

**T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DAVRANIŞSAL ÖĞRENME BAZLI BİR YAPAY
MAKİNE ÖĞRENME YÖNTEMİNİN GELİŞTİRİLMESİ**

ÖMER FARUK ERTUĞRUL

**DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

EYLÜL 2015

Tez Başlığı : “Davranışsal Öğrenme Bazlı Bir Yapay Makine Öğrenme Yönteminin Geliştirilmesi”

Tezi Hazırlayan : Ömer Faruk Ertuğrul

Sınav Tarihi : 04.09.2015

Yukarıda adı geçen tez, jürimizce değerlendirilerek Elektrik-Elektronik Mühendisliği Ana Bilim Dalı’nda Doktora Tezi olarak kabul edilmiştir.

Sınav Jüri Üyeleri

Tez Danışmanı	Doç. Dr. M. Emin TAĞLUK İnönü Üniversitesi	
Jüri Başkanı	Prof. Dr. Salih MAMİŞ İnönü Üniversitesi	
Üye	Doç. Dr. Müslüm ARKAN İnönü Üniversitesi	
Üye	Doç. Dr. Murat UYAR Siirt Üniversitesi	
Üye	Doç. Dr. Necmettin SEZGİN Batman Üniversitesi	

Prof. Dr. Alaattin ESEN
Enstitü Müdürü

ONUR SÖZÜ

Doktora Tezi olarak sunduğum “**Davranışsal Öğrenme Bazlı bir Yapay Makine Öğrenme Yönteminin Geliştirilmesi**” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Ömer Faruk ERTUĞRUL

ÖZET

Doktora Tezi

DAVRANIŞSAL ÖĞRENME BAZLI BİR YAPAY MAKİNE ÖĞRENME YÖNTEMİNİN GELİŞTİRİLMESİ

Ömer Faruk Ertuğrul

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

132+IX Sayfa

2015

Danışman: Doç. Dr. M. Emin TAĞLUK

Yapay makine öğrenmesi kapsamında birçok yöntem geliştirilmiş, veri analizi ve değerlendirilmesi için aktif olarak kullanılmaktadır. Bu yöntemlerden bazıları davranışsal öğrenme yöntemleri olup, insanın öğrenme sürecini baz almaktadırlar. Davranışsal öğrenme yöntemleri ile elde edilen sonuçlar deneysel verilere dayandıkları halde birbiriyle çelişen taraflarının olduğunu ve hepsinin aynı şartları sağlamadığını literatürden anlamaktayız. Bu konuda daha genel ve kapsayıcı yöntemlerin geliştirilmesine ihtiyaç olduğunu literatürde var olan bilgilerden anlaşılmaktadır.

Bu amaçla davranışçı kuramlardan Pavlov, Watson, Guthrie, Thorndike ve Skinner'ın koşullanma kuramları gibi popüler olanlar incelenmiş ve çelişkili kısımlarına yönelik hayvanlar üzerinde deneysel çalışmalar yapılarak bu çelişkilerin giderilmesine çalışılmıştır. Elde edilen veriler ışığında insan öğrenmesinde var olan öğrenme sürekliliği, unutma ve benzeri parametreler dikkate alarak daha genel bir davranışsal öğrenme yöntemi önerilmiş ve bu yöntem matematiksel olarak modellenmiştir. Genelleştirilmiş olan bu matematiksel modelin mevcut kuramların tüm özelliklerini sağladığına dair tezde çalışma yapılmış ve gösterilmiştir. Önerilen bu yöntem dinamik olarak öğrenme, unutma ve geriye yalın gibi kabiliyetlere de sahip olduğundan özellikle dinamik veri değerlendirmesinde tezde değinilen YSA ve KYK gibi diğer yöntemlere nazaran daha başarılı olduğu tespit edilmiştir.

Ayrıca, önerilen bu modelin sınıflandırma ve regresyon gibi problemlerin çözümünde kullanılabileceğini göstermek için model güncel veri kümeleri ile test edilmiştir. Elde edilen sonuçlar önerilen modelin psikoloji (davranış kontrolü, fobi sönümleme, vb...), kontrol, robotik ve benzeri alanlarda rahatlıkla kullanılabileceğini göstermiştir.

ANAHTAR KELİMELER: Yapay Öğrenme, Davranışçı Öğrenme, Modelleme, Sınıflandırma, Regresyon

ABSTRACT

PhD. Thesis

DEVELOPING AN ARTIFICIAL MACHINE LEARNING METHOD BASED ON BEHAVIORAL LEARNING

Ömer Faruk Ertuğrul

Inonu University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

132+IX Pages

2015

Supervisor: Assoc. Prof. Dr. M. Emin TAĞLUK

In the context of artificial machine learning many methods have been developed and actively used in analysis and evaluation of data. Some of these methods are the behavioral learning methods take human learning process as the bases for the method.

Despite of that the results obtained with the behavioral learning methods depend on the experimental data, there are contradictory arguments between methods and they do not hold the same conditions, which can be understood from the literature. From the information available in the literature it is understood that more general methods in this concept are need to be developed.

For this aim, among the popular behavioral learning theories like Pavlov, Watson, Guthrie, Thorndike and Skinner's conditioning theories were analyzed and animal based experimental studies were conducted toward the contradictory issues to remove these contradictions. In the light of the obtained experimental results, such parameters like continuously learning and forgetting, which hold in human learning, were taken into account and a more general behavioral learning method was proposed and the mathematical model for this method was developed. In this study it was demonstrated and shown that the developed generalized mathematical method is keeping on all of the properties of the available theories. Since the proposed method has dynamically learning, forgetting and back propagating talents, as was mentioned in the body of thesis, particularly it was proved that it is much successful in evaluating dynamical data compared to methods like ANN and kNN mentioned in the thesis.

Furthermore, in order to show the usability of the developed method in solution of classification and regression problems, the model was tested on the update datasets. The obtained results showed that the developed model can be used in psychology (behavior control, phobia attenuation etc...), control, robotic and similar fields.

KEYWORDS: Machine Learning, Behavioral Learning, Modelling, Classification, Regression.

TEŞEKKÜR

Öncelikle sadece bu çalışmada değil, bana her türlü yardım ve desteği veren ve oldukça yararlandığım önerileri sunan danışmanım Sayın Doç. Dr. M. Emin TAĞLUK'a ve rahatsız ettiğim ailesine;

Tez çalışması süresince bana her türlü destek ve önerilerini sunan Tez İzleme Komitesi Üyeleri Sayın Prof. Dr. M. Salih MAMİŞ ve Sayın Doç. Dr. Müslüm ARKAN'a;

Destek ve katkılarından dolayı İnönü Üniversitesi Mühendislik Fakültesi Elektrik ve Elektronik Mühendisliği Bölümü öğretim üyelerine, elemanlarına ve diğer personellerine, özellikle Sayın Cemal KELEŞ, Sayın İbrahim IŞIK ve Sayın Nurhan Akdeniz'e;

Tezin dilbilgisi ve içerik yönünden düzeltilmesinde katkılarından dolayı değerli dostlarım Yrd. Doç. Dr. Yılmaz KAYA, Yrd. Doç. Dr. Ramazan TEKİN'e ve Öğr. Gör. Abdulkerim ÖZTEKİN'e; Deneysel çalışmadaki sürecindeki katkılarından dolayı dostum Sayın Engin SÜMER'e; tavsiye ve katkılarından dolayı değerli dostum Dr. Barış Baykant ALAGÖZ'e;

Destek ve katkılarından dolayı Batman Üniversitesindeki Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü öğretim üyeleri ve elemanlarına;

Ayrıca, bu çalışma süresince bana destek olan ve çalışmalarımın otürü ihmal ettiğim değerli aileme ve özellikle bugünlere gelmemde büyük emeği olan sevgili BABAM ve ANNEM'e

teşekkür ederim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER LİSTESİ.....	vi
TABLolar LİSTESİ	viii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER.....	4
2.1. Öğrenme	4
2.2. Davranışçı Öğrenme Kuramları.....	5
2.3. Pavlov'un Yaklaşımı	6
2.3.1. Klasik Koşullanmanın Temel İlkeleri.....	8
2.3.2. Klasik Koşullanmanın Önemi ve Çıktıları	9
2.3.3. Hesapsal Modeller	10
2.3.4. Karşılaştırma Çalışmaları	13
2.4. Watson'ın Kuramı	14
2.5. Guthrie'nin Yaklaşımı	15
2.6. Thorndike'in Yaklaşımı.....	16
2.6.1. Thorndike'in Yaklaşımının Temel İlkeleri.....	16
2.6.2. Mevcut Hesapsal Modeller.....	18
2.7. Skinner'ın Yaklaşımı	18
2.7.1. Skinner Yaklaşımının Temel İlkeleri.....	19
2.7.2. Mevcut Hesapsal Modeller.....	19
2.8. Özetçe	20
3. MATERYAL VE YÖNTEM	21
3.1. Klasik Koşullanmanın Modellenmesi	21
3.1.1. Önerilen Klasik Koşullanma Modeli	21
3.1.2. Modelleme Sonuçları.....	22
3.1.3. Modelin Uygulama Sonuçlarının Değerlendirilmesi.....	26
3.2. Davranışçı Öğrenme Kuramlarının Genelleştirilmesi	28
3.2.1. Deneysel Çalışma: Ön bilgi	29
3.2.2. Deney Protokolü	30
3.2.3. Deney Sonucu.....	32
3.3. Genelleştirilmiş Davranışçı Öğrenme Kuramının Modellenmesi	33
3.3.1. Organizma Kaynaklı Uyarıcılar.....	34
3.3.2. Uyarıcılar	37
3.3.3. Tepki.....	38
3.3.4. Tepkisel Uyarıcı	39
3.3.5. Uyarıcı – Tepki Bağı	39
3.3.6. İstatistiksel İlişki.....	42
3.4. Özetçe	43

