley Değerleri

KVB (j)	$(\varphi_{1,j})$	$(\varphi_{2,j})$	$(\varphi_{3,j})$	$(\varphi_{4,j})$
1	5.48493	-16.13973	-1.01251	0.01486
2	4.98990	-18.85884	0.79258	0.95405
3	6.31974	8.47460	6.93173	15.52996
4	5.55265	-10.00364	-4.73321	-11.28420
5	6.44499	10.92678	-1.16187	-14.74637
6	-9.55082	7.63421	0.90837	-3.74456
7	3.58820	7.72569	1.18010	-15.02823
8	-0.68796	7.94310	-8.48336	-7.08605
9	4.55765	-8.99045	-6.10763	-1.12906
10	-2.36399	-1.29995	5.99220	-2.54416
11	-7.63513	-7.68895	-0.46463	-1.17240
12	9.40869	7.39439	-4.31642	13.52248
13	-0.02929	8.34581	-3.68971	0.78411
14	7.68308	-17.45208	9.83024	18.15352
15	-3.94772	11.20125	12.67848	17.39083
16	-11.04573	5.50144	9.62368	11.08384
17	4.82578	-16.93239	8.04735	-6.54824
18	-15.35507	10.36912	-8.28785	11.41153
19	-10.26147	-11.31606	-12.46896	5.86276
20	-3.68550	1.71902	7.96834	-4.64875
21	-6.24849	3.54582	-3.95507	6.11286
22	-0.06378	-1.84755	-19.30853	7.31471
23	4.53877	-0.57621	1.32342	-13.48551
24	3.93809	-4.42124	-5.78187	-6.67581
25	-8.94812	7.43218	0.52409	10.01021
26	-6.08994	-6.18885	4.94293	-15.65989
27	-5.45830	8.44692	6.44956	-1.04025
28	5.73578	-10.59095	3.17262	9.32198
29	8.34421	7.44059	-1.51595	8.24960
30	-4.57441	8.77393	-0.46697	-9.45550

Tablo 8'deki her bir öznitelik değerine ait shapley değerlerinin mutlak ortalamasını hesaplayarak özniteliklere ait global shapley değerleri elde edilir,

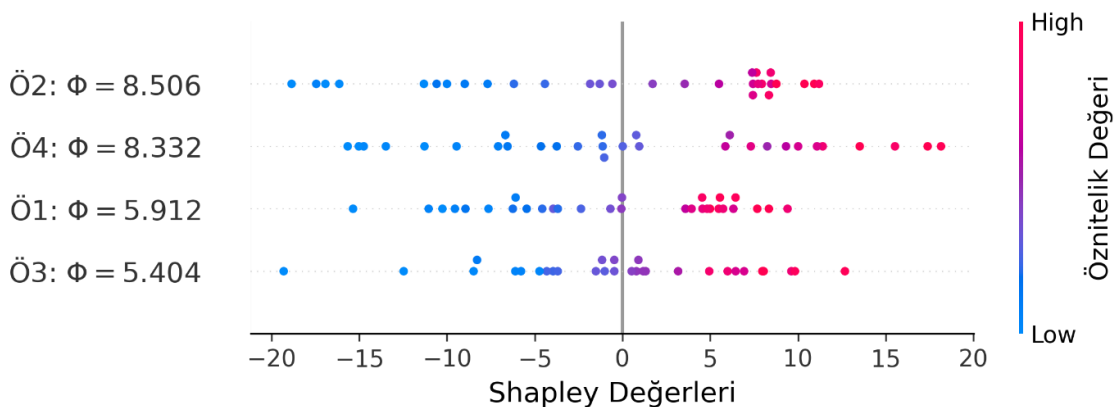
elde edilen global shapley değerleri üzerinden sıralama ilişkisi tanımlanarak girdiler arasındaki sıralı ilişki elde edilmiş olur. Tablo 9'da öznitelikler için hesaplanmış global shapley değerleri gösterilmiştir.

**Tablo 9:** Global Shapley Değerleri

Öznitelik (i)	$( \varphi_i )$
1	5.91194
2	8.50606
3	5.40401
4	8.33221

Tablo 9'a göre global shapley değerleri sırasıyla öznitelik 1 için 5.91194, öznitelik 2 için 8.50606, öznitelik 3 için 5.40401 ve öznitelik 4 için 8.33221 şeklinde hesaplanmıştır. Özniteliklere ait global shapley değerlerine bakarak öznitelik2 > öznitelik4 > öznitelik1 > öznitelik3 sıralaması elde edilmiştir. Buradan girdiler arasındaki ilişki de x'ler girdileri temsil etmek üzere  $\bar{x}^2 \succcurlyeq \bar{x}^4 \succcurlyeq \bar{x}^1 \succcurlyeq \bar{x}^3$  sonucuna ulaşılmıştır.

Şekil 13 ise Tablo 8'de de sunulan Shapley değerleri ile öznitelik değeri ilişkisini ve mutlak Shapley değerlerinin ortalamasına göre özniteliklerin modele katkıları bakımından sıralanışını göstermektedir.



**Şekil 13:** SDA Özet Grafiği

Şekil 13'te satır künyeleri, her bir öznitelik için mutlak Shapley değerlerinin ortalamaları; renk kodları da Shapley değerleri gösterimini özniteliğin yüksek değerleri için kırmızıya kadar sıcak renklere, özniteliğin düşük değerleri içinse maviye kadar soğuk renklere atanmaları göstermektedir. Genel olarak bu grafik, her bir öznitelik için çeşitli gözlemlerin verisi ile elde edilmiş Shapley değerlerini bu özniteliğin bilgisinin tahmini beklenen değerden saptırabildiği biçiminde özetlemektedir. Şekil 13'te görüldüğü gibi veri kümesinde özniteliklerin önem sıralaması en önemliden en önemsiz sırasıyla ikinci öznitelik, dördüncü öznitelik, birinci öznitelik ve üçüncü öznitelik biçimindedir.

#### 4.2.6. Öznitelik Önem Sıralaması ile Ağırlık Kısıtlı Veri Zarflama Analizi

Bölüm 4.2.4.'te ve Bölüm 4.2.5'te sırasıyla PÖS ile bulguları ve SDA ile bulguları anlatılmıştır. Bu son aşamada ise ayrı ayrı PÖS ve SDA bulgularından elde edilen öznitelik (VZA girdi kriteri) önem sıralamaları ağırlık kısıtlı birer VZA modeli oluşturmak üzere standart VZA modeline eklenmiştir.

Bir örnekle somutlaştırılacak olursa Tablo 3'te sunulan veri için PÖS sıralaması  $\vec{x}^4 \succcurlyeq \vec{x}^2 \succcurlyeq \vec{x}^3 \succcurlyeq \vec{x}^1$  biçiminde ve SDA sıralaması ise  $\vec{x}^2 \succcurlyeq \vec{x}^4 \succcurlyeq \vec{x}^1 \succcurlyeq \vec{x}^3$  biçimindedir. Dolayısıyla standart VZA modellerine PÖS için (4.27) – (4.29)'da sunulan kısıtlar, SDA için ise (4.30) – (4.32)'de sunulan kısıtlar eklenerek her bir KVB için ikişer ağırlık kısıtlı VZA modeli oluşturulmuştur.

$$\begin{aligned} & \vdots \\ v_4 & \geq v_2 & (4.27) \\ v_2 & \geq v_3 & (4.28) \\ v_3 & \geq v_1 & (4.29) \\ & \vdots \end{aligned}$$

Standart VZA eklenen kısıtlarda ordinal bir önem ilişkisi tanımlanmıştır. Her ne kadar Heaton (2017), Heaton ve diğerleri (2017) ve benzeri çalışmalarda bozunumlara dayalı yitim fonksiyonu sapmaları normalize edilerek özniteliklerin görece önemlerine dair kardinal veri edinim yöntemleri önerilmiş olsa da VZA'nın

ağırlık belirleme esnekliği konusunda aşırı olabileceği düşünülen sınırlandırmalardan kaçınmak adına bu tez çalışmasında öznitelik önem bilgisi ağırlık kısıtlı VZA’da yalnızca ordinal önem ilişkileri biçiminde deşifre edilmiştir.

$$\begin{aligned} & \vdots \\ v_2 & \geq v_4 \quad (4.30) \\ v_4 & \geq v_1 \quad (4.31) \\ v_1 & \geq v_3 \quad (4.32) \\ & \vdots \end{aligned}$$

PÖS’ten deşifre edilen ordinal önem bilgisine dayalı ağırlık kısıtlarının bir benzeri de SDA ile öznitelik sıralamasından elde edilmiş ve yine yalnızca ordinal önem bilgisi ile ağırlık kısıtları tanımlanmıştır. Bu tercih temel olarak Podinovski ve Athanassopoulos (1998)’in ağırlık kısıtlamalarının ağırlık belirleme serbestisi üzerinde aşırı baskısının etkinlik skorlarını fazla düşük hesaplama sonucu doğurabileceği eleştirisine dayanmaktadır.

Tablo 7’de sunulmuş olan PÖS bulgularından, Tablo 9’da sunulmuş olan SDA sıralamalarından ve bu bulgulara dayalı ağırlık kısıtlarından görüldüğü üzere iki yöntem birbirlerinden farklı modeller oluşturmaktadır. Bu farklılığın arkasında PÖS ve SDA yöntemlerinin süreç farklılıkları yatmaktadır. PÖS, diğer tüm öznitelik bilgilerinin varlığında ve tüm gözlemler için eşanlı olarak ilgili öznitelik bilgisinde bozunumun sonuçlarını incelerken SDA, ilgili özniteliğin tahmin değerine marjinal katkısını kendisinden önce modele sunulan öznitelik bilgileri ve ilgili özniteliğin bilgisinin kaçınıcı sırada modele sunulduğuna göre tüm olasılık uzayında inceleyen ve bu incelemeleri her bir gözlem için bireysel olarak tekrarlayıp elde edilen veriyi tek bir küresel modele katkı değerine kadar birleştiren bir yaklaşımdır.

Tablo 10, standart VZA sonuçlarını, PÖS ile SDA destekli ağırlık kısıtlı VZA sonuçlarını ve aynı sırayla analizlere ait ortalama etkinlik skor değerlerini göstermektedir.

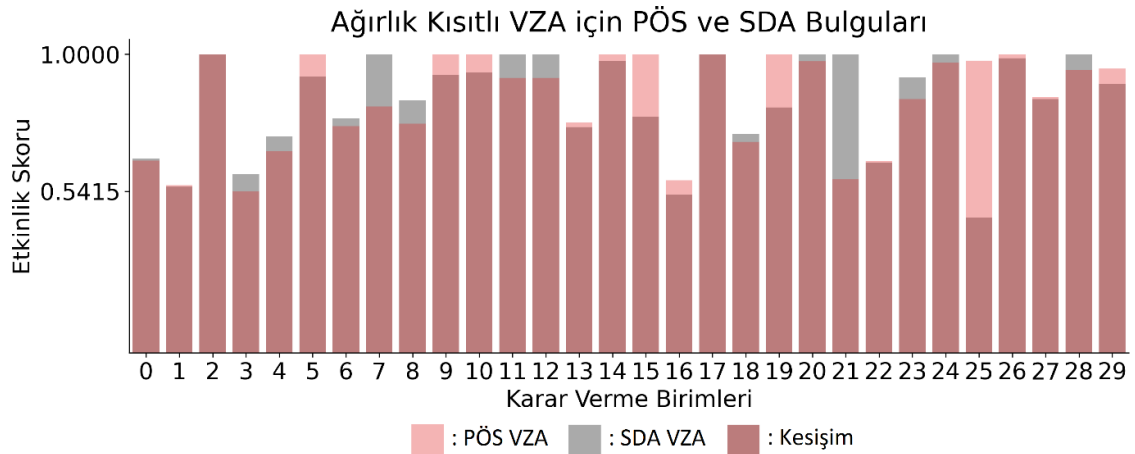
**Tablo 10:** Deney Bulguları

<b>KVB</b>	<b>VZA</b>	<b>PÖS</b>	<b>SDA</b>
1	1	0.64366	0.65116
2	1	0.56139	0.55661
3	1	1.00000	1.00000
4	1	0.54146	0.59845
5	1	0.67566	0.72424
6	1	1.00000	0.92643
7	1	0.75946	0.78636
8	1	0.82532	1.00000
9	1	0.76759	0.84598
10	1	1.00000	0.93086
11	1	1.00000	0.93868
12	1	0.92093	1.00000
13	1	0.92109	1.00000
14	1	0.77226	0.75647
15	1	1.00000	0.97825
16	1	1.00000	0.78996
17	1	0.57831	0.53103
18	1	1.00000	1.00000
19	1	0.70733	0.73298
20	1	1.00000	0.82262
21	1	0.97642	1.00000
22	1	0.58114	1.00000
23	1	0.64297	0.63716
24	1	0.85056	0.92249
25	1	0.97161	1.00000
26	1	0.97896	0.45352
27	1	1.00000	0.98658
28	1	0.85618	0.85040
29	1	0.94660	1.00000
30	1	0.95244	0.90057
<b>Ort.</b>	<b>1</b>	<b>0.84771</b>	<b>0.84403</b>

Tablo 10'da satırlar KVB'lere ait künye numaraları başlığı olmak üzere standart VZA etkinlik skorunu, PÖS destekli ağırlık kısıtlı VZA etkinlik skorunu ve SDA destekli ağırlık kısıtlı VZA etkinlik skorunu sunmaktadır. Bu tablodan da görülebileceği gibi PÖS destekli ağırlık kısıtlı VZA ile etkin birim sayısı 30'dan 9'a düşmüştür. Benzer şekilde incelendiğinde yine 30 olan etkin birim sayısı SDA destekli ağırlık kısıtlı VZA ile 9'a düşmüştür. PÖS destekli ağırlık kısıtlı VZA ile SDA destekli ağırlık kısıtlı VZA kıyaslandığında KVB3 ve KVB18 için etkin birim



olma özelliğinin değişmediği görülmektedir. KVB6, KVB10, KVB11, KVB15, KVB16, KVB20 ve KVB27 için PÖS destekli ağırlık kısıtlı VZA'da bu karar verme birimleri etkin olma özelliğini taşıırken, SDA destekli ağırlık kısıtlı VZA sonuçlarına bakıldığında söz konusu birimlerin etkin olma özelliklerini yitirdikleri görülmektedir. Benzer şekilde, KVB8, KVB12, KVB13, KVB21, KVB22, KVB25 ve KVB29 için SDA destekli ağırlık kısıtlı VZA'da bu karar verme birimleri etkin olma özelliğini taşıırken, PÖS destekli ağırlık kısıtlı VZA'da söz konusu karar verme birimleri etkin olma özelliklerini yitirmişlerdir. Tek veri kümesine ait standart VZA skorları ile PÖS destekli ağırlık kısıtlı VZA skorları ile SDA destekli ağırlık kısıtlı VZA skorlarına ait ortalama etkinlik skoru değerleri de Tablo 10'un son satırında sunulmuştur. Bu bilgiye göre iki ayrı yaklaşımın Veri Zarflama Analizinde ayırt etme gücüne olan katkısının benzer olduğu görülmektedir.