4.	ARAŞTIRMA BULGULARI VE TARTIŞMA	45
4.1.	Önerilen Yaklaşımın Davranışçı Kuramları Sağlama Yeteneği	45
4.1.1.	Pavlov'un Yaklaşımı	45
4.1.2.	Watson'ın Yaklaşımı	55
4.1.3.	Guthrie'nin Yaklaşımı	57
4.1.4.	Thorndike'in Yaklaşımı	60
4.1.5.	Skinner'in Yaklaşımı	69
4.1.6.	Arduino ile Modelleme	73
4.2.	Önerilen Davranışsal Öğrenme Modelinin Analizi	74
4.2.1.	Önerilen Modelin Genel Özellikleri	75
4.2.2.	Önerilen Modelin Özellikleri	75
4.2.3.	Önerilen Modelin Eğitim Sürecinin İncelenmesi	77
4.2.4.	Önerilen Modelin Ürettiği Tepkinin Analizi	80
4.2.5.	Önerilen Modelin İşlemsel Yük Analizi	83
4.2.6.	Önerilen Algoritmanın Hafıza İhtiyacı	85
4.2.7.	Önerilen Modelin Yapay Sinir Ağları ile Karşılaştırılması	87
4.2.8.	Önerilen Yöntemin Yapay Öğrenmeden Farkları	88
4.3.	Davranışsal Öğrenme Bazlı Yapay Öğrenme Yöntemi	89
4.3.1.	Deney Prosedürü	89
4.3.2.	Sınıflandırma	91
4.3.3.	Regresyon	94
4.3.4.	Yapay Öğrenme Sonuçların Değerlendirilmesi	96
4.4.	Örnek Uygulama: Ortalama Deniz Su Seviyesinin Tahmini	98
4.4.1.	Veri Seti	99
4.4.2.	Deney Prosedürü	100
4.4.3.	Sonuçlar ve Değerlendirme	102
4.5.	Özetçe	108
5.	SONUÇ VE ÖNERİLER	110
5.1.	Bu Tez Çalışmasında Elde Edilen Sonuçlar	110
5.2.	Gelecekte Yapılabilecek Çalışmalarla İlgili Öneriler	111
	KAYNAKLAR	113
	EKLER	121
	EK-1. Etik Kurul Kararı	121
	EK-2. Önerilen GDÖ Yönteminin Sınıflandırma Kodu	122
	EK-3. Önerilen GDÖ Yönteminin Regresyon Kodu (MATLAB)	124
	EK-4. Önerilen Yöntemin Akıllı Kontrol Kodu	126
	EK-5. Önerilen Yöntemin Arduino Kodu	127
	ÖZGEÇMİŞ	129

ŞEKİLLER LİSTESİ

Şekil 2.1.	Koşullanma süreci	7
Şekil 3.1.	Nötr uyarıcı – tepki ilişkisi	22
Şekil 3.2.	Koşulsuz uyarıcı – koşulsuz tepki ilişkisi	23
Şekil 3.3.	Eşzamanlı koşullanma	23
Şekil 3.4.	Gecikmeli koşullanma	24
Şekil 3.5.	Gecikmeli ikincil koşullanma	25
Şekil 3.6.	Sönme	25
Şekil 3.7.	Gölgeleme	26
Şekil 3.8.	Denekler	30
Şekil 3.9.	4 gün buğday ile beslenen deneklerin ekmeğe olan tepkisi	31
Şekil 3.10.	4 gün ekmek ile beslenen deneklerin buğdaya olan tepkisi	32
Şekil 3.11.	Genelleştirilmiş davranışçı öğrenme yaklaşımı	33
Şekil 3.12.	Klasik koşullanmada bitişik olay sayısının etkisi	36
Şekil 3.13.	Edimsel koşullanmada bitişik olay sayısının etkisi	36
Şekil 3.14.	Edimsel koşullanmada birleştirme katsayısının etkisi	37
Şekil 3.15.	Aksiyon potansiyeli ve safhaları	38
Şekil 3.16.	Sönme katsayısının etkisi	40
Şekil 3.17.	Öğrenme adımının etkisi	41
Şekil 3.18.	Koşullanmada başlangıç ağırlıklarının etkisi	42
Şekil 4.1.	Eş zamanlı koşullanma	46
Şekil 4.2.	Gecikmeli koşullanma	46
Şekil 4.3.	Farklı bitişiklik değerlerine sahip uyarıcıların ağırlık değişimi	47
Şekil 4.4.	Pekiştirme	48
Şekil 4.5.	Sönme	48
Şekil 4.6.	Uyarıcıların genelleşmesi ve ayırt edilmesi	49
Şekil 4.7.	Gölgeleme	50
Şekil 4.8.	Öğrenilmiş acizlik	51
Şekil 4.9.	Kendiliğinden geri gelme	52
Şekil 4.10.	Dereceli koşullandırma	53
Şekil 4.11.	Tekrar kazanım	53
Şekil 4.12.	Geçmiş yaşam	54
Şekil 4.13.	İstatistiksel ilişki	55
Şekil 4.14.	En son, sıklık ve bağ ilkeleri	56
Şekil 4.15.	Küçük Albert Deneyi	56
Şekil 4.16.	Bitişiklik ve bağ	57
Şekil 4.17.	Dikkat ve hazır oluş	58
Şekil 4.18.	Eşik yöntemi	59
Şekil 4.19.	Yorma yöntemi	59
Şekil 4.20.	Bağdaşmayan uyarıcılar yöntemi	60
Şekil 4.21.	Bağlaşımcılık	60
Şekil 4.22.	Tepkisel uyarıcı	62
Şekil 4.23.	Farklı katsayılarla sahip uyarıcılar	64
Şekil 4.24.	Tekrar	65
Şekil 4.25.	Bağlantı kurarak geçiş kuralı	66

Şekil 4.26.	Transfer kuralı	67
Şekil 4.27.	Etki kuralı	67
Şekil 4.28.	Organizma uyarıcısının şiddeti.....	68
Şekil 4.29.	Pekiştirme.....	69
Şekil 4.30.	Sönme.....	70
Şekil 4.31.	Davranış biçimlendirme	71
Şekil 4.32.	Genelleme	72
Şekil 4.33.	Ayırt edici uyarıcı.....	73
Şekil 4.34.	Pavlov'un Deneyi.....	74
Şekil 4.35.	Ağırlık değişimi.....	74
Şekil 4.36.	Modelin yapısı.....	75
Şekil 4.37.	Sistemin yakınsama bölgesinin şematik gösterimi.....	77
Şekil 4.38.	Unutma süreci - unutma katsayısı değişimi	79
Şekil 4.39.	Ağırlık – gürültü oranı değişimi.....	79
Şekil 4.40.	Tek uyarıcı-tepki	80
Şekil 4.41.	Öğrenme: sinaptik seviyede öğrenme	81
Şekil 4.42.	Sinirsel seviyede uyarıcı-tepki bağı	81
Şekil 4.43.	İki uyarıcı ve iki tepki türü olan model yapısı.....	82
Şekil 4.44.	İki tepkili uzay karar dağılımı	82
Şekil 4.45.	Uzay karar dağılımı	83
Şekil 4.46.	Modelin çalışma yapısı.....	84
Şekil 4.47.	Öğrenme eğrisi	87
Şekil 4.48.	Diyabet veri setinin sınıflandırma doğruluğu.....	92
Şekil 4.49.	Karaciğer hastalığı veri setinin sınıflandırma doğruluğu	92
Şekil 4.50.	D-E epilepsi verilerinin sınıflandırma doğruluğu	93
Şekil 4.51.	EMG veri setinin sınıflandırma doğruluğu	94
Şekil 4.52.	Gürültülü <i>Sinc</i> veri seti.....	95
Şekil 4.53.	<i>Sinc</i> veri setinin regresyon doğruluğu	95
Şekil 4.54.	Deniz seviyesi yüksekliği (NOAA).....	96
Şekil 4.55.	Bermuda veri setinin regresyon doğruluğu	96
Şekil 4.56.	PSMSL'de kayıtlı ölçüm istasyonları	100
Şekil 4.57.	1. Deneyin prosedürü	101
Şekil 4.58.	2. Deneyin prosedürü	101
Şekil 4.59.	Veri tüpü.....	102
Şekil 4.60.	Hata oranları.....	103
Şekil 4.61.	Regresyon eğrisi.....	104
Şekil 4.62.	ODSS değerleri (638. istasyon).....	105
Şekil 4.63.	5 Yıllık ODSS değerinin tahmin edilmesi.....	106
Şekil 4.64.	Tahmin edilen ODSS değeri (2014-2024).....	107

TABLÖLAR LİSTESİ

Tablo 2.1.	Pavlov'un klasik koşullanma deneyi sonuçları	7
Tablo 2.2.	Uygunluk izleri (x_i).....	11
Tablo 2.3.	Takviye Terimi ($r(\lambda, y)$)	12
Tablo 2.4.	YSA tabanlı yaklaşımlar.....	12
Tablo 2.5.	Klasik koşullanma modellerinin karşılaştırması.....	13
Tablo 2.6.	Karşılaştırma sonuçları (Malaka ve Hammer, 1996).....	14
Tablo 2.7.	Matematiksel edimsel koşullanma modelleri	20
Tablo 3.1.	Karşılaştırma	27
Tablo 3.2.	Deneklerin beslenme kayıtları (1-4. gün).....	31
Tablo 3.3.	Deneklerin beslenme kayıtları (5-8. gün).....	32
Tablo 4.1.	Öğrenme parametreleri.....	45
Tablo 4.2.	Uyarıcılar arasında benzerlik ilişkisi.....	49
Tablo 4.3.	Uyarıcılar arasındaki korelasyon ilişkisi	50
Tablo 4.4.	DU ile diğer uyarıcılar arasındaki istatistiksel ilişki	55
Tablo 4.5.	Uyarıcılar ve tepki arasındaki ilişki.....	61
Tablo 4.6.	DU ile diğer uyarıcılar arasındaki ilişki	66
Tablo 4.7.	Uyarıcılar arasındaki benzerlik.....	72
Tablo 4.8.	Arduino Mega 2560 mikrodeneği kartının özellikleri	73
Tablo 4.9.	Kullanılan zaman (10 adet testin ortalaması)	85
Tablo 4.10.	İhtiyaç duyulan hafıza değişkenleri ve boyutu.....	85
Tablo 4.11.	Uyarıcı ve bağlı olay sayısına bağlı hafıza ihtiyacı (B).....	86
Tablo 4.12.	Uyarıcı ve tepki sayısına bağlı hafıza ihtiyacı (B)	86
Tablo 4.13.	Test sonuçları	87
Tablo 4.14.	Yapılan çalışmaların doğruluk sonuçları.....	97
Tablo 4.15.	Yapılan çalışmaların doğruluk sonuçları (rastgele sıralamalı).....	98
Tablo 4.16.	Yapılan çalışmaların zamansal sonuçları (sn)	98
Tablo 4.17.	Seçilen istasyonlar ve özellikleri	100
Tablo 4.18.	Kullanılan önerilen davranışçı öğrenme modelinin katsayıları	102
Tablo 4.19.	YSA'nın öğrenme parametreleri	102
Tablo 4.20.	Hata değerleri	103
Tablo 4.21.	Belirli aralıktaki ODSS tahmini	106

SİMGELER VE KISALTMALAR

AÖM	Aşırı öğrenme makineleri
B	Bayt
DVM	Destek vektör makineleri
DT	Doğal tepki
DU	Doğal uyarıcı
GDÖ	Genelleştirilmiş davranışçı öğrenme yöntemi
KT	Koşullu tepki
KU	Koşullu uyarıcı
kYK	k en yakın komşuluk
NOAA	The National Oceanic and Atmospheric Administration, United States Department of Commerce
NU	Nötr uyarıcı
ODSS	Ortalama deniz su seviyesi
OKH	Ortalama karesel hata
OKHK	Ortalama karesel hatanın karekökü
OMYH	Ortalama mutlak yüzde hata
PSMSL	The Permanent Service for Mean Sea Level
UCI	The Machine Learning Repository
YSA	Yapay sinir ağları
M	Etkin uyarıcı sayısı
N	Birleştirilecek/ilişkilendirilebilecek uyarıcı sayısı
OU	Organizma uyarıcı
T	Tepki
TF	Transfer fonksiyonu
TU	Tepkisel uyarıcı
U	Uyarıcı
w	Ağırlık
x	Giriş
y	Çıkış
α	Birleştirme katsayısı
β	Sönme katsayısı
η	Öğrenme adım katsayısı
η_0	Başlangıç öğrenme adım katsayısı
μ	Aritmetik ortalama

1. GİRİŞ

Yapay zeka ve dolayısıyla yapay öğrenme kavramı birçok güncel teknolojik alanda kullanılmaktadır. Öğrenmenin doğal haline benzer biçimde işleyen “davranışsal öğrenme” bazlı bir yapay öğrenme algoritma veya modelin geliştirilmesi bu alanda oldukça yararlı olabileceği düşüncesiyle bu tez çalışması yapılmıştır. İnsan benzeri öğrenme yeteneğine sahip bir modelin, bu tezin sonuçlarında da gösterildiği gibi, literatüre kazandırılması orijinal olabileceği düşünülmüştür.

Yapay öğrenme ve uygulamaları, yaşam kalitemizi artırma amacıyla günden güne artış göstermekte ve bunun için birçok yöntem geliştirilmiş ve geliştirilmeye devam edilmektedir. 1943 yılında McCulloch ve Pitts tarafından YSA’nın matematiksel temelleri ortaya atılmış olan yapay öğrenmeyi Samuel (1959) sisteme ait geçmiş ya da benzetimlerle elde edilmiş verilerden yola çıkarak yüksek bir performans ile yeni örnek verilerin işlenmesine olanak sağlayan yöntemlere verilen genel ad olarak tanımlamıştır. Yapay öğrenme, matematiksel kesinlik isteyen veya ihmallere dayanan sistem modelleme yaklaşımlarına alternatif bir yaklaşım olup, sınıflandırma, kümeleme ve regresyon amacıyla kullanılmaktadır. Yapay öğrenme, denetimli, yarı denetimli, denetimsiz ve takviyeli öğrenme şeklinde olabilmektedir.

Yapay öğrenme diğer modelleme yaklaşımları gibi sisteme ait daha önce yapılmış deney sonuçlarına ihtiyaç duymakta ancak, daha az örnek, veri ve giriş parametresi ile sonuca ulaşabilmektedir. Ayrıca ihmale dayanan sistem modelleme yöntemlerinden farklı olarak etkisinin az olduğu tespit edilen girişler ağırlıklandırma ve özellik seçme/indirgeme gibi yöntemlerle elenebilmektedir. Literatürde birçok farklı özellikte ve yapıda yapay öğrenme yöntemi bulunmaktadır. Alpaydın’a (2004) göre bunun nedeni bir problemle ilgili tüm veri setinin, yani tüm girdilere karşı sistemin oluşturacağı çıktıların bilinmesi ihtimalinin çok düşük olması ve ölçüm veya gözlem tarzından kaynaklı farklı dağılımlarına sahip verilerin değerlendirilmeye tabi tutulmasıdır. Bir problemin çözümü için kullanılacak bir yapay öğrenme yönteminin başarısı öğrenilmesi istenen sistemin yapısına, veri kümesinin karakteristiğine, ulaşmak istenen genelleştirme ya da ezberleme performansına, işlemsel kapasitesine, öğrenme hızına veya sonuç üretme hızına göre belirlenmektedir. Genel anlamda yapay öğrenme yöntemleri klasik yöntemlere göre birçok üstünlüğü ya da kullanım kolaylığı bulunmasına karşın yapay öğrenme yaklaşımlarının başlangıç kabulleri

nedeniyle birçok eksiğinin de olduğunu kabul etmek gerekir. Örneğin, Bayes tabanlı yöntemlerde verinin normal (Gaussian) dağılımında olduğu kabul edilmekte, kYK yönteminde ise verinin tüm özellikleri eşit önemde kabul edilmektedir.

Bilindiği gibi hayvanlar yaşamlarını idame edecek yeteneklerle doğarlar. İnsan ise yaşamasına yardımcı olabilecek sadece sınırlı sayıda koruyucu refleksle doğar ve bu koruyucu refleksler ile başlayan öğrenme süreci daha sonra birçok farklı konuda karmaşık problemleri çözebilen, olayları birbiriyle ilişkilendirebilen ve çevreye adapte olabilen bireylere dönüşmesine kadar uzamaktadır. Bu süreci modellemek amacıyla öğrenmeyi objektif ve ölçülebilir deney sonuçlarına göre değerlendiren davranışçı öğrenme kuramları temel alınarak birçok matematiksel model önerilmiştir. (Watson, 1914 Chester, 1990; Malaka ve Hammer, 1996; Balkenius ve Morén, 1998; Malaka, 1999; Vogel vd., 2004; Tağluk ve Ertugrul, 2015).

Literatürde daha önce önerilmiş modeller ve önerilen bu model dahil olmak üzere klasik koşullanmanın tüm ilkelerini gerçekleştirebilecek bir matematiksel modelin literatürde bulunmadığı tespit edilmiştir. Balkenius ve Morén (1998) klasik koşullanmanın modellenememesinin nedeni olarak detaylı deney eksikliği ve deney düzeneği kurma zorluğu olduğu belirtilmiştir. Ancak Pavlov (1927) tarafından önerilen klasik koşullanma kuramının daha sonra elde edilen birçok deney sonucunu açıklayamadığı görülmüştür (Allen ve Madden, 1985; Malone, 1990; Stuart vd., 1987; Pornpitakpan, 2012). Bu sebeple geliştirilecek yapay öğrenme yönteminde sadece klasik koşullanma değil de tüm davranışçı öğrenme kuramlarının temel alınması gerekmektedir. Mevcut yöntemlerin göstermiş oldukları başarıya rağmen en temel eksiklikleri, eğitim sürecinde karşılaşmadığı herhangi bir duruma karşı yeni cevaplar veya sonuçlar üretebilme kabiliyetinin az olmasıdır; sistem karşılaştığı yeni ortama kendini adapte etmemesidir (Alpaydın, 2002). Yapılan literatür taramasında sürekli öğrenen yöntemlerin geliştirilmiş olduğunu ancak, zamanla değişim gösteren süreçlere yönelik gelişmeye açık yöntemlerin olmadığı ve buna ihtiyaç duyulduğu kanaatine varılmıştır.

Yukarıda verilen bilgilere dayanarak, bu tez çalışması ile insanın öğrenme sürecinde olduğu gibi, sürekli öğrenebilecek, untabilecek, daha önce ürettiği sonuçlardan yararlanabilecek (geriye yayılım) ve daha önce karşılaşmadığı girdiler için yeni sonuçlar üretebilecek dinamik bir öğrenme modelinin tasarlanması hedeflenmiştir. Bu amaçla öncelikle mevcut yapay öğrenme yöntemleri incelenmiştir (Materyal ve Metot bölümüne Bakınız). İnceleme neticesinde

teorisyenlerin farklı bakış açılarıyla farklı yorumlarda bulunmuş olmaları nedeniyle bu teorilerin bazı konularda çeliştikleri ya da birinin önem atfettiği yere diğeri değinmediği öğrenilmiştir. Bu sebeple modellemeye başlanmadan önce mevcut davranışçı teorinin harmanlanarak geliştirilmesine ihtiyaç duyulmuştur. Bunu yaparken bu teorilerin arasında tartışmalı olan kısımlar için hayvan denek kullanılarak deneyler yapılmış ve bu deney sonuçları ile literatür bir araya getirilerek daha genel bir model geliştirilmeye çalışılmıştır.

Bu model kullanılarak sadece klasik koşullanmanın değil, tüm davranışçı kuramların tekrarlanabildiği gösterilmiştir ki bu durum önerilen modelin başarılı olduğunu göstermektedir. Daha sonra bu model Arduino Mega 2560 mikrodenetçi kartına gömülerek söz konusu model donanımsal olarak ta gerçekleştirilmiştir. Veri girişleri için bu donanıma birtakım sensörler bağlanarak algılayıcılar oluşturulmuştur. Klasik koşullanma deneyi elektronik ortamda tekrar edilmiş ve başarılı sonuçlar elde edilmiştir (Araştırma Bulguları bölümüne bakınız). Önerilmiş olan bu model insan öğrenmesi sürecinin daha iyi anlaşılmasına farklı bir bakış açısı getirmiştir. Bu donanımsal model davranış şekillendirmesi, korku sönmülmesi gibi konularda önemli sonuçlar doğurabilme potansiyeline sahip olacağı düşünülmektedir.

Tez çalışmasında önerilen modelin özellikleri detaylı olarak incelenmiş ve ardından yapay öğrenme açısından sistemin performansını irdelemek için model bir takım testlere tabi tutulmuştur. Bu testler için sınıflandırma materyali olarak literatürde bulunan veri setlerinden: diyabet, karaciğer ve epilepsi hastalıkları ile EMG hareket türü (saldırgan-normal hareket) tespiti ve regresyon veri setlerinden Bermuda ve gürültü Sinc veri setleri kullanılmıştır. Önerilen model, YSA ve kYK gibi yöntemler ile kıyaslanmıştır. Önerilen yöntem ile YSA kullanılarak elde edilen başarı oranları Bermuda veri seti hariç, kullanılan tüm diğer veri setleri için birbirine yakın bulunmuştur (Araştırma Bulguları bölümüne bakınız). Zaman sıralı olan Bermuda veri setinde önerilen yöntem, YSA ve kYK'nın OKH değerleri sırasıyla 0,0199, 0,2020 ve 0,1070 bulunmuştur. Önerilen yöntemin Bermuda veri seti için ekstra başarılı sonuç vermesinin nedeni veri setinin zaman sıralı olmasından olabileceği düşünülmektedir. Ayrıca, dünyanın 7 farklı bölgesinden alınmış ODSS verileri kullanılarak yöntemin farklı zaman sıralı veri setleri için de başarısı doğrulanmıştır. Önerilen yöntem, özellikle zaman sıralı veri setlerinde YSA ve kYK'ya göre çok daha başarılı olduğu tespit edilmiştir. Yapılan bu tespitler neticesinde önerilen modelin gelişmeye açık bir yapay öğrenme yöntemi olduğu ve birçok veri setinde başarıyla kullanılabileceği sonucuna varılmıştır.