**Şekil 14:** Ağırlık Kısıtlı VZA için PÖS ve SDA Bulguları

Şekil 14'te pembe renk ve gri renk sırasıyla PÖS ve SDA algoritması desteğiyle oluşturulmuş ağırlıklı kısıtlı VZA etkinlik skorlarını gösterirken bu iki rengin karışımından oluşan bordo renk ise çubuk grafiklerinde her iki tür etkinlik skorlarının gösterimindeki kesişim nedeniyle ortaya çıkmıştır.

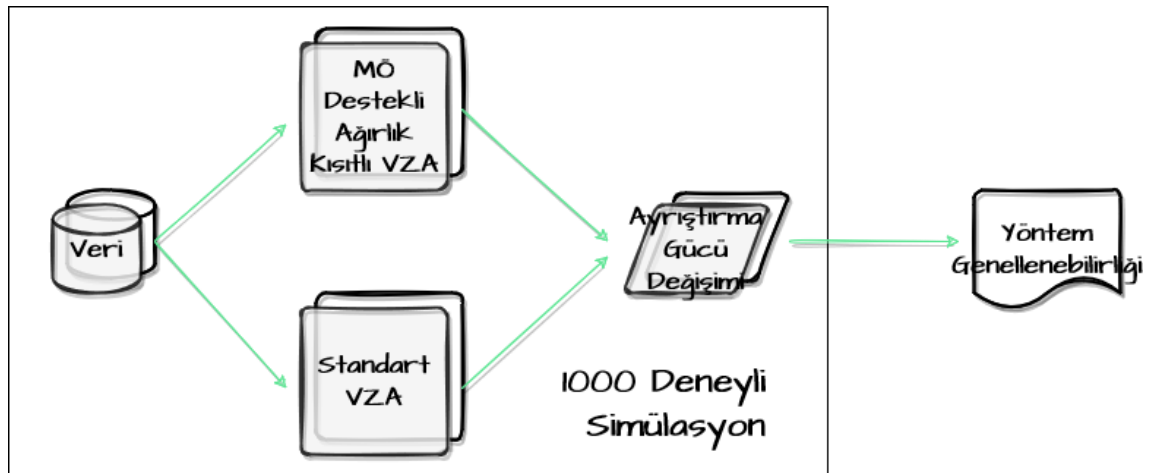
Yapılan deney sonucunda makine öğrenmesi desteği ile VZA kriterleri için önem bilgisinin edinilebileceği ve bu önem bilgisinin kılavuzluğunda formüle edilen ağırlık kısıtlı VZA modelleriyle ayırttırma gücünün her iki makine öğrenmesi

yorumlama algoritması için de benzer biçimde artırılabilirdiği ortaya konmuştur. Ancak; türetilmiş tek bir veri kümesinden yola çıkarak yapılan çıkarımların genellenebilirliğini savunmak mümkün değildir. Bu nedenle bir sonraki bölümde ayrıştırma gücünü artırmada makine öğrenmesi yorumlama algoritmalarının kullanımının genellenebilirliği incelenmiştir.

### 4.3. ÖZNETELİK ÖNEM BİLGİSİ ile AĞIRLIK KISITLI VERİ ZARFLAMA ANALİZİ ÜZERİNE 1000 DENEY İÇEREN SİMÜLASYON ANALİZİ

Bölüm 4.2’de tek bir veri kümesi üzerinden derin öğrenme ve makine öğrenme yorumlama algoritmaları aracılığıyla ağırlık kısıtlı VZA’da VZA kriterleri arasındaki nesnel ilişkilerin ortaya çıkarılabileceği ve bu ilişkilere göre formüle edilip standart VZA modeline eklenen ağırlık kısıtları ile VZA’nın ayrıştırma gücünün iyileştirilebileceği gösterilmiştir.

Bölüm 4.2.’de yapılan bu analiz, tek bir örneğin sunumu niteliğindedir ve genellenebilirlik için yeterli sav sunmamaktadır. Bu nedenle tezin bu bölümünde genellenebilirliği tartışabilmek adına benzer kurallarla türetilmiş her biri 4 girdi ile 1 çıktının üretildiği 30’ar gözlem (KVB) içeren 1000 ayrı veri kümesi ile yapılan 1000 ayrı deneyi içeren bir simülasyon analizi tasarlanmış ve gerçekleştirilmiştir. Şekil 15’te simülasyon analizinin görsel özeti sunulmuştur.



Şekil 15: Simülasyon Analizi Görsel Özeti

### 4.3.1. Simülasyon Analizinde Araştırma Tasarımı

Bölüm 4.2.1’de tek veri kümesi ile yapılan deneyin tasarımı sunulmuştur. Simülasyon analizinde denk deneyler 1000 defa tekrarlanmıştır. Tek veri ile deneye paralel olarak bu simülasyon analizinde 1000 ayrı veri kümesi için VZA etkinlik skorları, PÖS destekli ağırlık kısıtlı VZA skorları ve SDA destekli ağırlık kısıtlı VZA etkinlik skorları ile karşılaştırılarak Bölüm 4.2’de tek veri kümesi ile yapılan deneyde gözlenen VZA’da ayırıştırma gücü iyileştiriminin genellenebilirliği araştırılmıştır.

#### 4.3.1.1. Simülasyon Analizinde Veri Kümeleri

Bölüm 4.2.2’de Python programlama diline ait olan Numpy kütüphanesi aracılığıyla VZA girdi kriterleri ve bu girdi kriterlerini argüman alan CD üretim fonksiyonuna ait üs parametreleri rassal olarak türetilmişti. Bu türetimin ve yapılan deneyin tekrarlanabilirliğini sağlamak adına rassal hal (instance) `numpy.random.seed(1000)` kodu aracılığıyla 1000 sayısal değeri ile tanımlı sabit bir kurala bağlanmıştır. Benzer mantıkla simülasyon analizinde türetilen tüm veri kümeleri 1000 ayrı `seed` değeri ile sabitlenerek rassallığa bağlı olarak veri kümelerinin tekrar kullanım olasılığı elenmiş ve analizin tekrarlanabilirliği sağlanmıştır.

#### 4.3.1.2. Simülasyon Analizinde Derin Öğrenme ile Genel Üretim Fonksiyonlarının Modellenmesi

Bölüm 4.2.3’te tek veri kümesi ile yapılan deney için CD üretim fonksiyonu çıktı değerlerini etiketler olarak alan ve VZA girdi kriterleri verisini öznitelikler olarak kullanarak VZA çıktı kriteri tahminleyen derin mimarili bir YSA modeli tanıtılmıştır. Simülasyon analizinde Bölüm 4.2.3’te tanıtılan model mimarisi ve hiperparametre değerleri değişiklik yapılmaksızın tüm veri kümeleri için genel birer üretim fonksiyonunun modellenmesinde kullanılmıştır.

Yüksek başarımlı bir modelin genel bir üretim fonksiyonunu temsil yeteneği de yüksek olacaktır. Simülasyonda kullanılan tüm veri kümelerinde model başarımları yüksektir ve dolayısıyla tüm veri kümeleri için genel birer üretim fonksiyonu bilgisi elde edilmiştir denilebilir.

Tablo 11’de simülasyon analizinde kullanılan tüm veri kümeleri için model başarımlarının performans metriklerinin betimsel istatistikleri özetlenmiştir.

**Tablo 11:** 1000 Veri Kümesi için Model Başarımlarının Performans Metrikleri

Betimsel İstatistikler	Performans Metrikleri		
	$R^2$	$\sqrt{HKO}$	HKO
En Küçük Değer	$1 - 8.5 \times 10^{-5}$	$6.3 \times 10^{-7}$	$3.9 \times 10^{-13}$
En Büyük Değer	$1 - 8.0 \times 10^{-16}$	$6.8 \times 10^{-1}$	$4.7 \times 10^{-1}$
Ortalama	$1 - 3.4 \times 10^{-7}$	$6.2 \times 10^{-3}$	$1.5 \times 10^{-3}$
Standart Sapma	$3.5 \times 10^{-6}$	$3.9 \times 10^{-2}$	$1.9 \times 10^{-2}$

Tüm veri kümeleri için elde edilen en iyi modellerde HKO değerleri yaklaşık  $[3.9 \cdot 10^{-13}, 4.7 \cdot 10^{-1}]$  aralığındadır ve ortalama HKO değeri yaklaşık  $1.5 \cdot 10^{-3}$ ’tür. Yine tüm veri kümeleri için elde edilen en iyi modellerde verideki değişkenliğin açıklanma oranları en az yaklaşık  $1 - 8.5 \cdot 10^{-5}$ ; en çok yaklaşık  $1 - 8 \cdot 10^{-16}$  ve ortalama yaklaşık  $1 - 3.4 \cdot 10^{-7}$ ’dir. Diğer bir ifade ile modeller genel bir üretim fonksiyonu olarak çıktı değerlerindeki değişkenliği neredeyse tamamen açıklayabilmektedir.

#### 4.3.1.3. Simülasyon Analizinde Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması Kullanılarak VZA Girdi Kriterleri Arasındaki Önem Bilgilerinin Edinilmesi

Bölüm 4.2.4’te önerilen optimizasyona dayalı yeniden dağıtım ile PÖS (PÖS) algoritması ayrıntılı olarak sunulmuştur. Simülasyon uygulamasında da tek veri kümesi ile yapılan deney ile aynı PÖS algoritması kullanılmıştır.

PÖS algoritması 1000 ayrı veri kümesine uygulanmıştır. Tablo 12’de simülasyon uygulamasında kullanılmış 1000 adet veri kümesi havuzuna ait ilk 10 veri kümesi için PÖS bulguları özetlenmektedir.

**Tablo 12:** İlk 10 Veri Kümesi için PÖS Bulguları ve Öznitelik Sıralaması

Veri Kümesi	R <sup>2</sup>	pR <sup>2</sup>				$\sqrt{HKO}$	p $\sqrt{HKO}$				PÖS
		PG1	PG2	PG3	PG4		PG1	PG2	PG3	PG4	
1	1 - 2.9 x 10 <sup>-14</sup>	0.50538	0.86858	0.07421	0.56712	1.3 x 10 <sup>-12</sup>	14.03177	7.24913	19.17011	13.12634	[2, 0, 3, 1]
2	1 - 1.2 x 10 <sup>-9</sup>	0.64102	0.71621	0.82372	0.41908	4.7 x 10 <sup>-7</sup>	11.88067	10.64733	8.38953	15.11406	[3, 0, 1, 2]
3	1 - 1.9 x 10 <sup>-14</sup>	0.67716	0.52971	0.53177	0.49599	7.7 x 10 <sup>-12</sup>	10.91093	13.17869	13.24365	13.65349	[3, 2, 1, 0]
4	1 - 3.2 x 10 <sup>-14</sup>	0.62279	0.47016	0.44839	0.52410	1.0 x 10 <sup>-11</sup>	10.21692	12.11941	12.42359	11.51271	[2, 1, 3, 0]
5	1 - 4.2 x 10 <sup>-14</sup>	0.53238	0.16302	0.39717	0.72308	9.0 x 10 <sup>-12</sup>	9.55973	12.75610	10.86815	7.40304	[1, 2, 0, 3]
6	1 - 5.9 x 10 <sup>-15</sup>	0.73620	0.36768	0.66902	0.59427	1.9 x 10 <sup>-12</sup>	9.11223	14.17088	10.19507	11.28665	[1, 3, 2, 0]
7	1 - 6.4 x 10 <sup>-8</sup>	0.52403	0.48956	-0.25459	0.22529	3.5 x 10 <sup>-4</sup>	10.02097	10.44187	16.29455	12.84092	[2, 3, 1, 0]
8	1 - 1.0 x 10 <sup>-12</sup>	0.82022	0.66456	0.76855	0.20884	2.3 x 10 <sup>-3</sup>	6.48587	8.58526	7.15961	13.23144	[3, 1, 2, 0]
9	1 - 1.7 x 10 <sup>-6</sup>	-0.36588	0.14029	0.36069	-0.22692	3.4 x 10 <sup>-4</sup>	14.43973	11.46253	9.90385	13.79296	[0, 3, 1, 2]
10	1 - 1.3 x 10 <sup>-13</sup>	0.53316	0.52528	0.41812	0.31745	2.2 x 10 <sup>-11</sup>	8.70904	8.75483	9.70876	10.67346	[3, 2, 1, 0]

Tablo 12’de sütunlar sırasıyla modelin orijinal verideki değişkenliği açıklama gücünü, bozunuma tabi tutulmuş dört veri kümesi için veri kümelerindeki değişkenliği açıklama gücünü, hata kareleri ortalamasının karekökünü, bozunuma tabi tutulmuş dört veri kümesi için hata kareleri ortalamalarının kareköklerini ve PÖS’e göre özniteliklerin en önemliden en önemsiz künyelerinin sırasını belirtmektedir. Satırlarda ise gözlemlerin veri kümelerinin künye başlıkları içinde PÖS bulguları sunulmuştur. PÖS için seçilen performans kriteri HKO’nun kareköküdür ve öznitelikler sıralanırken künye numaraları 0’dan başlayarak 3’e kadar tanımlanmıştır. Örneğin, Tablo 12’deki ilk veri kümesi için yaklaşık 0 olan performans kriteri bozunuma tabi tutulmuş veri kümeleri için sırasıyla 14.03177, 7.24913, 19.17011 ve 13.12634 olarak hesaplanmıştır ve dolayısıyla öznitelikler en önemliden en önemsiz üçüncü girdi, birinci girdi, dördüncü girdi ve ikinci girdi biçiminde sıralanmıştır.