2. KURAMSAL TEMELLER

Bu bölümde öğrenme kavramı, davranışçı öğrenme kuramları ve ilgili modeller irdelenmiştir.

2.1. Öğrenme

Canlılarda öğrenme çevreye uyum (adaptasyon) süreci olarak tanımlanabilir. Adaptasyon, homeostatis gibi doğal dengeleme yöntemlerinden bilinçli bir uyum sürecine kadar geniş bir yelpazeyi kapsamaktadır (Topses, 2009). Öğrenmenin birçok farklı tanımı mevcut olup bu tanımların popüler olanları aşağıda sunulmuştur.

“Öğrenme bireylerin nesneleri ve yeni durumları yeni bir biçimle algılamaya hazır duruma gelişidir.” (Topses, 2009)

“Öğrenme davranışların referans çerçevesindeki işaret ve ipuçlarında değişme demektir.” (Topses, 2009)

“Öğrenme bireyin kendi yaşantıları aracılığıyla davranışlarında değişiklik oluşturması sürecidir.” (Topses, 2009)

“Öğrenme bireyin olgunlaşması düzeyine göre, çevresiyle olan etkileşimi sonucu, yeni davranışlar kazanması ya da eski davranışlarını değiştirme sürecidir.” (Topses, 2009)

“Öğrenme, yaşantılar aracılığıyla, kişinin davranışlarında oldukça kalıcı ve izli değişiklikler oluşturma sürecidir.” (Topses, 2009)

“Öğrenme bir problem çözme sürecidir, hedefe doğru güdülenmiş kişinin önündeki engelleri dengesizlikten dengeliliğe dönüştürerek, gerginlikten kurtulması anlamına gelir. Güdülenmiş kişi, aşılması gereken engel, çeşitli çözüm çabaları ve amaca ulaşmak bu sürecin öğelerini oluşturur.” (Topses, 2009)

“Bireyin kendi tepkileri, etkinlikleri ve yaşantıları yoluyla çevresine uyum biçimini değiştiren davranışlar geliştirmesini ya da davranışlarının farklılaşmasını öğrenme etkinliğidir.” (Topses, 2009)

“Kişinin daha sonra karşılaşacağı durumlara farklı bir yaklaşım göstermesine neden olan yaşantı ürünü herhangi bir davranış değişmesidir.” (Topses, 2009)

Görüldüğü üzere öğrenme süreci henüz tam olarak anlaşılamamış ve bu sebeple öğrenmenin tam bir tanımı yapılamamıştır. Öğrenme biyo-psiko-sosyal bir varlık olan insanın en temel psikolojik uygulaması olup yaşantılar sonucu meydana gelmekte ve hayatının tamamında sürekli olarak devam etmektedir (Yeşilyaprak vd., 2012). Şöyle ki; hayvanlar yaşamlarını idame edecek yeteneklere sahip olarak doğarlar, insanlar ise doğumlarında sahip oldukları tek becerileri emme içgüdüleri ve birkaç tane refleksif harekettir. Geri kalan her şey öğrenme ile elde edilen kazanımlardır ve başkasının desteğine gereksinim duymadan yaşayabilmesi için birkaç yıllık bir öğrenme süreci gerekmektedir (Yapıcı ve Yapıcı, 2010).

2.2. Davranışçı Öğrenme Kuramları

Psikolojik açıdan öğrenme kuramı insanların nasıl öğrendiklerini açıklamak üzere çeşitli genellemeleri ve ilkeleri içeren bir model ya da sistemdir. Birçok farklı psikolojik öğrenme kuramı önerilmiştir. Bunlar: davranışçı, bilişsel ağırlıklı davranışçı, bilişsel, çoklu zekâ, duygusal zeka ve nörobiyolojik kuramlar olarak ayrıştırılabilir (Fer vd., 2011; Topses, 2009; Veznedaroğlu ve Özgür, 2005).

Yapılan çalışmada ise bu öğrenme kuramlarından davranışçı öğrenme yaklaşımlarını temel alan bir yapay öğrenme yöntemi geliştirilmeye çalışılmıştır. J. B. Watson tarafından sistematik hale getirilen davranışçı yaklaşımın en önde gelen düşünürleri: öğrenmenin fizyolojik kısmı ile ilgilenen Ivan Petroviç Pavlov, psikolojik yanı ile ilgilenen B. F. Skinner ve E. L. Thorndike'dir (Schunk, 2012). Davranışçı öğrenme kuramları felsefik olarak pragmatist (yararcı) felsefeye dayanır ve temel bilimsel ilkesi determinizm (nedensellik) ilkesidir (Topses, 2009).

Watson'a göre "mekanizma, davranışı açıklar" (Yeşilyaprak vd., 2012). Yani, davranışların gerçek nedeni sinir sistemidir. Bu görüşe göre davranışçılar temel de "objektif olmayan, kanıtlanamayan, somut olarak ölçülüp değerlendirilmeyen hiçbir yaklaşımın değeri yoktur" (Veznedaroğlu ve Özgür, 2005) ilkesine dayandırılmakta ve dolayısıyla içsel yaşantılar reddedilmektedir. Ayrıca öğrenme sürecini uyaran ve tepki süreci olarak yorumlanmaktadır. Özetle, öğrenmenin daha ziyade çevresel etmenlerin (uyarıcılar) etkisiyle olduğu iddia edilmektedir (Topses, 2009). Topses (2009), davranışı "organizmanın dışarıdan ya da içeriden gelen uyarılara verdiği iç ve dış tepkilerin bütünü" olarak tanımlamıştır. Yani, organizmanın her türlü etkinliğine davranış denmektedir.

Yapılan çalışmada davranışçı öğrenme teorileri temel alınarak yeni bir yapay öğrenme süreci modellenmiştir. Davranışçı teorilerin bu tezde temel alınma nedenleri:

- Öğrenmeyi deneyim sonucunda davranışlarda açık olarak görünen değişiklik olarak kabul edilmesi,
- Öğrenenin kafası boş bir kutu olarak kabul edilmesi ve öğrenenin davranışları ve çevresi arasındaki etkileşim üzerinde yoğunlaşması,

olarak sayılabilir. Öğrenme ile ilgili araştırma yapan Pavlov, Watson ve Thorndike'in, bu araştırmaları insan ve hayvanların laboratuvarlarda belli bir durumda nasıl davrandıkları deneysel çalışmalarla destekledikleri için onların bu yaklaşımlarına davranışçı yaklaşım denmektedir. Davranışçı kuramlar, öğrenmeyi; uyarıcı (organizmayı harekete geçiren iç ve dış olaylardır) ile davranış arasında bağ kurma işi olarak görür. Bu nedenle daha çok davranış ve davranışa neden olan uyarıcılarla ilgilenmektedirler.

2.3. Pavlov'un Yaklaşımı

Klasik koşullanma (şartlanma, tepkisel şartlanma, koşullu refleks) yolu ile öğrenme tezi, ilk kez Nobel ödüllü Rus bilim adamı Pavlov (1927) tarafından önerilmiştir. Pavlov sindirim sistemi ile ilgili yaptığı araştırmada, köpeğin fizyolojik olarak, yiyecek ağzına geldiğinde salya salgılaması gerekirken, henüz eti görmeden deneyi yapan kişinin ayak seslerini duyduğunda da aynı güçte salya salgıladığını fark etmiş ve bu durumu laboratuvar ortamında incelemeye çalışmıştır. Laboratuvar ortamında köpeğe düzenli olarak yemek vermeden önce zil sesi vermiş ve zamanla köpeğe yemek verilme dahi zil sesini duyduğunda köpeğin salya salgıladığını gözlemlemiştir.

Bu deneyde başlangıçta köpeğe verilen zil sesi, normal şartlarda köpekte bir tepkiye (salya salımı) neden olmayan ya da ilişkisi olmayan nötr uyarıcıdır (NU). Yiyecek (et) ise normal şartlarda köpeğin salya salgılamasına neden olan ya da ilişkisi olan doğal uyarıcıdır (DU). Deneysel sürecin sonunda köpeğe verilen zil sesi ise köpeğin salya salgılamasına neden olan koşullu uyarıcı (KU) halini almıştır. DU ve KU'ya köpek tarafından verilen tepkiye (salya salgılama) sırasıyla doğal tepki (DT) ve koşullu tepki (KT) olarak isimlendirilebilir.


Klasik koşullanma, deneğin NU'ları süreç içerisinde DU ile ilişkilendirerek DU gibi algılanması ve bu uyarıcıya karşı DT gibi bir tepki yani KT vermesi süreci olarak bilinmektedir (Schunk, 2012; Pavlov, 1927). Diğer bir deyişle bu süreçte

NU'ların KU'lara dönüşmesi ve buna karşı KT üretilmesi klasik koşullanma olarak ifade edilmektedir. Eğer bu süreçte zil sesi köpeğin salya salgılamasına neden oluyorsa köpek koşullanmıştır (Veznedaroğlu ve Özgür, 2005; Pavlov, 1927). Pavlov'un deneyi Tablo 2.1'de özetlenmiştir.

Tablo 2.1. Pavlov'un klasik koşullanma deneyi sonuçları (Yeşilyaprak vd., 2012)

İşlem Sayısı	1. Etki	2. Etki	Tepki
1	zil (NU)	---	Yok
2	.	Et (DU)	Salya (DT)
3	Zil (NU)	Et (DU)	Salya (DT)
.	.	.	.
m	Zil (NU)	Et (DU)	Salya (DT)
.	.	.	.
n	Zil (KU)	---	Salya (KT)

Tablo 2.1'de verilen deneysel çalışma dizaynında elde edilen sonuçlar Şekil 2.1'de gösterilmiştir.



Şekil 2.1. Koşullanma süreci

Görüldüğü gibi denek süreç içerisinde koşullanmıştır. Klasik koşullanma karmaşık insan düşüncelerini açıklayamamakta; duygusal tepkiler, refleksi davranışlar, fobiler ve boş inançlarla ilgilenmektedir (Yeşilyaprak vd., 2012; Veznedaroğlu ve Özgür, 2005). Temelde koşullu öğrenme sonucu organizma daha önce vermediği yeni bir tepki vermez; yani yeni bir KT üretilmez ama öğrenme süreci ile mevcut KT'nin oluşma yoğunluğu veya ihtimali artar. Hangi DT'nin hangi uyarıcıya ve hangi şiddette yapılacağı sonradan öğrenilir (Yeşilyaprak vd., 2012). Şöyle ki, tekrarlanan DU, KU ve tepki ilişkisi istenen koşullanma bağının

gücünü ve DU ile KU uygulama süreleri arasındaki zaman farkı ise tepkinin şiddetini belirlemektedir (Erasmus, 2007).

2.3.1. Klasik Koşullanmanın Temel İlkeleri

Klasik koşullanmanın temel ilkeleri aşağıda sıralanmıştır.

- Bitişiklik: KU ve DU'ların verilme zamanının birbirine yakın ve peş peşe olmasıdır. Örneğin, Pavlov'un deneyinde köpeğe et ve zil sesinin peş peşe verilmesi gibi (Fer vd., 2011).
- Habercilik: KU'nın DU hakkında bilgi verici nitelikte olması gerektirir. Örneğin, Pavlov'un deneyinde zil sesinin yiyeceğin (etin) habercisi olması gibi (Fer vd., 2011).
- Pekiştirme: Öğrenilen tepkinin organizmaya yerleşmesi ve aynı şekilde devam etmesi için yapılan işlemlerdir (Fer vd., 2011).
- Sönme: KU tek başına verildiği ve bu durum pekiştirildiği takdirde bir müddet sonra tepkinin azalmasıdır (Schunk, 2012). Yani, KU'nın artık tek başına KT'yi oluşturamamasıdır. Örneğin, Pavlov'un deneyinde DU (et) verilmeden sadece KU (zil sesi) verilmesi ve bu durumun pekiştirilmesi durumunda KU'ya (zil sesi) olan KT'nin (salya) zamanla yok olmasıdır (Fer vd., 2011).
- Uyarıcı genelleme: Organizmanın KU'ya benzer diğer uyarıcılara da KU'ya verdiği tepkinin aynısını verme eğilimidir (Schunk, 2012; Fer vd., 2011).
- Uyarıcı ayırt etme: Organizmanın koşullanma sürecinde kullanılan KU'yı, diğerlerinden ayırt ederek farklı bir tepkide bulunma eğilimidir (Schunk, 2012, Fer vd., 2011).
- Gölgeleme: İki KU birlikte verildiğinde daha çok dikkat çeken uyarıcıya verilen tepkinin organizma tarafından verilmesidir (Fer vd., 2011).
- Öğrenilmiş acizlik (çaresizlik): Organizma ne kadar çaba harcarsa harcarsın, içinde bulunduğu durumu değiştiremeyeceğini öğrenerek artık bunu değiştirmek için çaba harcamaması ve bunu yaşantısına da genellemesidir, yani başarısızlığın öğrenilmesidir (Fer vd., 2011).
- Kendiliğinden geri gelme: Sönen KT'nin aniden ortaya çıkmasına denir. Örneğin, Pavlov'un deneyinde KU olan zil sesinin sönmesinden sonra herhangi bir zamanda kendiliğinden tekrar ortaya çıkması durumudur.
- Dereceli (üst düzey) koşullandırma: KU'ya bağlı olarak yeni bir koşullanmanın oluşmasıdır. Örneğin, Pavlov'un deneyinde zil sesiyle

beraber ışık da verildiğinde ve bu durum pekiştirildiğinde köpek bir süre sonra ışığa da zil sesine verdiği tepkiyi göstermektedir (Fer vd., 2011).

- Tekrar kazanım: Bir şeyi ikinci defa öğrenme birincisinden daha hızlı üçüncüsünden daha yavaştır (Pavlov, 1927).

2.3.2. Klasik Koşullanmanın Önemi ve Çıktıları

Klasik koşullanma kuramının belki de en önemli çıktısı insanın tanımı ile ilgilidir. Descartes ve birçok düşünür insan bedenini mükemmel bir makine olarak ifade etmektedirler. Onlara göre öğrenme ve diğer fonksiyonlar tamamen beyin ile alakalıdır. Ancak Pavlov'un yaptığı deneyler ve daha sonra bu konuda yapılan çalışmalar göstermiştir ki insan vücudunu sadece bir makine olarak ifade etmek eksik bir tanımdır. Aristoteles'in önerdiği gibi, insan çevresi ile iletişim halinde olan yaşayan canlı bir makinedir ve çevresi ile olan iletişimi nedeniyle öğrendikleri kendi vücudundan ve çevresel etmenlerden etkilenmektedir (Malone, 1990). Örneğin, Miguez vd. (2014) stresin sonuçlarını inceledikleri çalışmalarında; stresin koşullu analjezi (acı yetimi) ve hiperanaljezi hastalıklarını tetiklediğini belirtmişlerdir. Ayrıca Dalla ve Shors (2009) yaptıkları çalışmada cinsiyet farkının öğrenme üzerindeki etkilerini araştırmış ve öğrenme sürecinin fiziksel etmenler ile ilintili olduğunu ortaya koymuşlardır.

Pavlovcu yaklaşıma göre, insan bazı refleks davranışları ile doğar ve daha sonra bu davranışları KU'larla hayatlarının her alanına yayarlar (Malone, 1990). Bu materyalist görüş başta batı dünyasında ilgi görmediği halde, SSCB'de Stalin döneminde ciddi olarak desteklenmiştir. Ancak daha sonra davranışların nedeninin araştırılmasında bilimsel bir araç olarak görülmüş ve Darwinci yaklaşımın gelişmesi ile beraber, batı akademisyenleri Pavlov'un çalışmalarından klasik koşullanma ile ilgilenmişler ve bu çalışmalar davranışçı öğrenme teorilerinin temeli olmuştur (Malone, 1990).

Klasik koşullanma insan davranışlarının temel ve en derin tepkisi olan refleksler ile ilgilendiğinden, insan veya hayvan davranışlarının nedenlerini anlama ve onları kontrol etme nedenleri önemli bir araştırma alanı olmuştur. Bu amaçla insan ve hayvan denekler kullanılarak birçok çalışma yapılmıştır (Shechner vd., 2014; Vervliet ve Geens, 2014; Yoshida vd., 2004). Yapılan deneylerle insan ve hayvanların öğrenme süreçleri, tepkileri, davranışları ve duyguları ile ilgili çok zengin bilgiler elde edilmiştir. Bu nedenle klasik koşullanma süreci psikoloji, davranış bilimi, kısa ve uzun dönem hafıza, sinir sistemi biyolojisi ve benzeri

farklı bilimsel alanlarca da incelenmiştir (Bouton ve Moody, 2004; Delamater ve Westbrook, 2014; Todd vd., 2014).

Klasik koşullanma ile insan ve hayvanlarda istem dışı tepkilerin oluşması süreci açıklandığından özellikle pazarlama, reklam ve müşteri davranışları alanlarında yoğunluklu olarak analiz edilmiştir (Allen ve Madden, 1985; Stuart vd., 1987; Pornpitakpan, 2012). Ayrıca, korkuya neden olarak koşullanma süreçleri birçok insan ve hayvan denekler üzerinde test edilmiştir (Vervliet ve Geens, 2014; Yoshida vd., 2004; Li vd., 2007).

Allen and Madden (1985) yaptıkları klasik koşullanmanın reklam alanında etkisini inceleyen derleme çalışmasında, klasik koşullanmanın reklamların etkisini anlamada ve etkin reklam hazırlamada önemli olduğunu belirtmişlerdir. Klasik koşullanmanın müşteri üzerindeki etkileri ile ilgili yapılan çalışmalarda klasik koşullanmanın müşteri davranışlarını manipüle etmek için kullanılabilecek bir araç olduğu belirtilmiştir (Pornpitakpan, 2012; Stuart vd., 1987).

Li vd. (2007) lateral amigdal sinir hücrelerini biyo-fiziksel olarak modellemişlerdir. Bu modellemede Hodgkin-Huxley sinir modeli ve Hebbian türü sinaptik plastisite öğrenme yapısı kullanılmıştır. Yaptıkları çalışmada klasik koşullanma yoluyla koşullanma ve sönümleme süreçlerini başarıyla modellemişlerdir. Erasmus (2007) RealNeuron YSA modeli ağlar kullanılarak klasik koşullanma süreci çağrışımsal öğrenme tabanlı olarak modellemiştir. Yaptıkları çalışmada önerdikleri modelin basit ve rahatlıkla uygulanabilir olduğunu belirtmişlerdir. Salotti ve Lepretre (2008) yaptığı çalışmada klasik ve edimsel koşullanma mekanizmalarını kullanarak öğrenebilen ve hareket edebilen bir robot modeli tasarlamışlardır. Ayrıca, dinamik bir öğrenme kuramı olan klasik koşullanma; koşullanma ve unutma gibi kabiliyetleri nedeniyle ağ güvenliğinde başarılı olarak uygulanmıştır (Liu ve Ding, 2008 ve 2009). Chester (1990) klasik koşullanmanın akıllı kontrol yöntemi olarak kullanılabileceğini belirtmiştir.

2.3.3. Hesapsal Modeller

Klasik koşullanmanın en temel öğrenme yaklaşımlarından biri olduğu ve birçok potansiyel kullanım alanı olduğu halde tüm özellikleri ile modellenememesi birçok araştırmacının ilgisini çekmiştir. Klasik koşullanmayı modellemek için mevcut yapay öğrenme algoritmalarını kullanan birçok çalışma yapılmıştır. Bunlar arasında Hebbian öğrenme algoritması kullanan LA piramit hücre (Li vd., 2007), Bayes yöntemi (Courville et al., 2003; Gershman ve Niv, 2012), gizli Markov

modeli (Austermann ve Yamada, 2008), ve YSA tabanlı yaklaşımlar (Liu ve Ding, 2008 ve 2009; Clouse vd., 1997) sayılabilir. Ayrıca, klasik koşullanma sürecinin daha iyi anlaşılabilmesi ve kullanılabilmesi amacıyla birçok matematiksel model önerilmiştir. Bu modeller kabaca takviyeli öğrenme ve YSA tabanlı yaklaşımlar olarak ikiye ayrılabilir (Tagluk ve Ertugrul, 2015).