Ayrıca Tablo 12’de bozunuma tabi tutulmuş bazı veri kümelerinde  $R^2$  değerinin negatif değerli olduğu görülmektedir (bkz 7. veri kümesi için üçüncü özniteliğin bozunumu ile elde edilen model için, 9. veri kümesi için birinci özniteliğin bozunumu ile elde edilen model için ve dördüncü özniteliğin bozunumu ile elde edilen model için  $R^2$  değerleri sırasıyla yaklaşık -0.25, -0.37 ve -0.23’tür). Bunun nedeni  $R^2$ ’nin seçilen hesaplanma yöntemidir:

$$R^2 = 1 - \frac{\sum_i (e_i)^2}{\sum_i (y_i - \hat{y}_i)^2} \quad (4.33)$$

(4.33)’deki eşitliğe göre kalıntı hatası (*residual error*) tahmin hatalarından büyükse  $R^2$  negatif değerli olabilecektir. Bu koşulun oluşabilmesi için modelin herhangi bir sabit değer ( $c$ ) için tüm  $y_i$  ‘leri  $\hat{y}_i = c$  hiperdüzleminden (ör. bir bağımsız değişken ve bir bağımlı değişkenin varlığında yatay bir doğrudan) daha kötü tahminlemesi gereklidir. Diğer bir ifade ile  $R^2$ ’nin negatif değerli olması için modellerin  $\hat{y}$  ile negatif korelasyonu olan değerleri tahminliyor olması gereklidir.

Ayrıca; Tablo 12’de görüldüğü üzere 7. veri kümesine ait üçüncü özniteliğin bozunumuyla elde edilen modele ve 9. veri kümesi için birinci ve dördüncü özniteliğin bozunumuyla elde edilen modellere ait  $R^2$  ‘nin negatif değerli olması optimizasyona dayalı olarak yeniden gerçekleştirilmiş olan bozunumun son derece başarılı olduğunu ortaya koymaktadır.

Tablo 12’de önerilen optimizasyon temelli PÖS algoritmasının, özniteliklerin model başarımı bakımından taşıdığı bilgiyi son derece etkili biçimde yok edebildiği simülasyon verisi üzerinden de gösterilmiştir.



**Şekil 16:** PÖS Destekli VZA’da Önem Sırasına Göre Öznitelik Dağılımları

Şekil 16’dan görüldüğü üzere, 1000 adet veri kümesinin %27.29’unda öznitelik1 birinci sıraya yerleşirken, %25.50’ünde öznitelik4, %24.20’sinde öznitelik3,



%23.01'lik kısmında ise öznitelik2 birinci sıraya yerleşmiştir. Benzer şekilde ikinci, üçüncü ve dördüncü sıralara ait olan öznitelik dağılımları da Şekil 16'da gösterilmiştir.

**Tablo 13:** PÖS Destekli VZA'da Sıralama Frekans Bilgileri

Öznitelik	Sıra 1	Sıra 2	Sıra 3	Sıra 4
Ö1	273	229	259	239
Ö2	230	244	268	258
Ö3	242	264	245	249
Ö4	255	263	228	254

Tablo 13'te özniteliklere ait sıralamalar için frekans bilgisi özetlenmiştir. Örneğin, Öznitelik1 modellerin 273 tanesinde birinci sıraya yerleşirken, 229 tanesinde ikinci, 259 tanesinde üçüncü ve 239 tanesinde ise dördüncü sırada yer almıştır. Benzer şekilde, öznitelik1 modellerin 273 tanesinde birinci sırada yer alırken, 230 tanesinde öznitelik2, 242 tanesinde öznitelik3, 255 tanesinde ise öznitelik4 birinci sırada yer almıştır.


#### **4.3.1.4. Simülasyon Analizinde Shapley Değerleri Algoritması ile Öznitelik Önem Sıralaması Kullanılarak VZA Girdi Kriterleri Arasındaki Önem Bilgilerinin Edinilmesi**

Tezin bu alt bölümünde 1000 veri kümesi için kurulan genel üretim fonksiyonu tahminleme modellerinin tümü için Bölüm 4.1.3 ve Bölüm 4.2.5'te anlatılmış olan SDA algoritması uygulanmış ve bulguları kaydedilmiştir. Simülasyon uygulamasında 30 gözlemlili (KVB) 1000 veri kümesinin her birinde 30 ayrı Shapley değeri hesaplanmıştır. Tablo 14, ilk 10 veri kümesi için bu bulguların bir özeti niteliğindedir.

**Tablo 14:** İlk 10 Veri Kümesi için SDA Bulguları

Veri Kümesi	$ \overline{\varphi_1} $	$ \overline{\varphi_2} $	$ \overline{\varphi_3} $	$ \overline{\varphi_4} $	SDA Sıralaması
1	7.35386	5.84117	8.73434	6.89943	[2, 0, 3, 1]
2	5.87170	6.05239	6.07058	9.67446	[3, 2, 1, 0]
3	5.74541	7.42037	7.12405	8.04154	[3, 1, 2, 0]
4	6.77344	5.57290	5.95499	6.18047	[0, 3, 2, 1]
5	6.53074	7.19256	7.72307	6.77974	[2, 1, 3, 0]
6	6.23700	6.68575	7.21419	7.01211	[2, 3, 1, 0]
7	6.21894	7.06280	7.56592	7.73312	[3, 2, 1, 0]
8	4.57646	6.10378	7.54252	9.62194	[3, 2, 1, 0]
9	7.49484	6.18558	5.35575	8.38890	[3, 0, 1, 2]
10	7.98275	8.65944	6.14496	6.26476	[1, 0, 3, 2]

Tablo 14'te satırlar veri kümelerinin künye numaraları başlığı içinde sırasıyla her bir özniteliğe dair mutlak Shapley değerleri ortalamalarını ve SDA ile öznitelik sıralamasını göstermektedir. Tablo 14'e bakarak veri kümesi 2 için global shapley değerleri sırasıyla öznitelik 1 için 5.87170, öznitelik 2 için 6.05239, öznitelik 3 için 6.07058 ve öznitelik 4 için 9.67446 şeklinde hesaplanmıştır. Özniteliklere ait global shapley değerlerine bakarak öznitelik4 > öznitelik3 > öznitelik2 > öznitelik1 sıralaması elde edilmiştir. Buradan girdiler arasındaki ilişki de  $x^4 \succ x^3 \succ x^2 \succ x^1$  sonucuna ulaşılmıştır.



**Şekil 17:** SDA Destekli VZA'da Önem Sırasına Göre Öznitelik Dağılımları

Şekil 17'den görüldüğü üzere, 1000 adet veri kümesinin %26.39' unda öznitelik4 birinci sıraya yerleşirken, %25' inde öznitelik3, %24.40'inde öznitelik1, %24.20'lik kısmında ise öznitelik2 birinci sıraya yerleşmiştir. Benzer şekilde ikinci, üçüncü ve dördüncü sıralara ait olan öznitelik dağılımları da Şekil 17'de gösterilmiştir.

**Tablo 15:** SDA Destekli VZA'da Sıralama Frekans Bilgileri

Öznitelik	Sıra 1	Sıra 2	Sıra 3	Sıra 4
Ö1	244	246	253	257
Ö2	242	257	244	257
Ö3	250	252	260	238
Ö4	264	245	243	248

Tablo 15'te özniteliklere ait sıralamalar için frekans bilgisi özetlenmiştir. Örneğin, Öznitelik1 modellerin 244 tanesinde birinci sıraya yerleşirken, 246 tanesinde ikinci, aynı şekilde 253 tanesinde üçüncü ve 257 tanesinde ise dördüncü sırada yer almıştır. Benzer şekilde, öznitelik1 modellerin 244 tanesinde birinci sırada yer alırken, 242 tanesinde öznitelik2, 250 tanesinde öznitelik3 ve 264 tanesinde ise öznitelik4 birinci sırada yer almıştır.

#### 4.3.2. Simülasyon Bulguları

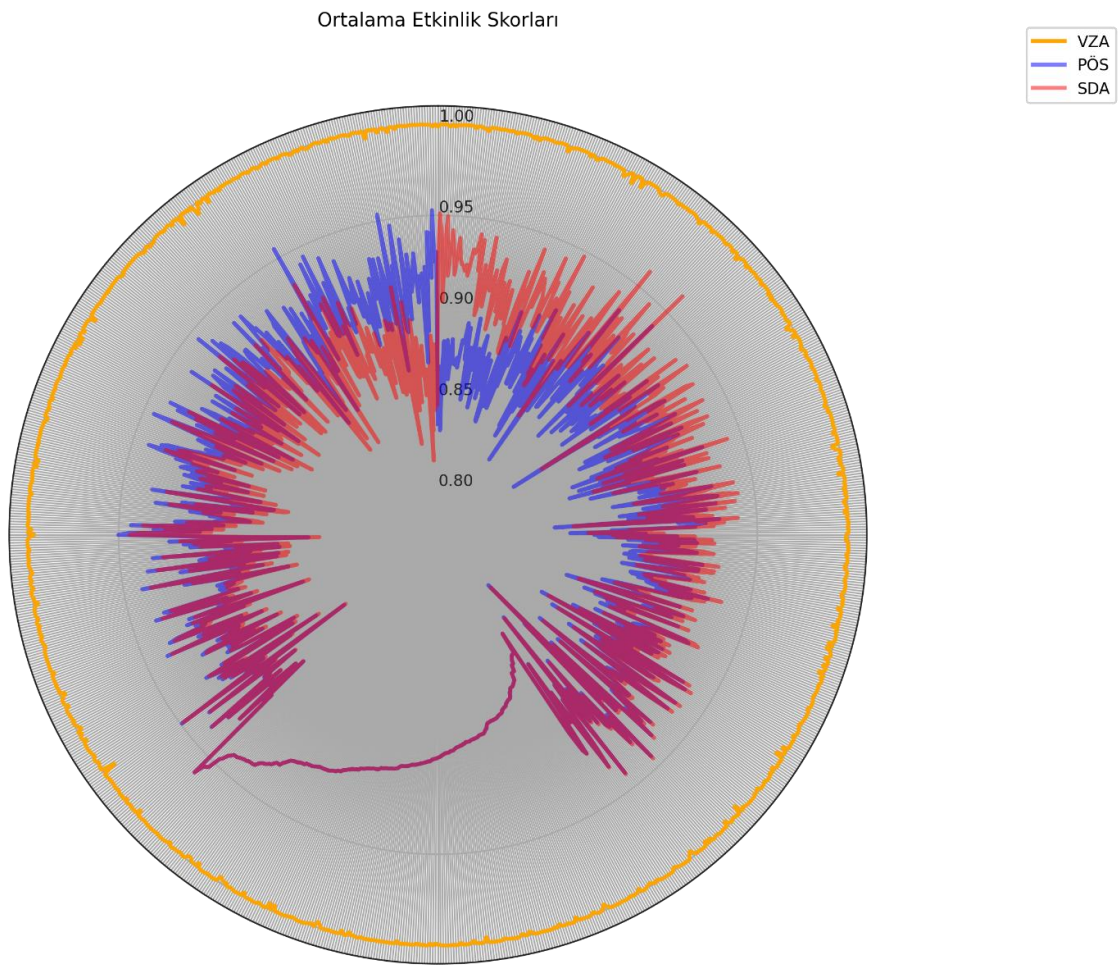
1000 veri kümesinin tümü için Tablo 10'da tek veri kümesi için bulunan sonuçların benzerleri elde edilmiş olup söz konusu simülasyon verisine (1000 adet veri kümesi) ait ağırlık kısıtlı VZA modellerinin bulgularına dair bir özet sunum Tablo 16'da verilmiştir.

**Tablo 16:** İlk 10 Veri Kümesi için Analiz Bulguları

Veri Kümesi	Etkin KVB Sayısı			Etkinlik Skor Ortalaması		
	VZA	PÖS	SDA	VZA	PÖS	SDA
1	28	8	8	0.99990	0.86931	0.86931
2	30	9	10	1.00000	0.87027	0.91194
3	29	14	11	0.99982	0.91284	0.91134
4	29	9	8	0.99986	0.91862	0.90604
5	29	9	12	0.99903	0.89602	0.89534
6	30	14	14	1.00000	0.91345	0.91148
7	30	10	11	1.00000	0.88756	0.89996
8	30	9	14	1.00000	0.90691	0.91629
9	29	8	7	0.99853	0.90892	0.86262
10	30	6	9	1.00000	0.85543	0.89575

Tablo 16'da satırlarda veri kümelerinin künyeleri başlığında bu veri kümelerinde sırasıyla standart VZA ile bulunan etkin KVB sayısı, PÖS destekli ağırlık kısıtlı VZA ile bulunan etkin KVB sayısı, SDA destekli ağırlık kısıtlı VZA ile bulunan etkin KVB sayısı ve standart VZA etkinlik skorları ortalaması, PÖS destekli ağırlık kısıtlı VZA etkinlik skorları ortalaması, SDA destekli ağırlık kısıtlı VZA etkinlik skorları ortalaması verisi özetlenmiştir. Tablo 16'ya bakılarak veri kümesi 1 için standart

VZA sonucu 28 olan etkin birim sayısının PÖS destekli ağırlık kısıtlı VZA ve SDA destekli ağırlık kısıtlı VZA ile ayrı ayrı 8 etkin birime düşürüldüğü görülebilir. Benzer şekilde yine Tablo 16'da yaklaşık 0.99 olan standart VZA skorunun, PÖS destekli ağırlık kısıtlı VZA ve SDA destekli ağırlık kısıtlı VZA ile ayrı ayrı yaklaşık 0.86 etkinlik skoruna düşürüldüğü görülmektedir. Ayrıca PÖS'ün ve SDA'nın ağırlık kısıtlarına kılavuzluk ederek VZA'da ortalama etkinlik skorlarına ve etkin KVB sayılarına olan etkileri sırasıyla Şekil 18 ve Şekil 19'da 1000 adet veri kümesi üzerinden görselleştirilmiştir.