-Takviyeli öğrenme tabanlı modeller

En yaygın kullanılan takviyeli öğrenme tabanlı yaklaşımlar: Sutton-Barto (SB) (Sutton ve Barto, 1981), SOP (Wagner, 1981), TD (Sutton ve Barto, 1990), DR (Klopf, 1989), Balkenius Modeli (BM) (Balkenius ve Moren, 1999) ve CP (Malaka vd., 1995) modelleridir (Balkenius ve Morén, 1998; Malaka ve Hammer, 1996). Takviyeli öğrenme denklemlerinin çıkışına ait genel denklem:

$$y = f\left(\sum_i w_i x_i\right) \quad (2.1)$$

şeklindedir. Ağırlık değişimleri ise:

$$\Delta w_i = \beta \bar{x}_i r(\lambda, y) \quad (2.2)$$

ile ifade edilebilir. Burada: w_i ağırlıkları, Δw_i , ağırlıkların değişimini, x_i girişi, $\bar{x}_i$ x_i 'nin uygunluk izi ve r ise tahmin edilen çıkış (λ) ile gerçek çıkış (y) arasındaki ilişkiye dayanan takviye terimini göstermektedir (Malaka ve Hammer, 1996). Modellerin uygunluk izleri ve takviye terimleri Tablo 2.2. ve 2.3.'te özetlenmiştir

Tablo 2.2. Uygunluk izleri ($\bar{x}_i$)

Model	Denklem	No
SB / TD	$\bar{x}_i(t+1) = \alpha \bar{x}_i(t) + x_i(t)$	(2.3)
DR	$\bar{x}_i(t+1) = \sum_{j=0}^{\tau} c_j w_i(t-j) [x_i(t-j) - x_i(t-j-1)]$	(2.4)
CP	$\bar{x}_i(t) = \begin{cases} \bar{x}_i(t+1) = \alpha_1 \bar{x}_i(t) + [x_i(t) - x_i(t-1)], & x_i(t) > 0 \\ \bar{x}_i(t+1) = \alpha_2 \bar{x}_i(t) + [x_i(t) - x_i(t-1)], & x_i(t) \leq 0 \end{cases}$	(2.5)
SOP	$\begin{aligned} \bar{x}_i(t+1) &= \alpha_1 \bar{x}_i(t) + \gamma_1 (1 - \bar{x}_i(t) - \hat{x}_i(t)) \\ \hat{x}_i(t+1) &= \alpha_2 \hat{x}_i(t) + (1 - \alpha_1) \bar{x}_i(t) \end{aligned}$	(2.6)

Tablo 2.3. Takviye Terimi ($r(\lambda, y)$)

Model	Denklem	No
SB / DR	$\lambda(t) - \lambda(t-1) + \sum_i w_i(t) * x_i(t) - \sum_i w_i(t-1) * x_i(t-1)$	(2.7)
TD	$\lambda(t) + \gamma \sum_i w_i(t) * x_i(t+1) - \sum_i w_i(t) * x_i(t)$	(2.8)
CP	$\bar{\lambda}(t) + \gamma \sum_i w_i(t) * x_i(t) - \sum_i w_i(t-1) * x_i(t-1)$ $\bar{\lambda}(t+1) = \alpha \bar{\lambda}(t) + [\lambda(t) - \lambda(t-1)]$	(2.9)
SOP	$\bar{\lambda}(t) - \hat{y}(t)$ $\bar{\lambda}(t+1) = \alpha_1 \bar{\lambda}(t) + \gamma_1(1 - \bar{\lambda}(t) - \hat{y}(t))\lambda(t)$ $\hat{y}(t+1) = \alpha_2 \hat{y}(t) + \gamma_2(1 - \bar{\lambda}(t) - \hat{y}(t))y(t)$	(2.10)

burada α , α_1 , α_2 , γ , γ_1 ve γ_2 öğrenme katsayıları 0 ve 1 aralığında değer almaktadır.

-Yapay sinir ağları tabanlı modeller

YSA kullanan popüler yöntemler Klopff (Klopff, 1988), ağ davranış yönetme (PM, Liu ve Ding, 2008 ve 2009) ve uyarlamalı eşik öğrenme (ATL) (Clouse vd., 1997) modelleridir. Bu modellerin matematiksel denklemleri Tablo 2.4'te verilmiştir.

Tablo 2.4. YSA tabanlı yaklaşımlar

Model	Denklem	No
Klopff	$y(t) = \sum_{i=1}^n w_i(t) x_i(t) - \theta$ $\Delta w_i(t) = \Delta y(t) \sum_{j=1}^{\tau} c_j w_i(t-j) \Delta x_i(t-j)$	(2.11)
PM	$y(t_j) = \sum_{i=1}^n V_i CS_i(t_j) + V_{US} US$ $\Delta V_j = c * \eta_j * y(t_j) * x(t_j)$ $\eta_j = \begin{cases} 1 - \frac{t_j - t_{j-1}}{2T} & 0 < t_j - t_{j-1} \leq T \\ 1.5 - \frac{t_j - t_{j-1}}{T} & T < t_j - t_{j-1} \end{cases}$	(2.12)
ATL	$w_{ji}(t + \Delta t) = w_{ji}(t) + \begin{cases} \beta_w \alpha_{ji}(t) [S_i(t) - H_i(t)] & S_i(t) - H_i(t) > 0 \\ \eta_w \alpha_{ji}(t) [S_i(t) - H_i(t)] & S_i(t) - H_i(t) < 0 \end{cases}$ $H_i(t + \Delta t) = H_i(t) + \begin{cases} \beta_h [S_i(t) - H_i(t)] & S_i(t) - H_i(t) > 0 \\ \eta_h [S_i(t) - H_i(t)] & S_i(t) - H_i(t) < 0 \end{cases}$ $\alpha_{ji}(t) = \left[(1 - \gamma) \frac{W_{us}(t) W_{cs}(t) CS(t)}{W_{us}(t) W_{cs}(t) CS(t) + W_{us}(t) US(t)} + \gamma \alpha_{ji}(t - \Delta t) \right] S_i(t)$ $S_i(t) = \tanh[W_{us}(t) W_{cs}(t) CS(t) + W_{us}(t) US(t) + e^{-D_1 \Delta t} S_i(t - 1)]$	(2.13)

c_j Klopff modelindeki öğrenme katsayısıdır (Klopff, 1988). T ön bellek devri, j anlık zaman, US başlangıç değeri (x_0), CS giriş (x_i) ve c ise küçük bir katsayıdır (Liu ve Ding, 2008 ve 2009). ATL modeline ait $\beta_w, \eta_w, \beta_h, \eta_h$ parametreleri öğrenme ve γ unutma katsayıları, α_{ji} uygunluğu, H_i eşik değerini ve S_i ise çıkışı ifade etmektedir, bu modelde eşik değeri ve ağırlıklar güncellenmektedir (Clouse vd., 1997).

2.3.4. Karşılaştırma Çalışmaları

Chester (1990) yaptığı çalışmasında Sutton-Barto (1981), Klopff (1989) ve Grossberg-Schmajuk (1989) modellerini karşılaştırmıştır. Bu üç modelin de ortak özelliği üçünde Hebbian öğrenme yaklaşımına dayanmasıdır. Ancak bu yöntemlerin nasıl hatırladıkları konusunda farklılıklar göstermektedirler. Chester (1990) yaptığı karşılaştırma Klopff modelinin Sutton- Barto modeline göre daha başarılı olarak bağlantı oluşturduğunu belirtmiştir. Ayrıca Grossberg- Schmajuk modelinin geçici veya ani ilişki kurmada daha başarılı olduğunu ancak normal durumlara ani geçişlerde tepki hızı açısından yavaş kaldığını belirtmiştir. Cheung vd. (1992) gerçek zamanlı olarak kullanılacak klasik koşullanma modellerinden Sutton-Barto (1981 ve 1982), Rescorla-Wagner (1972) ve Klopff (1988 ve 1991) modellerini karşılaştırmışlardır.

Balkenius and Moren (1998) popüler klasik koşullanma modellerinden Sutton-Barto (1981), TD (Sutton-Barto, 1987), DR (Klopff, 1982), Balkenius (1995, 1996, 1998), Schmajuk-DiCarlo (1992) modellerini klasik koşullanma deneylerinde tespit edilen özellikleri gerçekleştirebilmesi açısından karşılaştırmışlardır. Elde ettikleri sonuçlar Tablo 2.5’te özetlenmiştir.

Tablo 2.5. Klasik koşullanma modellerinin karşılaştırması (Balkenius ve Moren, 1998)

	SB	TD	Klopff	Balkenius	SD
İzli Koşullanma	+	+	+	+	+
Gecikmeli Koşullanma	-	+	$\pm$	+	+
ISI Eğrisi	-	+	$\pm$	$\pm$	+
S Şekli	-	-	+	+	-
Kazanma					
Sönme	+	+	+	+	+
Tekrar Kazanım	-	-	$\pm$	-	+
Gölgeleme	+	+	+	+	+
Dereceli Koşullandırma	$\pm$	$\pm$	+	+	-
Kendiliğinden Geri Gelme	-	-	-	-	-
Koşullu Menetme	+	+	+	+	+
Kolaylaştırma	+	+	+	+	+

Malaka ve Hammer (1996) gerçek zamanlı olarak kullanılabilecek Sutton-Barto (1981), SOP (Wagner, 1981), TD (Sutton-Barto, 1990), DR (Klopf, 1989) ve CP (Malaka, 1995) modellerini karşılaştırmış ve elde ettikleri sonuçlar Tablo 2.6’da gösterilmiştir.

Tablo 2.6. Karşılaştırma sonuçları (Malaka ve Hammer, 1996)

	SB	DR	TD	CP	SOP	CP/TD
Pozitif İleri Koşullanma	+	+	+	+	+	+
Deneyimsiz Gecikmeli Koşullanma ile Menetme	+	+	-	-	+	+
Deneyimli Gecikmeli Koşullanma ile Menetme	+	+	+	-	+	+
Sönme	+	+	+	+	+	+
Gölgeleme	+	+	+	+	+	+
Gecikmeli Koşullanma	-	+	±	+	±	+
Koşullu Menetme	+	+	+	+	+	+
İlişkilendirilmemiş Menetme	-	-	-	-	±	±
Üst Düzey Koşullanma	+	±	+	+	-	+
Tam Seri Koşullanma	-	-	+	+	+	+

Sonuç olarak Tablo 2.5 ve 2.6 incelendiğinde şu ana kadar önerilmiş modellerin her birinin bir takım eksiklerinin olduğu ve hiçbirinin tüm klasik koşullanma deneyleri sonucu elde edilen çıktıları karşılayamadığı görülmektedir (Tagluk ve Ertugrul, 2015).