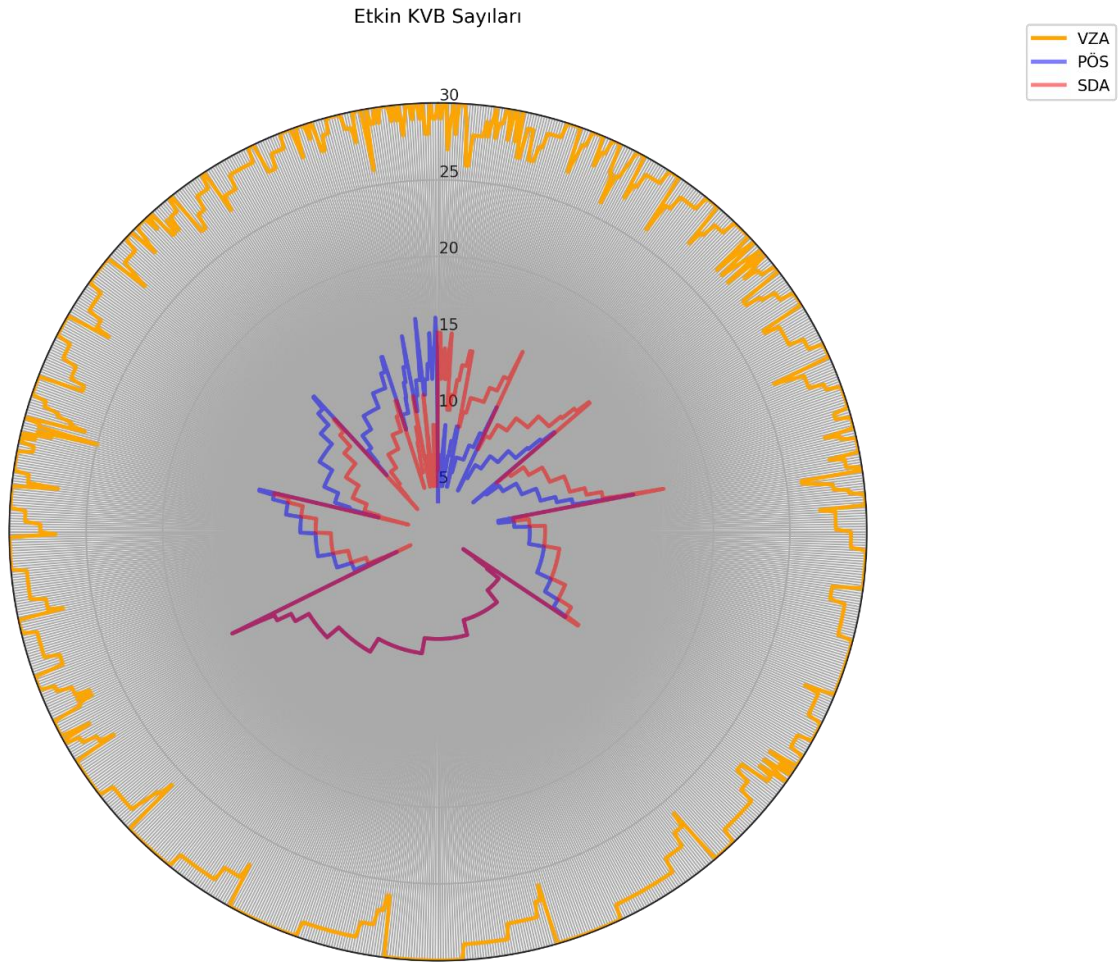
**Şekil 18:** 1000 Veri Kümesi için Etkinlik Skorları Ortalamaları

Şekil 18'de standart VZA'ya, PÖS destekli ağırlık kısıtlı VZA'ya ve SDA destekli ağırlık kısıtlı VZA'ya ait veri sırasıyla sarı, mavi ve kırmızı renk kodları ile temsil olunmaktadır. Mor renk ise mavi ve kırmızı renklerin kesişimi nedeniyle ortaya

çıkılmaktadır. Burada 1000 veri kümesine ait etkinlik skorları ortalaması verisi [0.8, 1] aralığında doğrusal ölçekte her bir veri kümesi bir yarıçap çizgisi üzerinde görselleştirilmiştir.

Şekil 18’de sunulan daire grafiğın sol yarısı PÖS destekli ağırlık kısıtlı VZA etkinlik skorları ortalamasının SDA destekli ağırlık kısıtlı VZA etkinlik skorları ortalamasından büyük ya da eşit olduđu deney bulgularını gösterirken, daire grafiğının sađ yarısı ise SDA destekli ağırlık kısıtlı VZA etkinlik skorları ortalamasının PÖS destekli ağırlık kısıtlı VZA etkinlik skorları ortalamasından büyük ya da eşit olduđu deney bulgularını göstermektedir. Daire grafiğinin alt bölümündeki mor çizgi her iki algoritmanın da VZA’nın ayrıştırma gücünde denk iyileştirme yapabildiđi ve herhangi bir yöntemin diđerine üstünlük sağlayamadıđı deneyleri göstermektedir.

Simülasyon bulgularına göre PÖS destekli ağırlık kısıtlı VZA, 1000 deneyin 372’sinde SDA destekli ağırlık kısıtlı VZA’dan daha büyük ortalama etkinlik skoru üreten modellere kılavuzluk ederken 1000 deneyin 408 tanesinde ise SDA destekli ağırlık kısıtlı VZA, PÖS destekli ağırlık kısıtlı VZA’dan daha büyük ortalama etkinlik skoru üreten modellere kılavuzluk etmiştir. Kalan 220 deneyde her iki yöntem denk sonuçlara kılavuzluk etmiştir.



**Şekil 19:** 1000 Veri Kümesi için Etkin KVB Sayıları

Şekil 19'da standart VZA'ya, PÖS destekli ağırlık kısıtlı VZA'ya ve SDA destekli ağırlık kısıtlı VZA'ya ait veri sırasıyla sarı, mavi ve kırmızı renk kodları ile temsil olunmaktadır. Mor renk ise mavi ve kırmızı renklerin kesişimi nedeniyle ortaya çıkmaktadır. Burada 1000 veri kümesine ait etkin KVB sayıları verisi  $[0, 30]$  aralığında doğrusal ölçekte her bir veri kümesi bir yarıçap çizgisi üzerinde görselleştirilmiştir.

Şekil 19'da sunulan daire grafiğın sol yarısı PÖS destekli ağırlık kısıtlı VZA etkin KVB sayılarının SDA destekli ağırlık kısıtlı VZA etkin KVB sayılarından büyük ya da eşit olduđu deney bulgularını gösterirken, daire grafiğının sađ yarısı ise SDA destekli ağırlık kısıtlı VZA etkin KVB sayılarının PÖS destekli ağırlık kısıtlı VZA etkin KVB sayılarından büyük ya da eşit olduđu deney bulgularını göstermektedir.

Daire grafiğinin alt bölümündeki mor çizgi her iki algoritmanın da VZA'nın ayrıştırma gücünde denk iyileştirme yapabildiği ve herhangi bir yöntemin diğerine üstünlük sağlayamadığı deneyleri göstermektedir.

Simülasyon bulgularına göre PÖS destekli ağırlık kısıtlı VZA, 1000 deneyin 322'sinde SDA destekli ağırlık kısıtlı VZA'dan daha çok sayıda etkin KVB belirleyen modellere kılavuzluk ederken 1000 deneyin 345 tanesinde ise SDA destekli ağırlık kısıtlı VZA, PÖS destekli ağırlık kısıtlı VZA'dan daha çok sayıda etkin KVB belirleyen modellere kılavuzluk etmiştir. Kalan 333 deneyde her iki yöntem denk sonuçlara kılavuzluk etmiştir.

**Tablo 17:** 1000 Veri Kümesi için Analiz Bulguları

Betimsel İstatistikler	Etkin KVB Sayısı			Etkinlik Skor Ortalaması		
	VZA	PÖS	SDA	VZA	PÖS	SDA
<b>Ortalama</b>	29.08665	9.41634	9.49701	0.99947	0.89700	0.89897
<b>Standart Sapma</b>	0.97089	1.97743	1.99326	0.00087	0.02365	0.02382
<b>En Küçük Değer</b>	25	4	4	0.99212	0.81395	0.81571
<b>En Büyük Değer</b>	30	17	17	1	0.96463	0.96363

Tablo 17'de 1000 veri kümesi için standart VZA etkin birim sayısı ortalaması yaklaşık 29; PÖS destekli ağırlık kısıtlı VZA etkin birim sayısı ortalaması yaklaşık 9.4 ve SDA destekli ağırlık kısıtlı VZA etkin birim sayısı ortalaması yaklaşık 9.5'tir. Aynı sıra ile 1000 veri kümesi için etkinlik skorlarının ortalaması ise standart VZA için 0.999; PÖS destekli ağırlık kısıtlı VZA için 0.897; SDA destekli ağırlık kısıtlı VZA için ise 0.899 olarak hesaplanmıştır.

#### 4.4. DERİN ÖĞRENME DESTEKLİ VERİ ZARFLAMA ANALİZİNDE AYRIŞTIRMA GÜCÜ İYİLEŞTİRME ARAŞTIRMASININ SONUÇLARI

Tez çalışmasının bu alt bölümünde genel bir üretim fonksiyonu modelinin yorumlanması ile VZA girdilerinin VZA çıktısını tahminde görelî etkileri marjinal dönüşüm hızı yerine kullanılarak nesnel bir ağırlık kısıtlı VZA modeli üretme prosedürü tanımlanmıştır. Prosedürün amacı, VZA'da ağırlık belirleme serbestisi



kaynaklı düşük ayırt etme gücü sorunsalını gidermek ya da iyileştirmektir. Bunun için tek veri kümesi üzerinden gerçekleştirilen 3 fazlı deneyde elde edilen sonuçların genellenebilir olduğunu göstermek adına 1000 ayrı veri kümesi üzerinden PÖS ve SDA yöntemlerinden destek alarak oluşturulan ağırlık kısıtlı VZA modelleri bir simülasyon analizi olarak ele alınmıştır.

Bölüm 4.2'de ve Bölüm 4.3'te ağırlık kısıtlarına kılavuzluk etmek üzere iki ayrı makine öğrenmesi modellerini yorumlama yöntemi kullanılmış ve analiz bulguları özetlenmiştir. Sunulmuş olan bulgulara dair yorum ve tartışmalar, bu alt bölümde başlıklar halinde organize edilmiştir.

#### **4.4.1. Girdi Pertürbasyonu ile Öznitelik Sıralama Algoritması ve Shapley Değerleri Algoritmasının Karşılaştırması**

PÖS, özniteliklerin görece önemini tüm gözlemler için eşanlı bir etkiyi inceleyerek değerlendiren bir algoritmadır. Tüm model sonuçları için tek bir genel önem sıralaması vermesi bakımından da avantajlara sahip olan bu yöntemin iki ana dezavantajı vardır. Bunlardan ilki korele özniteliklerin varlığında ortak bilginin model için korunması nedeniyle öznitelik öneminin olduğundan düşük hesaplanma sorunsalı iken ikincisi de özniteliklerde bozunum için kullanılan geleneksel yöntem olan rassal yeniden dağıtımın (bkz. Heaton, 2018, Heaton vd., 2017, Olden vd., 2004) özellikle gözlem sayısı az olan durumlarda öznitelikler arasında denk olmayan bozunumlara yol açarak hatalı yorumlara yol açma olasılığıdır. Bölüm 4.2.4'te anlatılan optimizasyonla yeniden dağıtım iyileştirmesi, PÖS'ün ikinci dezavantajını ortadan kaldırarak yöntemin kararlı yorumlar üreten robust bir versiyonunu üretmiştir. İlk dezavantaj ile ilgili olarak da kurulan ve PÖS ile yorumlanmaya çalışılan model VZA verisi ile çalıştırıldı; VZA verisinin kendi içerisinde bir üretim olanakları kümesi varsayımı ile üretilen miktarlar ve üretim sürecinde tüketilen miktarlar sınıflandırmasına tabi tutularak girdi kriterleri ve çıktı kriterleri olarak ayrıştırıldı; ve makine öğrenmesi yönteminde yalnızca VZA girdi kriterleri öznitelik olarak alındığı ve bu sayede girdi-çıkı korelasyonu sistemden arındırıldı; değerlendirilerek dikkate alınmamıştır.

Öte yandan SDA; her bir gözlem için ayrı ayrı özniteliklerin model çıktısına katkılarını tanımlayan bir yöntemdir. Dolayısıyla genel bir öznitelik önem bilgisine ulaşmak adına yerel öznitelik katkıları mutlak değerleri alınıp her bir öznitelik için ortalamaları hesaplanarak birleştirilmiştir. Şekil 13'te verilen SDA özet grafiği, öznitelikler için yerel katkıların ve bu yerel katkıların ilgili özniteliğin değerine göre aldığı değerlerin renk kodu ile temsil edildiği bir görsel özetdir. Şekil 13'te bazı yerel katkı değerlerinin, özellikle de ilgili öznitelik düşük değerliyen, negatif değerli olduğu görülmektedir. Bu durum, yerel katkının tanımından kaynaklıdır; yerel katkı ilgili özniteliğin bilgisinin model çıktısını (VZA çıktı kriteri değerinin tahmini) naive değerden (ortalama değer, vb.) ne kadar saptırdığıdır. Diğer bir ifade ile Şekil 13'e göre tüm öznitelikler VZA çıktı kriterinin değeri ile doğru orantılı olarak modellenmiştir ve özniteliklerin düşük değerli olması tahminlenen değerlerin ortalamadan düşük olması sonucunu doğurmaktadır.

SDA yerel öznitelik katkı değerlerini hesaplariken tüm dizilim ve sıra olasılık uzayının makul bir alt kümesinden yola çıkmaktadır ve bu nedenle belli bir hata marjı içerebilmektedir. Ayrıca genel öznitelik önem bilgisi için kullanılan yöntem yine SDA'nın varsayımlarından olan toplamsallığın (bkz. Lundberg ve Lee, 2017) bir devamı olarak L1 uzaklığı olarak seçilmiştir. Ancak; bu yaklaşımın iki olası zayıflığı vardır. Bunlar sırasıyla uç değerlerin SDA yorumu üzerinde yanıltıcı etki yapma olasılığı ve genel öznitelik önem fonksiyonunda tüm gözlemlerin eşit ağırlıkta birleştirilmesinin gürültülü veride temsil ediciliği düşük gözlemlerin SDA yorumunu bozma olasılığıdır (Slack ve diğerleri, 2020). Ayrıca yine PÖS'teki gibi SDA da korele özniteliklerin varlığında yanıltıcı olabilmektedir. Korele özniteliklerin varlığına dair PÖS için yapılan savunma SDA için de geçerlidir ve bu nedenle bu zayıf yön önemsizmemiştir. Uç değerlerin varlığında kareli (quadratic) veya daha üst dereceli polinom fonksiyonu içeren uzaklık hesaplamaları daha dramatik yorum hatalarına yol açabilecektir ve bu bakımdan L1 uzaklığı bu olumsuzluğun olası etkilerinin en aza indirilmesi için uygun bulunmuştur. SDA'nın ikinci olası zayıf yönü değerlerlendirilecek olursa; bu tez çalışmasındaki uygulamada veri bir CD üretim fonksiyonu ile türetilmiştir. Parametrik yapısallığa tabi olan bu veri VZA üretim olanakları kümesinin serbest

atılabilirlik aksiyomu bakımından güçlü bir temsili değildir. Bu aksiyoma göre KVB'ler daha çok girdi tüketerek aynı miktar çıktılarını üretebilecek ya da aynı miktarda girdiyi tüketerek daha az çıktı üretebileceklerdir (Charnes vd., 1978; Zhu, 2015, s.68). Bu aksiyomun iyi temsil edildiği veri; VZA çıktı kriterlerini VZA girdi kriterleri dışında bilinmeyen ve modelde yer almayan özneliliklerle modellediği için yapısal olarak gürültü içermektedir. Diğer bir ifade ile etkin sınırdaki yer almayan gözlemlerin modelde kullanılması sakıncalıdır. Tez uygulamasında, 30'ar KVB içeren veri kümelerinde ortalama etkin KVB sayısı 29'dan büyük olduğu için bu olumsuz yan önemli görülmemiştir.

PÖS ve SDA genel öznelilik önemi elde etmede karşılaştırılacak olursa;

- Temel olarak SDA yerel öznelilik katkılarının (önem) hesaplanması için tasarlanmış ve genel öznelilik önemlerinin yorumlanabilmesi için uyarlanabilen bir yöntemken PÖS, doğrudan genel öznelilik önemlerinin değerlendirilmesine yönelik bir yöntemdir.
- SDA öznelilik bilgisinin diğer öznelilik bilgilerinin çeşitli dizilimleri ve ilgili öznelilik bilgisinin kaçınıcı sırada modele sunulduğuna göre çok sayıda deneyden özneliliğin model sonucuna katkısını hesaplarken PÖS, son sırada ilgili öznelilik bilgisinin modele sunulduğu ve diğer öznelilik bilgilerinin modele sunulduğu diziliminin belirsiz olduğu tek bir deneyden çıkarımlar üretmektedir.
- SDA için kullanılan Lundberg ve Lee (2017) algoritması yaklaşık değerlerin hesaplanması bakımından hata marjı içerebilmekte (belirli aralıkta farklı sonuçlar üretebilmekte) (Geada, 2022) ancak; bu tez çalışmasında önerilmiş optimizasyona dayalı yeniden dağıtımla PÖS kararlı sonuçlar üretmektedir.
- PÖS destekli ağırlık kısıtlı VZA ve SDA destekli ağırlık kısıtlı VZA yöntemlerinin her ikisinde de VZA'nın doğasını korumak adına ağırlık belirleme serbestisini yalnızca ordinal kriter önem bilgisi ile sınırlandırılmıştır. Bu sınırlandırma genel bir üretim fonksiyonu modellemesine dayandırılmış ve ağırlık belirleme serbestisi KVB'lerin

kendilerine has doğalarından gelen ağırlık uyarlamalarını engellemek adına kardinal önem bilgileri ile ağırlık kısıtları formüle edilmemiştir.

#### **4.4.2. Veri Zarflama Analizinde Ayırt Etme Gücünün Artırılması Bakımından PÖS Destekli Ağırlık Kısıtlı VZA ve SDA Destekli Ağırlık Kısıtlı VZA**

Açıklanabilir yapay zeka yaklaşımları olarak PÖS'ün ya da SDA'nın daha doğru ya da daha üstün yöntemler olduğu tartışması bu tezin kapsamında yer almamaktadır. Ancak; simülasyon uygulamasında genel olarak PÖS destekli ağırlık kısıtlı VZA yönteminin daha düşük ortalama etkinlik skorları üretebildiği, daha az sayıda etkin KVB belirleyebildiği ve değişkenliği daha az, daha kararlı biçimde VZA'nın ayırt etme gücünü iyileştirdiği gözlemlenmiştir. Ayrıca iki ayrı yöntemin çeşitli KVB'ler için farklı etkinlik skorları hesaplanmasına ve farklı KVB'lerin etkin ya da etkin olmayan biçiminde sınıflandırılmasına zemin hazırladığı gözlemlenmiştir. Bu bakımdan iki ayrı yöntem bu tez çalışması kapsamında iki ayrı "uzman görüşü" olarak değerlendirilmektedir.

Bu iki ayrı makine öğrenmesi yorumlama algoritması kullanılarak elde edilen sonuçlar arasında farklılıkların düzeni ifade etmek adına yapılan korelasyon analizi sonucunda tüm deneylerde PÖS destekli ağırlık kısıtlı VZA etkinlik skorları ile SDA destekli ağırlık kısıtlı VZA etkinlik skorları arasındaki doğrusal korelasyon (*Pearson product moment correlation*) 0.608 iken sıra korelasyonu da (*Spearman rank correlation*) 0.505 olarak hesaplanmıştır.

VZA'da ayırıştırma gücünün ele alındığı tezin bu bölümünde KVB'lerin etkinlik skorları aracılığıyla sıralanması daha önemli bir odak olarak değerlendirilebilir. Bu nedenle PÖS ve SDA destekli ağırlık kısıtlı VZA yöntemleri arasındaki benzerlik ya da fark ilişkisini sıra korelasyonu üzerinden açıklamak daha makul bir tercih olarak görülmüştür. Yaklaşık 0.5 olarak hesaplanan sıra korelasyonu iki yöntemin genel olarak birbirine çok aykırı düşmeyen ancak çok da benzemeyen etkinlik skorlarının hesaplanmasına kılavuzluk ettiği biçiminde yorumlanabilir.

#### 4.4.3. Tartışma ve Öneriler

Standart VZA modelinde VZA girdi kriterleri ağırlıklarına ve VZA çıktı kriterleri ağırlıklarına her bir KVB için farklı bir değer kompozisyonu atanabilmektedir. Burada her bir KVB'nin mümkün olan en yüksek etkinlik skoruna ulaşacağı biçimde serbesti ile belirlenen ağırlıklar bir yandan KVB'lerin kendilerine has üretim koşullarını temsil ederek performansın düşük ölçümünü engellemekte bir yandan da bazı kriterlerin VZA'da neredeyse değerlendirilmeksizin performansın yüksek ölçülmesine yol açabilmektedir. Bu halde de gerçekte çok önemli olmayan kriterlerin fazla ağırlıklandırılması sonucu performansın yanıltıcı hesaplanmasına neden olabilmektedir.

Tez çalışmasında, homojenite aksiyomuna dayanılarak KVB'lerin kendilerine has üretim olanakları farklılıklarının ihmal edilebileceği ve benzer üretim yöntemlerinde benzer girdiler kullanarak benzer çıktılar üretecekleri (Pedraja ve diğerleri, 1997) ve bu nedenle genel bir üretim fonksiyonu modelinin tüm KVB'ler için, derin öğrenme modellerinin performans metriklerine dayanılarak, temsil gücünün yüksek olduğu varsayılmıştır. Böylece açıklanabilir yapay zeka yöntemleri ile desteklenerek kurulan ağırlık kısıtlı VZA modelleri ağırlık serbestisi kaynaklı olumsuzlukları giderebilmekte ya da azaltmaktadır. Ağırlık serbestisinin olumlu katkısı olarak performans düşük ölçümünün önlenmesi ise öznitelik önem bilgisinin yalnızca ordinal bilgi kapsamında ağırlık kısıtlı VZA'ya aktarılması yolu ile sınırlandırılmış bir ağırlık serbestisi biçiminde korunmuştur. Bu varsayımın olmadığı hallerde PÖS'ün kullanımı ve SDA'nın yerel öznitelik önemlerinin genel öznitelik bilgisi için birleştirilmesi uygun olmayacaktır. İlave olarak bu tez çalışmasının SDA'nın yerel öznitelik katkılarını değerlendirerek bu varsayımın yokluğunda SDA destekli ağırlık kısıtlı VZA yöntemine yönelik bir çalışmaya ışık tutacağı değerlendirilebilir.

Ayrıca bu tez çalışmasında veri türetimi parametrik yöntemlerle yapılmıştır ve bunun sonucunda veride gürültü yoktur. Serbest atılabilirlik aksiyomunun temsil edildiği veri kümelerinde yalnızca etkin sınırdaki KVB'ler ile beslenen PÖS ya da

SDA kılavuzluğunda formüle edilen ağırlık kısıtlarının ve ortaya çıkan performans ölçümlerinin tüm verinin kullanıldığı bir uygulamaya göre farklılaşıp farklılaşmadığı da sonraki çalışmaların bir konusu olabilecektir.

## SONUÇ

20. yüzyılın sonları ve 21. yüzyılda veri aktarımı ve veri işleme yeteneklerindeki üstel eğilim, istek ve taleplere yönelik süreç hacimlerinde de aynalanmıştır. Ancak; zaman ve diğer kaynaklardaki kısıtlılık azalmamış aksine bu hacim artışıyla beraber daha da kritik hale gelmiştir. Bu olguları performans analizleri ve buna bağlı doğal seçimler izlemiştir. Girdi (kaynak) kullanım etkinliğini bir anlamda engelleyerek etkinsiz üretim yapan birimlerin elenmesi zamanın gereklerine uymanın tek koşulu haline gelmiştir. Bu nedenle yarım yüzyıldır performans ölçümünde en yaygın ve en çok kabul gören yöntemlerden biri olan Veri Zarflama Analizinin işlem verimliliği daha yüksek olan Yapay Sinir Ağları vb. makine öğrenmesi teknikleriyle desteklenmesi ya da değiştirilmesi arayışına yönelinmiştir. Bu tez çalışması kapsamında bu arayışlar Veri Zarflama Analizini desteklemek üzere farklı açılardan ele alınarak değerlendirilmiş ve Veri Zarflama Analizine bu modern tekniklerin keşfedilen yeni bir faydası tanıtılmıştır.

Bu tez çalışması Yapay Sinir Ağları ve Veri Zarflama Analizinin beraber kullanıldığı araştırmaları inceledikten sonra ana akım olan VZA etkinlik skorlarının ya da etkinlik sınıflarının kestirimi yerine son derece az çalışmanın olduğu YSA'nın VZA'ya diğer olası katkılarının araştırıldığı alana yönelmiştir. Makine öğrenmesi literatürünün konvansiyonel sınırlarını çığır açıcı yöntemlerle genişleten güncel odaklardan biri, model çıktılarını üretmekte model girdilerinin (özniteliklerin) görelî paylarını açıklayabilen araçlardır (makine öğrenmesi yorumlama algoritmaları). Makine öğrenmesi yorumlama algoritmalarını YSA ile birleştirmek düşüncesi de "VZA'da ayrıştırma gücünü iyileştirmede YSA nesnel bir kılavuz olarak kullanılabilir mi?" sorusunu doğurmuştur.

Bu tez çalışmasının uygulama bölümü "VZA'da ayrıştırma gücünü iyileştirmede YSA nesnel bir kılavuz olarak kullanılabilir mi?" araştırma sorusuna yöneliktir. Bu

araştırmanın bulguları ve bu bulgulara dair ön değerlendirmeler Bölüm 4.4'te sunulmuştur. Tezin bu son bölümünde ise araştırma bulgularına ve sonuçlarına dair nihai yorumlar sunulmuş, çalışmanın literatüre katkıları ve önemi vurgulanmış ve sonraki araştırmalara yön verebilecek tartışma ve öneriler sıralanmıştır.

Bölüm 4'te gerçekleştirilen VZA'da ayrıştırma gücünü derin öğrenme yöntemleri üzerinden iyileştirme araştırmasında Yapay Sinir Ağları ve yorumlanabilir makine öğrenme algoritmalarının birlikte kullanımı ile üretilen VZA kriterlerine dair nesnel önem ilişkilerinin, standart VZA'nın gözlemler arasında hiçbir ayrıştırma yapamadığı hallerde bile, önemli ayrıştırma gücü iyileştirmesi sağlayabildiği sonucuna varılmıştır. Ayrıca, mevcut ağırlık kısıtlı VZA literatüründe henüz hiç kullanılmamış bir nesnel kriter önem ilişkisi kaynağı literatüre kazandırılmış ve bu kaynağı üretmek üzere önerilen iki ayrı yöntem için genellenebilirlik araştırılmış ve yapılan 1000 deneyle simülasyon analizi ile bu yöntemlerin kararlı yapıda ayrıştırma gücünde iyileştirme sağlayabildiği deneyimlenmiştir.

Bu tez çalışmasının uygulama bölümü; VZA'nın zayıf yönlerinden olan düşük ayrıştırma gücü sorunsalı için YSA ve yorumlanabilir makine öğrenme algoritmaları destekli çözüm yöntemlerini keşfetmek ve genellenebilirlik bakımından test etmek üzerinedir. Uygulama içinde yer bulan araştırmalar sonucunda kullanılabilir iki ayrı genellenebilir yöntem önerilmiştir. Bu araştırmaların ve bulgularının önemi;

- Ayrıştırma gücünü artırmak üzere; tüm KVB'ler için ayrıştırma gücü iyileştirilmiş model üzerinden etkinlik skorlarını eksiksiz hesaplayabilmesi bakımından tam bir yaklaşım sunan ağırlık kısıtlı VZA'da nesnel bilgi kaynaklarının sınırlılığı veya erişilebilir olmayışı sorunsalına yalnızca VZA kriterleri verisini kullanarak veri temelli ve nesnel bilgi üretebilen yeni bir kaynağın önerilmesi,
- Bu öneriyi oluşturmakta kullanılan makine öğrenmesi yorumlama algoritmalarının ilk defa YSA-VZA literatürüne sunumu ve böylece



açıklanabilir yapay zeka disiplinleri ile performans analizi disiplinlerinin birlikteliği üzerine bir araştırma alanı yaratılması,

- Makine öğrenmesi yorumlama algoritmalarından PÖS'ün genelde düşük kardinaliteli veri kümeleri üzerinden gerçekleştirilen VZA vb. uygulamalarına uyumlandırılacak biçimde ve ürettiği öznitelik önemlerinde gözlemlenebilecek değişkenliğin sıfır düzeyine indirgenerek geliştirilmesi,
- VZA'nın temel dayanaklarından olan homojenite kabulü üzerinden bir genel üretim fonksiyonunun modellenebilirliğinin tartışılması ve çok sayıda gözlem üzerinden sınanarak onaylanması

katkılarından kaynaklanmaktadır. Bu genel nesnel bilgi kaynağı YSA üzerinden *marjinal-dönüşüm-hızı-benzeri* bilgilerin veri kümeleri için türetilirliğinin gösterimi ile sağlanmış ve ayrıştırma gücüne tam ve objektif bir çözüm sunmuştur.