2.4. Watson’ın Kuramı

Watson’ın bağ (bitişiklik) kuramına göre öğrenme sadece çevresel etmenlerle alakalıdır (Yapıcı ve Yapıcı, 2005 ve 2010; Topses, 2009; Watson, 1959). Watson için en önemli şey, tekrarlanma sıklığıdır. Watson’ın kuramında Thorndike’in kuramından farklı olarak memnuniyet veya hoşnutsuzluk gibi psikolojik kavramlar ve pekiştirgeçlerin öğrenmeye etkisi yoktur (Yeşilyaprak vd., 2012). Ayrıca, Watson “bir insan ne öğrenmişse odur” ilkesini benimsemiştir. Watson psikolojik rahatsızlıkların anormal olarak kabul edilen tesadüfi olumsuz öğrenmeden kaynaklandığını iddia etmiştir (Yeşilyaprak vd., 2012) ve “Bana bir düzine sağlıklı bebek ve onları istediğim şekilde yetiştirme imkânı verin. Onlardan rastgele herhangi birini alıp yetenekleri, eğilimleri, ırk ve atası kim olursa olsun, onu seçeceğim herhangi bir alanda; örneğin doktor, hukukçu, sanatçı, tüccar, hatta dilenci, hırsız yapabilirim” iddiasında bulunmuştur (Watson, 1959). Ayrıca, Küçük Albert Deneyi olarak adlandırılan Albert adındaki 11 aylık bir bebeğe koşullanma yoluyla ilk başta nötr bir uyarıcı olan beyaz fareye (bazı kaynaklarda tavşan olarak

geçmektedir (Yeşilyaprak vd., 2012)) karşı DU olan çekicin yüksek sesini kullanarak korku duygusu oluşturulmuştur (Watson ve Rayner, 1920).

Watson'ın kuramının temel ilkeleri aşağıda listelenmiştir (Yapıcı ve Yapıcı, 2005 ve 2010).

- En son (yenilik) ilkesi: Bir uyarıcıya daha önce o uyarıcıya verilen en son tepkinin verilme ihtimali daha yüksektir.
- Sıklık ilkesi: Bir uyarıcıya verilen en sık tepkinin aynı uyarıcı ile karşılaşıldığında tekrarlanma ihtimali daha yüksektir.
- Bağ (bitişiklik) ilkesi: Karmaşık ya da beceri isteyen bir davranışı oluşturan koşullu uyaran ve tepki arasında zincirleme bir bağın oluşturulması gerekir.

2.5. Guthrie'nin Yaklaşımı

Guthrie öğrenme ile ilgili tek denemede öğrenme ve bitişiklik kuramı teorilerini ortaya koymuştur. Guthrie öğrenmeyi uyarıcı ve tepki arasındaki işaret ve bitişikliğin sonucu ortaya çıkan ve uyarıcının yapısıyla tepki yapısındaki eşleşmeyle tanımlamıştır (Topses, 2009). Guthrie kuramlarında tepki yerine beceri ve hareket kavramlarını kullanmaktadır ve uyarıcı – tepki bağı yerine alışkanlık kavramını kullanmaktadır. Ayrıca, Guthrie pekiştirmenin uyarıcı – tepki bağına gücünü artırmadığını, organizmanın uyarıcıya verdiği son tepkiye benzer tepki verme eğiliminde olduğunu belirtmiştir. Ancak beceri, birçok hareketten meydana geldiği için tekrarın gerekli olduğunu ifade etmiştir. Guthrie göre yapılarak öğrenilmelidir. Ayrıca Thorndike'ın önerdiği deneme-yanılma ilkesini ret etmiştir (Schunk, 2012; Yapıcı ve Yapıcı, 2005 ve 2010). Öğrenme için sıklık ya da pekiştirme isteyen teorilerin aksine, Guthrie göre öğrenmenin tek bir deneme ile sağlandığını belirtmiştir (Guthrie, 1946).

Guthrie'ye göre ket vurma yoksa öğrenilen şey unutulmaz ve öğrenmede en önemli etmen hazır oluşturmaktır. Ödül ve cezaların ise öğrenme üzerinde dolaylı (çağırmsal) etkisi vardır ve bu etki davranıştaki değişim kadardır (Yeşilyaprak vd., 2012). Ayrıca, Guthrie'ye göre ceza uyarıcı ile eşzamanlı olmalıdır (Guthrie, 1934). Guthrie laboratuvarlarda yapılan deneylerin gerçek dünyayı yansıtmadığını belirtmiştir.

Guthrie'nin yaklaşımının temel ilkeleri aşağıda listelenmiştir (Yapıcı ve Yapıcı, 2005 ve 2010).

- Bitişiklik: Bir hareket ya da davranış oluşturan uyarıcı o davranışı ya da hareketi belirtir.
- Dikkat: Organizma öğrenmeye odaklı olmalıdır.
- Hazır oluş: Organizma öğrenilen tepkiyi vermek için tüm kaynakları ile hazır olmalıdır.

Ayrıca, Guthrie olumsuz davranışları değiştirmek için üç yöntem önermiştir (Yapıcı ve Yapıcı, 2005 ve 2010; Topses, 2009). Bunlar:

- Eşik (alıştırma) yöntemi: Tepki verilemeyecek kadar zayıf uyarıcılar ile davranışın değiştirilmesidir (Schunk, 2012). Örneğin, atları eyere alıştırmak için önce battaniye kullanılması.
- Yorma (bıktırma, yorgunluk) yöntemi: Değiştirilmek istenen davranışa ait uyarıcının aşırı yoğun şekilde verilmesidir (Schunk, 2012). Örneğin, sigara alışkanlığından kurtarmak için hiç ara vermeden aşırı miktarda sigara içirilerek sigara içme alışkanlığının bırakılması.
- Bağdaşmayan uyarıcılar (zıt tepki) yöntemi: Uyarıcıyı ortamda arzu edilmeyen bir durumda vermektir (Schunk, 2012). Örneğin, tavuk yeme alışkanlığı olan bir köpeğin boynuna tavuk bağlama.

2.6. Thorndike'in Yaklaşımı

Thorndike öğrenmenin uyarıcı-tepki arasındaki bağların güçlenip, sönmesi ile ifade edilen, küçük adımlarla ilerleyen ve temelde deneme yanılma ile işleyen bir süreç olduğunu belirtmiştir. Watson ve Guthrie'nin aksine, Thorndike tatmin ve rahatsızlıkların doğru tepkiyi belirlemede önemli olduğunu belirtmiştir. Ayrıca, Thorndike'a göre klasik koşullanma tüm öğrenme türlerini karşılamamaktadır. Thorndike'nın bağlaşımcılık (ilişkilendirme) kuramında öğrenmeyi problem çözme olarak tanımlamakta (Yapıcı ve Yapıcı, 2010) ve bunu da uyarıcı ve tepki arasında bir sinirsel bir bağ (bağlaşımcılık) ile açıklamaktadır (Schunk, 2012). Thorndike yaptığı deneylerde bir kediyi sadece bir zincire dokunarak kurtulabileceği bir kutuya (problem kutusu) koymuş, kedinin problemi çözme hızı sabit ve aşamalı olarak arttığı ve her başarılı deneme sonucunda daha hızlı başarıya ulaştığını görmüştür (Fer vd., 2011; Schunk, 2012).

2.6.1. Thorndike'in Yaklaşımının Temel İlkeleri

Thorndike'in geliştirdiği öğrenme teoreminin temel ilkeleri ve kuralları aşağıda listelenmiştir.

- Baęlaşımıcılık ilkesi: Uyarıcı ve tepki arasında baęlantı olmalıdır (Fer vd., 2011).
- Deneme yanılma ilkesi: Thorndike problem çözmenin neden sonuç ilişkisi yerine, deneme yanılma yoluyla öğrenildiğini belirtmiştir (Schunk, (2012). Şöyle ki bir problem çözölürken birçok yol denenir; başarılı sonuç veren yöntemler benzer problemler için tekrarlanarak güçlenir başarıya ulaşmayan yöntemler ise zamanla kaybolur (Fer vd., 2011).
- Küçük adımlar ilkesi: Thorndike'a göre problem çözme süresi ardışık denemeler sonucu kısalmaktadır. Bu açıdan bakıldığında karmaşık bir problemin çözümünün öğrenilmesi için problem basit adımlara bölünerek öğrenme görevleri adım adım basitten karmaşıęa doğru düzenlenmelidir (Fer vd., 2011).
- Etki (etki-sonuç, haz-elem) kuralı: Tatmin edici şekilde sonuçlanan tepkiler güçlenir, rahatsız edici şekilde sonuçlanan tepkilerin baęa bir etkisi yoktur (Fer vd., 2011; Topses, 2009).
- Tekrar (alıştırma, egzersiz) kuralı: Tekrar öğrenmeyi güçlendirir, tekrar etmeme ise zayıflatır (Fer vd., 2011; Topses, 2009).
- Hazır bulunuşçuluk (oluş) kuralı: Öğrenmenin doyurucu olması için organizma öğrenmeye hazır olmalıdır (Yapıcı ve Yapıcı 2005 ve 2010; Topses, 2009). Ayrıca organizmanın harekete hazır olduğunda bunu gerçekleştirmesinin ödüllendirici, hazır olmadığında gerçekleştirmeye zorlanması veya hazır olduğunda gerçekleştirememesinin cezalandırıcı olduğunu ifade etmektedir (Yapıcı ve Yapıcı 2005 ve 2010; Topses, 2009; Fer vd., 2011).
- Çeşitli tepki kuralı: Öğrenenin öğrenme materyaline karşı tepki vermesi gerekmektedir (Topses, 2009).
- Tutum ve tavır kuralı: Öğrenenin tüm kaynaklarını öğrenme amacına odaklaması gerekmektedir (Topses, 2009).
- Öğrenilen materyalin temel unsurlarına tepki gösterme kuralı: Öğrenme materyalinin kritik noktalarına tepki vermesi gerektięi ile ilgilidir (Topses, 2009).
- Baęlantı kurarak geçiş kuralı: Eski uyarıcı ile yeni uyarıcı arasında baęlantı kurarak, eski uyarıcıya verilen tepkinin yeni uyarıcıya verilmesidir (Topses, 2009).
- Transfer (geçiş) kuralı: Eski öğrenilenlerin, yenilerin öğrenilmesinde kolaylık sağlamasıdır (Topses, 2009).

- Gdlenme kuralı: Gdlenme ğrenmenin performansını artırmaktadır. Gdlenme: (1) ğrenmeye karşı ilgi, (2) gelişme isteęi, (3) materyalin kiři için nemi, (4) problemin kiři için nemi, (5) dikkat řeklinde ayrıřtırılmıştır (Topses, 2009).