Bu tez çalışması içerisinde gerçekleştirilen araştırmalara dair tartışma ve öneriler 3 grupta sunulmaktadır;

**Genel üretim fonksiyonu modeli üzerine:** Üretim olanakları kümesinin temel aksiyomlarından olan homojeniteye göre KVB'ler aynı türden girdileri kullanarak aynı türden çıktıları benzer yöntemlerle üretirler. Üretimin benzer yöntemlerle gerçekleştirilmesi genel bir üretim fonksiyonunun modellenebilirliği konusunda ilham kaynağı olmuştur. Genel üretim fonksiyonunun VZA girdi kriterleri ile VZA çıktı kriterlerindeki değişkenliği açıklama gücü ne kadar yüksekse veri kümesinin o kadar benzer yöntemler kullanan gözlemlerden oluştuğu savunulabilir. Bu bakımdan genel üretim fonksiyonu modelinin başarımlı gücü homojenitenin test edilmesinde bir araç olarak değerlendirilmektedir.

Genel üretim fonksiyonu modellenirken eldeki tüm VZA verisi kullanılmaktadır. VZA'nın KVB sayısı bakımından eksiksiz veri ile gerçekleştirilen bir teknik olması; bir genel üretim fonksiyonu modellenirken aşırı öğrenmenin ihmal edilebilirliğini düşündürmektedir. Aşırı öğrenme olgusunu ele almak isteyen araştırmacılara

VZA veri kümelerinin genelde büyük hacimli olmaması gerekçesi ile KÇD'nin özel bir türü olan *Leave One Out Cross Validation (LOOCV)* algoritması önerilebilir. Bu algorithmada K, veri kümesinin kardinalitesine eşittir.

Bölüm 4'te standart VZA için ayrıştırma gücünün olmadığı (tüm birimlerin etkin bulunduğu) bir örnek üzerinden çalışma başlatılmıştır. Üretim olanakları kümesinin serbest atılabilirlik aksiyomu gereği etkinsiz KVB'lerin yer aldığı bir veri kümesi YSA terimleri cinsinden tanımlandığında "gürültü" içeren bir veri kümesidir. Bu gürültünün giderilmesi model başarımını ciddi biçimde etkileyecektir ve dolayısıyla genel üretim fonksiyonu modellenirken etkin sınır üzerinden veya neredeyse etkin KVB'leri içeren bir öğrenme kümesinin tercih edilmesi akla yatkındır. Sonraki çalışmalarda genel üretim fonksiyonu model başarımına gürültünün etkisi incelenebilir.

***Makine öğrenmesi yorumlama algoritmaları üzerine:*** Homojenitenin ima ettiği üretim tarzı benzerliğinin bir diğer boyutu da girdi kullanım oranlarının benzerliği olabilir. Genel üretim fonksiyonu modeli ile makine öğrenmesi yorumlama algoritmalarını birleştirerek elde edilen öznitelik (VZA girdi kriteri) önem bilgileri, veri kümesi içerisinde alınan örneklemeler arasında yüksek değişkenlik gösteriyorsa bu durum veri kümesinin heterojen gözlemlerden oluştuğu biçimde yorumlanabilir. Ancak; tamamen aynı üretim fonksiyonuna tabi KVB'ler çıktı üretiminde birbirlerinden farklı girdileri baskın olarak kullandığında iki ayrı KVB için çıktı düzeyini farklı VZA girdi kriterlerinin açıklıyor olacağı açıktır. Bu halde homojeniteye aykırılığı düşünmek tartışmaya açıktır.

Bu tez çalışmasında VZA ayrıştırma gücünü iyileştirmede kullanılan nesnel bilgi, genel üretim fonksiyonu modeli için global öznitelik önem bilgisidir ve bu bilgi ağırlık kısıtlı VZA'da VZA girdi kriterleri için ordinal önem ilişkileri olarak aktarılmıştır. Ordinal ilişki kısıtlarının seçimi, VZA'nın ağırlık belirleme serbestisi ruhunu genel bir kural üzerinden aşırı kısıtlamadan ayrıştırma gücünü iyileştirebilecek makul bir sınırlama getirme mantığına dayanmaktadır. Ağırlık belirleme serbestisi, her bir KVB için en yüksek etkinlik skorunu hesaplayarak

kendine has ağırlık birleşiminin belirlenmesi olarak ifade edilebilir. Genel üretim fonksiyonu modeli üzerinden her bir KVB için türetilen yerel öznitelik önem bilgileri, her bir KVB için kendine has ağırlık sınırlandırımı formülasyonunda kullanılabilir. Bu durumda ordinal ilişkiler yerine kardinal ilişki kısıtlarının yazımının aşırı sınırlandırıcı olmayacağı savunulabilir. Gelecek çalışmalarda Ribeiro vd.'nin (2016) LIME (*Local Interpretable Model-agnostic Explanations*) ya da Shapley Değerleri algoritmalarının yerel öznitelik önem bilgisi türetiminde kullanılarak VZA ayrıştırma gücüne katkısı araştırılabilir.

VZA ayrıştırma gücü üzerine yoğunlaşan araştırmada önerilen yöntemlerden biri, girdi pertürbasyonu ile öznitelik sıralama (PÖS) algoritmasını kullanmaktadır. Standart hali ile PÖS'te, her bir öznitelik vektörünün rassal yeniden dağıtım ile bozunuma uğratılırken diğer verinin aynen korunduğu öznitelik sayısınca veri kümesi için model başarımlarının orijinal model başarımları ile karşılaştırmasına dayanmaktadır. Rassal dağıtımın olasılık uzayında çok iyi bozunmuş vektörler olabileceği gibi iyi korunmuş vektörler de vardır ve  $N$  gözlemlili bir veri kümesi için olasılık uzayı  $N!$  farklı vektör içermektedir.  $N$  küçüldükçe özniteliklerin denk bozunuma uğramama olasılığı artmaktadır ( $N$  büyük olsa bile bu olasılık hiçbir zaman 0 değildir). Dengesiz bozunumlar özniteliklerin göreceli önemlerine dair yanıltıcı yorumlara neden olabileceğinden bu çalışmada PÖS'ün optimizasyon temelli yeniden dağıtım ile yapılan daha üstün bir versiyonu önerilmiştir. VZA, genel olarak düşük kardinaliteli veri kümelerinde uygulanan bir teknik olduğundan PÖS'ün bu yeni versiyonunun VZA için en uygun uyarlama olduğu değerlendirilmektedir. Ancak; önerilen yöntemde kurulan optimizasyon modeli bir karma tamsayı ve kareli kısıtlı programlama problemidir. Son derece yüksek hesaplama maliyeti olan bu model,  $N$  büyüdükçe çözülebilirliğini yitirebilecektir. Bu yöntemi büyük  $N$  değerlerine sahip veri kümelerinde kullanmak isteyen araştırmacıların PÖS içerisindeki optimizasyon problemlerini meta-sezgisel yöntemlerle çözmesi önerilmektedir.

Ayrıca bu tez çalışmasında PÖS algoritmasının konvansiyonel olarak yitim fonksiyonu üzerinden değerlendirme yaklaşımı uygulanmıştır. Yitim

fonksiyonuna alternatif oluşturabilecek diğer model başarımlarına göre olası sıralamaların yitim fonksiyonuna göre sıralama ile uyumlu olduğu ancak; bu durumun istisnaları olduğu gözlemlenmiştir. Yitim fonksiyonu ya da  $R^2$  üzerinden sıralamanın, diğer nesnel bilgi kaynaklarının varlığında diğer nesnel bilgilerle uyumunun karşılaştırması gelecek bir araştırmanın konusu olabilecektir.

Bu tez çalışmasında VZA ayrıştırma gücünü derin öğrenme ve makine öğrenmesi yorumlama algoritmaları ile iyileştirmenin iki yöntemi önerilmiş ve bu yöntemlerin genellenebilirliği bir simülasyon analizi ile test edilerek onaylanmıştır. Bu yöntemlerin güvenilirlik araştırmasını, gerçek hayattan ve farklı alanlardan edinilen veri kümeleri üzerinden denemelerle, genişletmek sonraki araştırmalara konu olarak önerilmektedir.

***Literatür ana akımı ile bu araştırma arasında homojenite varsayımına dair olası bağlantılar:*** VZA etkinlik skorlarının tahminlenmesi için VZA-YSA literatüründe sunulan motivasyonlardan biri de büyük ölçekli veri kümelerinde performans analizi arayışıdır. Bir genel kabul olarak veri hacmi büyüdüğünde üretim olanakları kümesi aksiyomlarından homojenitenin ihlal edileceği varsayılmakta ancak; bu varsayım uygulamada nadiren test edilmektedir. Homojenitenin test edilebilmesi için; genel üretim fonksiyonu model başarımlarını cinsinden ve elde edilen veriden alınan farklı örneklem için makine öğrenmesi yorumlama algoritmaları ile türetilen öznel önem bilgisindeki değişkenlik cinsinden iki ayrı araç tanımlanabileceği tartışılmıştır.

Veri hacminden bağımsız olarak zamansal veya mekansal olarak tam veriye erişim olanağı olmayan hallerde, verinin sonradan eklenen örneklem halinde birikeceği açıktır. Bu durumda sonradan edinilebilen veri örneklemelerinin homojenite testi yine bu tez çalışmasında tartışılan yöntemlerle gerçekleştirilebilir.

YSA ile VZA etkinlik skorlarını tahminleyen modellerin yalnızca homojenitenin sağlandığı verilerde kullanılması gerekmekte ve homojenite testinin VZA-YSA

literatüründe önemli bir yeri olması gerektiği açıktır. Literatürde henüz açık halindeki bu alana dair çalışmaların artırılması, bu tez çalışmasının son önerisidir.

## KAYNAKÇA

- Adler, N., & Golany, B. (2001). Evaluation of deregulated airline networks using data envelopment analysis combined with principal component analysis with an application to Western Europe. *European Journal of Operational Research*, 132(2), 260-273.
- Adler, N., & Golany, B. (2002). Including principal component weights to improve discrimination in data envelopment analysis. *Journal of the Operational Research Society*, 53(9), 985-991.
- Adler, N., & Yazhemsy, E. (2010). Improving discrimination in data envelopment analysis: PCA–DEA or variable reduction. *European Journal of Operational Research*, 202(1), 273-284.
- Agarap, A. F. (2018). Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*.
- Alain, G., & Bengio, Y. (2016). Understanding intermediate layers using linear classifier probes. *arXiv preprint arXiv:1610.01644*.
- Allen, R., A. Athanassopoulos, R.G. Dyson, and E. Thanassoulis. (1997). "Weights restrictions and value judgements in data envelopment analysis: Evolution, development, and future directions." *Annals of Operations Research*. Vol. 73.
- Alpaydın, E. (2004). *Introduction to Machine Learning (Adaptive Computation and Machine Learning Series)*. The MIT Press.

- Andersen, P., & Petersen, N. C. (1993). A procedure for ranking efficient units in data envelopment analysis. *Management science*, 39(10), 1261-1264.
- Asi, H., Duchi, J., Fallah, A., Javidbakht, O., & Talwar, K. (2011, July). Private adaptive gradient methods for convex optimization. In *International Conference on Machine Learning* (pp. 383-392). PMLR.
- Athanassopoulos, A. D., & Curram, S. P. (1996). A comparison of data envelopment analysis and artificial neural networks as tools for assessing the efficiency of decision making units. *Journal of the operational research society*, 47(8), 1000-1016.
- Atıcı, K. B., Ulucan, A., & Bayar, I. U. (2018). The measurement of agricultural productivity change in OECD countries with Fuzzy data. *RAIRO-Operations Research*, 52(3), 1003-1017.
- Azadeh, A., Amalnick, M. S., Ghaderi, S. F., & Asadzadeh, S. M. (2007). An integrated DEA PCA numerical taxonomy approach for energy efficiency assessment and consumption optimization in energy intensive manufacturing sectors. *Energy policy*, 35(7), 3792-3806.
- Azadeh, A., Ghaderi, S. F., Mirjalili, M., & Moghaddam, M. (2011). Integration of analytic hierarchy process and data envelopment analysis for assessment and optimization of personnel productivity in a large industrial bank. *Expert Systems with Applications*, 38(5), 5212-5225.
- Azadeh, A., Saberi, M., & Anvari, M. (2010). An integrated artificial neural network algorithm for performance assessment and optimization of decision making units. *Expert systems with applications*, 37(8), 5688-5697.

- Azadeh, A., Saberi, M., Anvari, M., & Mohamadi, M. (2011). An integrated artificial neural network-genetic algorithm clustering ensemble for performance assessment of decision making units. *Journal of intelligent manufacturing*, 22(2), 229-245.
- Banker, R. D. (1984). Estimating most productive scale size using data envelopment analysis. *European journal of operational research*, 17(1), 35-44.
- Banker, R. D., Charnes, A., & Cooper, W. W. (1984). Some models for estimating technical and scale inefficiencies in data envelopment analysis. *Management science*, 30(9), 1078-1092.
- Banker, R. D., Gadh, V. M., & Gorr, W. L. (1993). A Monte Carlo comparison of two production frontier estimation methods: Corrected ordinary least squares and data envelopment analysis. *European Journal of Operational Research*, 67(3), 332-343.
- Bishop, C. M. (1995). *Neural networks for pattern recognition*. Oxford university press.
- Carvalho, A. R., Ramos, F. M., & Chaves, A. A. (2011). Metaheuristics for the feedforward artificial neural network (ANN) architecture optimization problem. *Neural Computing and Applications*, 20(8), 1273-1284.
- Charles, V., Aparicio, J., & Zhu, J. (2019). The curse of dimensionality of decision-making units: A simple approach to increase the discriminatory power of data envelopment analysis. *European Journal of Operational Research*, 279(3), 929-940.



- Charnes, A., Cooper, W. W., & Rhodes, E. (1978). Measuring the efficiency of decision making units. *European journal of operational research*, 2(6), 429-444.
- Charnes, A., Cooper, W. W., Golany, B., Seiford, L., & Stutz, J. (1985). Foundations of data envelopment analysis for Pareto-Koopmans efficient empirical production functions. *Journal of econometrics*, 30(1-2), 91-107.
- Charnes, A., W.W. Cooper, and Z.M. Huang. (1990). "Polyhedral cone-ratio DEA models with an illustrative application to large commercial banks." *Journal of Econometrics*. Vol. 46, pp. 73-91.
- Chen, W. C., & Cho, W. J. (2009). A procedure for large-scale DEA computations. *Computers & Operations Research*, 36(6), 1813-1824.
- Chilingerian, J. A., & David Sherman, H. (1997). DEA and primary care physician report cards: Deriving preferred practice cones from managed care service concepts and operating strategies. *Annals of operations Research*, 73, 35-66.
- Coelli, T. J., & Rao, D. P. (2005). Total factor productivity growth in agriculture: a Malmquist index analysis of 93 countries, 1980–2000. *Agricultural Economics*, 32, 115-134.
- Coelli, T. J., Rao, D. S. P., O'Donnell, C. J., & Battese, G. E. (2005). An introduction to efficiency and productivity analysis. Springer science & business media.
- Cooper, W. W., Seiford, L. M., & Zhu, J. (2011). Data envelopment analysis: History, models, and interpretations. In *Handbook on data envelopment analysis* (pp. 1-39). Springer, Boston, MA.

- Costa, Á., & Markellos, R. N. (1997). Evaluating public transport efficiency with neural network models. *Transportation Research Part C: Emerging Technologies*, 5(5), 301-312.
- Crowe, R. (2022, Temmuz 1). Machine learning modeling pipelines in production: Shapley values [Videos]. URL: <https://www.coursera.org/lecture/machine-learning-modeling-pipelines-in-production/shapley-values-JsOBS>
- Çelebi, D., & Bayraktar, D. (2008). An integrated neural network and data envelopment analysis for supplier evaluation under incomplete information. *Expert Systems with Applications*, 35(4), 1698-1710.
- Doyle, J., & Green, R. (1994). Strategic choice and data envelopment analysis: comparing computers across many attributes. *Journal of Information Technology*, 9(1), 61-69.
- Dulá, J. H. (2011). An algorithm for data envelopment analysis. *INFORMS Journal on Computing*, 23(2), 284-296.
- Dulá, J. H., & López, F. J. (2006). Algorithms for the frame of a finitely generated unbounded polyhedron. *INFORMS Journal on Computing*, 18(1), 97-110.
- Dulá, J. H., & López, F. J. (2013). DEA with streaming data. *Omega*, 41(1), 41-47.
- Dyson, R.G., and E. Thanassoulis. (1988). "Reducing weight flexibility in data envelopment analysis." *Journal of Operational Research Society*. Vol. 39, No. 6, pp. 563-576.

- Emrouznejad, A., & Shale, E. (2009). A combined neural network and DEA for measuring efficiency of large scale datasets. *Computers & Industrial Engineering*, 56 (1), 249-254.
- Farrell, M. J. (1957). The measurement of productive efficiency. *Journal of the Royal Statistical Society: Series A (General)*, 120(3), 253-281.
- Fukushima, K. (1988). Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural networks*, 1(2), 119-130.
- Galagedera, D. U. A., & Silvapulle, P. (2003). Experimental evidence on robustness of data envelopment analysis. *Journal of the Operational Research Society*, 54(6), 654-660.
- Gead, R. (2022, Ağustos 8) Shapley additive explanations (SHAP) [Çevrimiçi Video]. URL: <https://www.youtube.com/watch?v=VB9uV-x0gtg>
- Golany, B. (1988). "A note on including ordinal relations among multiplier in data envelopment analysis." *Management Science*. Vol. 34, No. 8, pp. 1029 - 1033.
- Golany, B., & Roll, Y. (1989). An application procedure for DEA. *Omega*, 17(3), 237-250.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.
- Göçken, M., Özçalıcı, M., Boru, A., & Dosdoğru, A. T. (2016). Integrating metaheuristics and artificial neural networks for improved stock price prediction. *Expert Systems with Applications*, 44, 320-331.

- Hamilton, W. (1852). *Discussions on philosophy and literature, education and university reform*. Harper.
- Han, F., Jiang, J., Ling, Q. H., & Su, B. Y. (2019). A survey on metaheuristic optimization for random single-hidden layer feedforward neural network. *Neurocomputing*, 335, 261-273.
- Hanafizadeh, P., Khedmatgozar, H. R., Emrouznejad, A., & Derakhshan, M. (2014). Neural network DEA for measuring the efficiency of mutual funds. *International journal of applied decision sciences*, 7(3), 255-269.
- Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction* (Vol. 2, s. 1-758). New York: springer.
- Heaton, J. (2015). AIFH, volume 3: deep learning and neural networks. *J. Chem. Inf. Model*, 3.
- Heaton, J. (2017). *Automated feature engineering for deep neural networks with genetic programming* (Doctoral dissertation, Nova Southeastern University).
- Heaton, J. (2018). Feature Importance in Supervised Training. *Predictive Analytics and Futurism*, 22.
- Heaton, J., McElwee, S., Fraley, J., & Cannady, J. (2017, May). Early stabilizing feature importance for TensorFlow deep neural networks. In *2017 International Joint Conference on Neural Networks (IJCNN)* (s. 4618-4624). IEEE.

- Hebb, D.O. (1949). *The Organization of Behavior: A neuropsychological theory*. New York: Wiley & Sons.
- Henriques, I. C., Sobreiro, V. A., Kimura, H., & Mariano, E. B. (2020). Two-stage DEA in banks: Terminological controversies and future directions. *Expert Systems with Applications*, 161, 113632.
- Hinton, G., Srivastava, N., & Swersky, K. (2012). Neural networks for machine learning. Coursera, video lectures, 264 (1), 2146-2153.
- Hoang, D. T., & Kang, H. J. (2018, June). Deep belief network and Dempster-Shafer evidence theory for bearing fault diagnosis. In 2018 IEEE 27th international symposium on industrial electronics (ISIE) (pp. 841-846). IEEE.
- Hochreiter, S. (1998). The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02), 107-116.
- Hughes, A., & Yaisawarng, S. (2004). Sensitivity and dimensionality tests of DEA efficiency scores. *European Journal of Operational Research*, 154(2), 410-422.
- Ioffe, S., & Szegedy, C. (2015, June). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning* (s. 448-456). PMLR.
- Jenkins, L., & Anderson, M. (2003). A multivariate statistical approach to reducing the number of variables in data envelopment analysis. *European Journal of Operational Research*, 147(1), 51-61.

- Jordan, M. I. (1986). Attractor dynamics and parallelism in a connectionist sequential machine. In Proceedings of the Eighth Conference of the Cognitive Science Society.
- Kabnurkar, A. (2001). *Mathematical modeling for data envelopment analysis with fuzzy restrictions on weights* (Doctoral dissertation, Virginia Tech).
- Kheirkhah, A., Azadeh, A., Saberi, M., Azaron, A., & Shakouri, H. (2013). Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis. *Computers & Industrial Engineering*, 64(1), 425-441.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Koronakos, G., & Sotiropoulos, D. N. (2020, Temmuz). A Neural Network approach for Non-parametric Performance Assessment. In *2020 11th International Conference on Information, Intelligence, Systems and Applications (IISA)* (pp. 1-8). IEEE.
- Kuo, R. J., Wang, Y. C., & Tien, F. C. (2010). Integration of artificial neural network and MADA methods for green supplier selection. *Journal of cleaner production*, 18(12), 1161-1170.
- Kwon, H. B. (2014). Performance modeling of mobile phone providers: A DEA-ANN combined approach. *Benchmarking: an international journal*.
- Kwon, H. B. (2017). Exploring the predictive potential of artificial neural networks in conjunction with DEA in railroad performance modeling. *International Journal of Production Economics*, 183, 159-170.

- Kwon, H. B., & Lee, J. (2015). Two-stage production modeling of large US banks: A DEA-neural network approach. *Expert Systems with Applications*, 42(19), 6758-6766.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Liao, H., & Li, Z. (2008). Multiobjective design of equivalent accelerated life testing plans. *International journal of reliability, quality and safety engineering*, 15(06), 515-538.
- Liao, H., Wang, B., & Weyman-Jones, T. (2007). Neural network based models for efficiency frontier analysis: an application to east asian economies' Growth Decomposition. *Global Economic Review*, 36(4), 361-384.
- Liu, H. H., Chen, T. Y., Chiu, Y. H., & Kuo, F. H. (2013). A comparison of three-stage DEA and artificial neural network on the operational efficiency of semi-conductor firms in Taiwan.
- Lovell, C. K. (1993). Production frontiers and productive efficiency. The measurement of productive efficiency: techniques and applications, 3, 67.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Mateus, B. C., Mendes, M., Farinha, J. T., & Cardoso, A. M. (2021). Anticipating future behavior of an industrial press using LSTM networks. *Applied Sciences*, 11(13), 6101.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.

Meng, W., Zhang, D., Qi, L., & Liu, W. (2008). Two-level DEA approaches in research evaluation. *Omega*, 36(6), 950-957.

Misiunas, N., Oztekin, A., Chen, Y., & Chandra, K. (2016). DEANN: A healthcare analytic methodology of data envelopment analysis and artificial neural networks for the prediction of organ recipient functional status. *Omega*, 58, 46-54.

Moore, G. E. (1965). Cramming more components onto integrated circuits.

Mostafa, M. M. (2009a). A probabilistic neural network approach for modelling and classifying efficiency of GCC banks. *International Journal of Business Performance Management*, 11(3), 236-258.

Mostafa, M. M. (2009b). Modeling the efficiency of top Arab banks: A DEA–neural network approach. *Expert systems with applications*, 36(1), 309-320.

Mostafa, M. M. (2009c). Modeling the competitive market efficiency of Egyptian companies: A probabilistic neural network analysis. *Expert Systems with Applications*, 36(5), 8839-8848.

Mousa, M. E. S., & Kamel, M. A. (2021). An integrated framework for predicting the best financial performance of banks: evidence from Egypt. *Journal of Modelling in Management*.

Mousavi, M. M., Ouenniche, J., & Tone, K. (2019). A comparative analysis of two-stage distress prediction models. *Expert Systems with Applications*, 119, 322-341.

Nair, V., & Hinton, G. E. (2009). 3D object recognition with deep belief nets. *Advances in neural information processing systems*, 22.



- Nesterov, Y. (1983). A method of solving a convex programming problem with convergence rate  $O(1/k^2)$ . *Soviet Mathematics Doklady*, 27, 372–376.
- Olden, J. D., Joy, M. K., & Death, R. G. (2004). An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. *Ecological modelling*, 178(3-4), 389-397.
- Omar, N., Johari, Z. A., & Smith, M. (2017). Predicting fraudulent financial reporting using artificial neural network. *Journal of Financial Crime*.
- Oyamada, M. (2018). *Efficient Machine Learning on Relational Data* (Doctoral dissertation, 筑波大学 (University of Tsukuba)).
- Pedraja-Chaparro, F., Salinas-Jimenez, J., & Smith, P. (1997). On the role of weight restrictions in data envelopment analysis. *Journal of Productivity Analysis*, 8(2), 215-230.
- Pendharkar, P. C. (2005). A data envelopment analysis-based approach for data preprocessing. *IEEE Transactions on Knowledge and Data Engineering*, 17(10), 1379-1388.
- Pendharkar, P. C. (2011). A hybrid radial basis function and data envelopment analysis neural network for classification. *Computers & Operations Research*, 38(1), 256-266.
- Pendharkar, P. C., & Rodger, J. A. (2003). Technical efficiency-based selection of learning cases to improve forecasting accuracy of neural networks under monotonicity assumption. *Decision support systems*, 36(1), 117-136.

- Podinovski, V. V., & Athanassopoulos, A. D. (1998). Assessing the relative efficiency of decision making units using DEA models with weight restrictions. *Journal of the Operational Research Society*, 49(5), 500-508.
- Podinovski, V. V., & Thanassoulis, E. (2007). Improving discrimination in data envelopment analysis: Some practical suggestions. *Journal of Productivity Analysis*, 28(1), 117-126.
- Polyak, B. T. (1964). Some methods of speeding up the convergence of iteration methods. *Ussr computational mathematics and mathematical physics*, 4(5), 1-17.
- Prechelt, L. (1998). Early stopping-but when?. In *Neural Networks: Tricks of the trade* (s. 55-69). Springer, Berlin, Heidelberg.
- Pyrzcz, M., Project Title, (2021a), PythonNumericalDemos / Interactive\_Shapley\_Values.ipynb, URL:[https://github.com/GeostatsGuy/PythonNumericalDemos/blob/master/Interactive\\_Shapley\\_Values.ipynb](https://github.com/GeostatsGuy/PythonNumericalDemos/blob/master/Interactive_Shapley_Values.ipynb)
- Pyrzcz, M. J. (2021b, Şubat 17). 05e Machine Learning: Shapley Value [Videos]. URL: <https://www.youtube.com/watch?v=oClYbnawLdg>
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016, August). "Why should i trust you?" Explaining the predictions of any classifier. In Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining (pp. 1135-1144).
- Roll, Y., B. Golany. (1993). "Alternate methods of treating factor weights in DEA." *OMEGA The Intl JI. of Mgmt. Sci.* Vol. 21, No. 1, pp. 99-109.

- Roll, Y., W.D. Cook, and B. Golany. (1991). "Controlling factor weights in data envelopment analysis." *IIE Transactions*. Vol. 23, No. 1, pp. 2 - 9.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1985). *Learning internal representations by error propagation*. California Univ San Diego La Jolla Inst for Cognitive Science.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- Russel, S., & Norvig, P. (1995). Artificial Intelligence: A Modern Approach, chapter 20. *Prentice-Hall Inc., Englewood Cliffs, New Jersey, 7632*, 598-624.
- Saad, D. (1998). Online algorithms and stochastic approximations. *Online Learning*, 5(3), 6.
- Samoilenko, S., & Osei-Bryson, K. M. (2010). Determining sources of relative inefficiency in heterogeneous samples: Methodology using Cluster Analysis, DEA and Neural Networks. *European journal of operational research*, 206(2), 479-487.
- Samoilenko, S., & Osei-Bryson, K. M. (2013). Using Data Envelopment Analysis (DEA) for monitoring efficiency-based performance of productivity-driven organizations: Design and implementation of a decision support system. *Omega*, 41(1), 131-142.

- Santin, D. (2008). On the approximation of production functions: a comparison of artificial neural networks frontiers and efficiency techniques. *Applied Economics Letters*, 15(8), 597-600.
- Santin, D., Delgado, F. J., & Valino, A. (2004). The measurement of technical efficiency: a neural network approach. *Applied Economics*, 36(6), 627-635.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Seiford, L. M., & Zhu, J. (1999). Infeasibility of super-efficiency data envelopment analysis models. *INFOR: Information Systems and Operational Research*, 37(2), 174-187.
- Shabanpour, H., Yousefi, S., & Saen, R. F. (2017). Forecasting efficiency of green suppliers by dynamic data envelopment analysis and artificial neural networks. *Journal of cleaner production*, 142, 1098-1107.
- Shapley, L.S. (1953). A value for n-person games, in: Contributions to the Theory of Games, *Annals of Mathematics Studies*, No. 28, vol. 2, Princeton University Press, Princeton, NJ, pp. 307–317.
- Shen, W. F., Zhang, D. Q., Liu, W. B., & Yang, G. L. (2016). Increasing discrimination of DEA evaluation by utilizing distances to anti-efficient frontiers. *Computers & Operations Research*, 75, 163-173.
- Shokrollahpour, E., Hosseinzadeh Lotfi, F., & Zandieh, M. (2016). An integrated data envelopment analysis–artificial neural network approach for benchmarking of bank branches. *Journal of Industrial Engineering International*, 12(2), 137-143.

- Singpai, B., & Wu, D. (2020). Using a DEA–AutoML approach to track SDG achievements. *Sustainability*, 12(23), 10124.
- Slack, D., Hilgard, S., Jia, E., Singh, S., & Lakkaraju, H. (2020, February). Fooling lime and shap: Adversarial attacks on post hoc explanation methods. In *Proceedings of the AAAI/ACM Conference on AI, Ethics, and Society* (pp. 180-186).
- Sreekumar, S., & Mahapatra, S. S. (2011). Performance modeling of Indian business schools: a DEA-neural network approach. *Benchmarking: An International Journal*.
- Stefanov, S. M. (2001). Separable programming: A dynamic programming approach. In *Separable Programming* (s. 91-139). Springer, Boston, MA.
- Sutskever, I., Martens, J., Dahl, G., & Hinton, G. (2013, May). On the importance of initialization and momentum in deep learning. In *International conference on machine learning* (pp. 1139-1147). PMLR.
- Taylor, W.M., R.G. Thompson, R.M. Thrall, and P.S. Dharmapala. (1997). "DEA/AR efficiency and profitability of Mexican banks: A total income model." *European Journal of Operational Research*. Vol. 98, pp. 346-363.
- Teh, Y. W., & Hinton, G. E. (2000). Rate-coded restricted Boltzmann machines for face recognition. *Advances in neural information processing systems*, 13.
- Thanassoulis E., A. Boussofiane, and R.G. Dyson. (1995). "Exploring output quality targets in the provision of perinatal care in England using data envelopment analysis." *European Journal of Operational Research*. Vol. 80, pp. 588 - 607.

- Thanassoulis, E., & Allen, R. (1998). Simulating weights restrictions in data envelopment analysis by means of unobserved DMUs. *Management Science*, 44(4), 586-594.
- Thanassoulis, E. (2001). Introduction To The Theory And Application Of Data envelopment Analysis. Birmingham: Springer.
- Thanassoulis, E., Portela, M. C., & Allen, R. (2004). Incorporating value judgments in DEA. *Handbook on data envelopment analysis*, 99-138.
- Thompson, R.G., F.D. Singleton Jr., R.M. Thrall, B.A. Smith. (1986). "Comparative site evaluations for locating a high-energy physics lab in Texas." *INTERFACES*. Vol. 16, No. 6, pp. 35-49.
- Thompson, R.G., L.N. Langemeier, C-T. Lee, E. Lee, and R.M. Thrall. (1990). "The role of multiplier bounds in efficiency analysis with application to Kansas farming." *Journal of Econometrics*. Vol. 46, pp. 93-108.
- Thompson, R.G., P.S. Dharmapala, E.J. Gatewood, S. Macy, and R.M. Thrall. (1996a). "DEA/Assurance region SDBC efficiency and unique projections." *OR Practice*. Vol. 44, No. 4, pp. 533-542.
- Thompson, R.G., P.S. Dharmapala, L.J. Rothenberg, and R.M. Thrall. (1996b). "DEA/AR Efficiency and profitability of 14 major oil companies in U.S. exploration and production." *Computers Operations Research*. Vol. 23, No. 4, pp. 357 – 373.
- Tsolas, I. E., Charles, V., & Gherman, T. (2020). Supporting better practice benchmarking: A DEA-ANN approach to bank branch performance assessment. *Expert Systems with Applications*, 160, 113599.

- Ulucan, A. (2002). İSO 500 şirketlerinin etkinliklerinin ölçülmesinde Veri Zarflama Analizi: Farklı girdi çıktı bileşenleri ve ölçüğe göre getiri yaklaşımları ile değerlendirmeler. *Ankara üniversitesi SBF dergisi*, 57(02).
- Ülengin, F., Kabak, Ö., Önsel, S., Aktas, E., & Parker, B. R. (2011). The competitiveness of nations and implications for human development. *Socio-Economic planning sciences*, 45(1), 16-27.
- Vaninsky, A. (2004). Combining data envelopment analysis with neural networks: Application to analysis of stock prices. *Journal of information and optimization sciences*, 25(3), 589-611.
- Wang, S. (2003). Adaptive non-parametric efficiency frontier analysis: a neural-network-based model. *Computers & Operations Research*, 30(2), 279-295.
- Wilson, D. R., & Martinez, T. R. (2003). The general inefficiency of batch training for gradient descent learning. *Neural networks*, 16(10), 1429-1451.
- Wolpert, J. (1976). Opening closed spaces. *ANNALS of the Association of American Geographers*, 66(1), 1-13.
- Wong, Y-H. B., and J. E. Beasley. (1990). Restricting weight flexibility in data envelopment analysis, *Journal of Operational Research Society* 41/9, 829-835.
- Wu, D. (2009). Supplier selection: A hybrid model using DEA, decision tree and neural network. *Expert systems with Applications*, 36(5), 9105-9112.

- 29/12/2022)., Yang, Z., & Liang, L. (2006). Using DEA-neural network approach to evaluate branch efficiency of a large Canadian bank. *Expert systems with applications*, 31(1), 108-115.
- Wu, J., Liang, L., & Chen, Y. (2009). DEA game cross-efficiency approach to Olympic rankings. *Omega*, 37(4), 909-918.
- Zelenyuk, V. (2020). Aggregation of inputs and outputs prior to Data Envelopment Analysis under big data. *European Journal of Operational Research*, 282(1), 172-187.
- Zhang, M., Li, H., Lyu, J., Ling, S. H., & Su, S. (2019). Multi-level CNN for lung nodule classification with Gaussian Process assisted hyperparameter optimization. arXiv preprint arXiv:1901.00276.
- Zhu, J. (1996). Data envelopment analysis with preference structure. *Journal of the Operational Research Society*, 47(1), 136-150.
- Zhu, J. (2015). *Data Envelopment Analysis a Handbook of Models and Methods*. Springer.



## EK 1. ORJİNALLİK RAPORU

	<b>HACETTEPE ÜNİVERSİTESİ</b> <b>SOSYAL BİLİMLER ENSTİTÜSÜ</b> <b>DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU</b>
<b>HACETTEPE ÜNİVERSİTESİ</b> <b>SOSYAL BİLİMLER ENSTİTÜSÜ</b> <b>İŞLETME ANABİLİM DALI BAŞKANLIĞI'NA</b>	
29/12/2022	
<p>Tez Başlığı: Yapay Sinir Ağları Destekli Etkinlik Ölçümü: Veri Zarflama Analizi Üzerine Uygulamalar</p> <p>Yukarıda başlığı gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler ve d) Sonuç kısımlarından oluşan toplam 138 sayfalık kısmına ilişkin, 29/12/2022 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda işaretlenmiş filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 2 'dir.</p>	
<p>Uygulanan filtrelemeler:</p> <ol style="list-style-type: none"> <li>1- <input checked="" type="checkbox"/> Kabul/Onay ve Bildirim sayfaları hariç</li> <li>2- <input checked="" type="checkbox"/> Kaynakça hariç</li> <li>3- <input type="checkbox"/> Alıntılar hariç</li> <li>4- <input checked="" type="checkbox"/> Alıntılar dâhil</li> <li>5- <input checked="" type="checkbox"/> 5 kelimedenden daha az örtüşme içeren metin kısımları hariç</li> </ol>	
<p>Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.</p>	
<p>Gereğini saygılarımla arz ederim.</p>	
29/12/2022	
<p><b>Adı Soyadı:</b> Irmak UZUN BAYAR</p> <p><b>Öğrenci No:</b> N15147602</p> <p><b>Anabilim Dalı:</b> İşletme</p> <p><b>Programı:</b> Doktora</p> <p><b>Statüsü:</b> <input checked="" type="checkbox"/> Doktora <input type="checkbox"/> Bütünleşik Dr.</p>	
<p><b><u>DANIŞMAN ONAYI</u></b></p> <p>UYGUNDUR.</p> <p>Doç. Dr.' Kazım Barış ATICI</p>	



**HACETTEPE UNIVERSITY  
GRADUATE SCHOOL OF SOCIAL SCIENCES  
Ph.D. DISSERTATION ORIGINALITY REPORT**

**HACETTEPE UNIVERSITY  
GRADUATE SCHOOL OF SOCIAL SCIENCES  
BUSINESS ADMINISTRATION DEPARTMENT**

29/12/2022

Thesis Title : Artificial Neural Network Aided Efficiency Measurement: Applications on Data Envelopment Analysis  
According to the originality report obtained by myself/my thesis advisor by using the Turnitin plagiarism detection software and by applying the filtering options checked below on 29/12/2022 for the total of 138 pages including the a) Title Page, b) Introduction, c) Main Chapters, and d) Conclusion sections of my thesis entitled as above, the similarity index of my thesis is 2 %.

Filtering options applied:

1.  Approval and Declaration sections excluded
2.  Bibliography/Works Cited excluded
3.  Quotes excluded
4.  Quotes included
5.  Match size up to 5 words excluded

I declare that I have carefully read Hacettepe University Graduate School of Social Sciences Guidelines for Obtaining and Using Thesis Originality Reports; that according to the maximum similarity index values specified in the Guidelines, my thesis does not include any form of plagiarism; that in any future detection of possible infringement of the regulations I accept all legal responsibility; and that all the information I have provided is correct to the best of my knowledge.

I respectfully submit this for approval.

29/12/2022

**Name Surname:** Irmak UZUN BAYAR  
**Student No:** N15147602  
**Department:** Business Administration  
**Program:** Ph.D.  
**Status:**  Ph.D.  Combined MA/ Ph.D.

**ADVISOR APPROVAL**

Doç. Dr. Kazım Barış ATICI

## EK 2. ETİK KURUL / KOMİSYON İZİNİ YA DA MUAFİYET FORMU

	<b>HACETTEPE ÜNİVERSİTESİ</b> <b>SOSYAL BİLİMLER ENSTİTÜSÜ</b> <b>TEZ ÇALIŞMASI ETİK KOMİSYON MUAFİYETİ FORMU</b>
<b>HACETTEPE ÜNİVERSİTESİ</b> <b>SOSYAL BİLİMLER ENSTİTÜSÜ</b> <b>İŞLETME ANABİLİM DALI BAŞKANLIĞI'NA</b>	
29/12/2022	
<p>Tez Başlığı: Yapay Sinir Ağları Destekli Etkinlik Ölçümü: Veri Zarflama Analizi Üzerine Uygulamalar          Yukarıda başlığı gösterilen tez çalışmam:</p>	
<ol style="list-style-type: none"> <li>1. İnsan ve hayvan üzerinde deney niteliği taşımamaktadır,</li> <li>2. Biyolojik materyal (kan, idrar vb. biyolojik sıvılar ve numuneler) kullanılmasını gerektirmemektedir.</li> <li>3. Beden bütünlüğüne müdahale içermemektedir.</li> <li>4. Gözlemsel ve betimsel araştırma (anket, mülakat, ölçek/skala çalışmaları, dosya taramaları, veri kaynakları taraması, sistem-model geliştirme çalışmaları) niteliğinde değildir.</li> </ol>	
<p>Hacettepe Üniversitesi Etik Kurullar ve Komisyonlarının Yönergelerini inceledim ve bunlara göre tez çalışmamın yürütülebilmesi için herhangi bir Etik Kurul/Komisyon'dan izin alınmasına gerek olmadığını; aksi durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.</p>	
<p>Gereğini saygılarımla arz ederim.</p>	
<p><b>Adı Soyadı:</b> Irmak UZUN BAYAR</p> <p><b>Öğrenci No:</b> N15147602</p> <p><b>Anabilim Dalı:</b> İşletme</p> <p><b>Programı:</b> Doktora</p> <p><b>Statüsü:</b> <input type="checkbox"/> Yüksek Lisans <input checked="" type="checkbox"/> Doktora <input type="checkbox"/> Bütünleşik Doktora</p>	
<b><u>DANIŞMAN GÖRÜŞÜ VE ONAYI</u></b>	
<p>Doç. Dr. Kâzım Barış ATICI</p>	
<p>Detaylı Bilgi: <a href="http://www.sosyalbilimler.hacettepe.edu.tr">http://www.sosyalbilimler.hacettepe.edu.tr</a></p>	
<p>Telefon: 0-312-2976860</p>	<p>Faks: 0-3122992147</p>
<p>E-posta: <a href="mailto:sosyalbilimler@hacettepe.edu.tr">sosyalbilimler@hacettepe.edu.tr</a></p>	



**HACETTEPE UNIVERSITY  
GRADUATE SCHOOL OF SOCIAL SCIENCES  
ETHICS COMMISSION FORM FOR THESIS**

**HACETTEPE UNIVERSITY  
GRADUATE SCHOOL OF SOCIAL SCIENCES  
BUSINESS ADMINISTRATION DEPARTMENT**

29/12/2022

Thesis Title: Artificial Neural Network Aided Efficiency Measurement: Applications on Data Envelopment Analysis  
My thesis work related to the title above:

1. Does not perform experimentation on animals or people.
2. Does not necessitate the use of biological material (blood, urine, biological fluids and samples, etc.).
3. Does not involve any interference of the body's integrity.
4. Is not based on observational and descriptive research (survey, interview, measures/scales, data scanning, system-model development).

I declare, I have carefully read Hacettepe University's Ethics Regulations and the Commission's Guidelines, and in order to proceed with my thesis according to these regulations I do not have to get permission from the Ethics Board/Commission for anything; in any infringement of the regulations I accept all legal responsibility and I declare that all the information I have provided is true.

I respectfully submit this for approval.

**Name Surname:** Irmak UZUN BAYAR  
**Student No:** N15147602  
**Department:** Business Administration  
**Program:** Ph.D.  
**Status:**  MA  Ph.D.  Combined MA/ Ph.D.

**ADVISER COMMENTS AND APPROVAL**

Doç. Dr. Kazım Barış ATICI