2.6.2. Mevcut Hesapsal Modeller

Hassan ve Al-Hamadi (2008) yaptıkları çalışmada, Thorndike’ın ğrenen kedi modelini gezgin satıcı probleminin özmnde kullanmışır. ğrenen kedi modelinde ğrenme katsayısı:

$$\eta(m) = \eta_0 \left(1 - e^{-\frac{m}{\tau}}\right) \cdot (1 + e^{-\frac{m}{\tau}})^{-1} \quad (2.14)$$

η ğrenme katsayısı, m ğrenme dalga sayısı, τ kedinin kafesten ıkış araştırması yapması için geen zamanı gstermektedir. ıkış:

$$y(n) = \exp(-\eta_i(n - 1)) \quad (2.15)$$

η_i fark katsayılar, n deneme sayısını ifade etmektedir.

2.7. Skinner’in Yaklaşımı

Skinner’in edimsel (aralı) kořullanma kuramına gre davranışlar tepkisel (refleksif hareketler) ve edimsel (ihtiya durumunda organizmanın kendilięinden ortaya koyduęu ve sonuları tarafından kontrol edilen davranışlar) olarak ikiye ayrılır (Schunk, 2012). Klasik kořullama uyarıcı ve tepki arasındaki iliřkiyi temel almaktadır. Ancak bazı durumlarda uyarıcıları tahmin etmek mmkn deęildir. Skinner’e gre davranışları kontrol eden sadece uyarıcılar deęil aynı zamanda uyarıcıların sonularıdır (Schunk, 2012; Fer vd., 2011; Topses, 2009), yani organizmaların davranışları, uyarıcılara otomatik cevap veren yapılar deęil, bilinli karar verme kabiliyetine sahip yapılardır (Schunk, 2012, Yapıcı ve Yapıcı, 2005 ve 2010). Skinner’e gre organizma o anda iinde bulunduęu řartlara benzer bir durum yoksa deneme-yanılma ile ğrenecektir. Zamanla hedefe ulařtırıcı tepkiler dięer tepkileri egale edecek ve davranış ğrenilecektir (Yeřilyaprak vd., 2012; Schunk, 2012). Her bir davranışın sonucunda hořa giden (olumlu, bařarılı, tatmin edici) veya gitmeyen (olumsuz, bařarısız, tatmin etmeyen) durumlar oluřmaktadır. Skinner hoř veya hoř olmayan sonuların etkisini edimsel kořullanma ile aıklamaya alışmış ve organizmanın hořa giden, dllendiren veya cezadan koruyan davranışlar tekrarlanma eęiliminde olduęu ve hořa gitmeyen, dllendirilmeyen veya cezalandıran davranışlar tekrarlanmadıęını ve bu tepkilerin zamanla kaybolduęunu belirtmişir (Fer vd., 2011; Topses, 2009).

Edimsel koşullanmanın temelinde pekiştirme ve cezalandırma yer almaktadır. Pekiştirme tarifeleri: birincil (hayatta kalmak için gerekli uyarıcılar) ve ikincil (sonradan öğrenilen uyarıcılar), olumlu ve olumsuz, sürekli ve aralıklı ile zamansal ve oransal açıdan sabit veya değişken aralıklı pekiştirme şeklinde ayrıştırılmıştır (Fer vd., 2011; Topses, 2009; Schunk, 2012). Cezalar ise birinci tip (olumsuz davranışa karşı organizmaya olumsuz uyarıcı vermek) ve ikinci tip (olumsuz davranışın karşı organizmaya verilen olumlu uyarıcıyı ortamdaki kaldırmak) olarak ayrıştırılmıştır (Fer vd., 2011).

2.7.1. Skinner Yaklaşımın Temel İlkeleri

Edimsel öğrenme teoreminin temel ilkeleri aşağıdaki gibi özetlenebilir (Fer vd., 2011).

- Pekiştirme ve ceza: Edimsel koşullanmada organizmanın pekiştirici uyarıcıyla izlenen tepkileri tekrarlanma eğilimindedir. Pekiştirici uyarıcılar, edimsel davranışların meydana gelme olasılığını artırır.
- Sönme: Pekiştirmemeden dolayı bir davranışın ortaya çıkma ihtimalinin (gücünün) azalmasıdır. Yani davranışın ortaya çıkma ihtimali koşullanmadan önceki seviyeye döner.
- Kendiliğinden geri gelme: Sönen bir davranışın rastgele tekrar oluşmasıdır.
- Biçimlendirme: Hedeflenen davranışın oluşması için davranışın küçük parçalara ayrılıp, pekiştiricilerle oluşturulmasıdır.
- Zincirleme: Küçük parçalara ayrılmış hedef davranışın birçok parçaya bölünmesi ve her bir parça arasındaki sıralamaya göre yapılmasıdır.
- Genelleme: Benzer uyarıcılara karşı benzer davranışın gösterilmesi eğilimidir.
- Ayırt edici uyarıcı: Tepki ile eşzamanlı ayırt edilen uyarılardır.

2.7.2. Mevcut Hesapsal Modeller

Edimsel tabanlı öğrenme daha ziyade robotikte ve otomasyon sistemlerinde kullanılmaktadır (Gaudiano ve Chang, 1997; Liu ve Zhang, 1996; Ren ve Ruan, 2009; Itoh vd., 2005). Örneğin, Itoh vd. (2005) yaptıkları çalışmada, Hull'un öğrenme teorisini kullanan edimsel koşullanma tabanlı öğrenen insansı robotlar konu alınmıştır. Daha ziyade robotikte kullanılması nedeniyle edimsel öğrenme matematiksel modelleme yerine algoritma tabanlı olarak önerilmiştir. Örneğin, Urn modeli öğrenme sürecinin olasılıkların artırılması olarak modellendiği bir algoritmik yöntemdir (Liu ve Zhang, 1996).

Edimsel koşullanma ile öğrenme süreci mevcut yapay öğrenme yöntemleri ile de simüle edilmiştir. Gaudiano ve Chang (1997) ve Lew vd. (2001) ileri beslemeli, Ren ve Ruan (2009) ve Ruan vd. (2009) ise geri beslemeli YSA ile, Ruan vd. (2009) kural tabanlı, Cai ve Ruan (2009) ise bulanık mantık kullanarak edimsel öğrenme sürecini modellemiştir. Uygulanan yapay öğrenme yöntemlerinin yanı sıra Morgan'ın (1990) geliştirdiği DR ve Morris'in (2000) geliştirdiği Artie matematiksel modellerine ait denklemler Tablo 2.7'de sunulmuştur.

Tablo 2.7. Matematiksel edimsel koşullanma modelleri

Model	Denklem	No
DR	$y'(t) = \sum_{i=1}^n w_i(t) - x_i(t) - \theta$	(2.16)
	$y(t) = \begin{cases} 0 & y'(t) \leq 0 \\ \lambda & y'(t) \geq \lambda \\ y'(y) & \text{aksi durumlarda} \end{cases}$	
	$\Delta w_i(t) = \Delta y(t) \sum_{j=1}^{\tau} c_j w_i(t-j) \Delta x'_i(t-j)$	
	$\Delta x'_i(t-j) = \begin{cases} \Delta x_i(t-j) & \Delta x_i(t-j) > 0 \\ 0 & \Delta x_i(t-j) \leq 0 \end{cases}$	
Artie	$O_j = \sum_{i=1}^n a_{ij} w_{ij} \mu_i$	(2.17)
	$w_{ij} \leftarrow w_{ij} + V - \frac{ w_{ij} }{\sum_{i=1}^n w_{ij}} (R + P)$	
	$P = \sum_{j=1}^n O_j(t) - \sum_{j=1}^n O_j(t-1)$	

Denklem 2.16'da; y çıkış, t zaman, w_i i . nöronun ağırlığı, θ sinirsel eşik değeri, λ çıkışa ait üst limit, maksimum zaman aralığı τ , c_j öğrenme katsayısını göstermektedir. Artie modelinde kullanan i giriş ve j çıkış nöronları için a_{ij} giriş, w_{ij} bağlantı ağırlıkları, μ_i çarpan değeridir. Ağırlık değişimlerinde kullanılan P Premack değerini, R tepkisel sonucu, V değişim değerlerini göstermektedir.

2.8. Özetçe

Yapılan literatür taramasında insan öğrenmesinin birçok farklı yönden anlaşılma çalışıldığı görüldü. Bunlardan biri olan davranışçı öğrenme yaklaşımları öğrenmeyi daha objektif olarak değerlendirdiklerinden ötürü, modelin temeli olacak yaklaşım olarak kabul edildi. Ancak davranışçı yaklaşımlardan klasik koşullanmanın bile henüz tam anlamıyla modellenememiş olduğu görüldü. Ayrıca bu yaklaşımlar temelde aynı olsalar bile bazı konularda olan çeliştikleri belirlendi.

3. MATERYAL VE YÖNTEM

3.1. Klasik Koşullanmanın Modellenmesi

İnsan gibi sürekli öğrenebilen bir yöntem geliştirmek amacıyla yapılan bu çalışmada öncelikle davranışçı öğrenme kuramlarının temelini teşkil eden ve organizmaların en temel öğrenme biçimi olan refleksi öğrenme sürecini açıklayan klasik koşullanma modellemelerine çalışıldı. 2. bölümde görüldüğü üzere klasik koşullanma sürecini modellemek için birçok farklı model önerilmiş ancak hiçbiri klasik koşullanmanın tüm özelliklerini modelleyememiştir. Bu sebeple klasik koşullanmanın özellikliklerini sağlayabilecek bir model önerilmiştir.

3.1.1. Önerilen Klasik Koşullanma Modeli

Burada düşünülen senaryo, organizmanın farklı ağırlıklara, yani etkiyel güce sahip birçok farklı uyarıcıların etkisini alıp toplamsal olarak değerlendirmek ve buna göre bir tepki geliştirme felsefesine dayanmaktadır. Süreçte şimdiki uyarıcılar değerlendirilirken uyarıcıların zamana bağlı olarak değişimi de önem arz ettiğinden bir önceki i . uyarıcı ile şimdiki i . uyarıcı arasındaki farksal etki değişimine göre şimdiki i . uyarıcının etkisinin ağırlıklandırılması gerektiği düşünülmektedir. Şöyle ki:

$$\hat{U}_i^{t_n} = (U_i^{t_n} - U_i^{t_{n-1}})U_i^{t_n} = U_i^{t_n} \frac{\partial U_i}{\partial t} \quad (3.1)$$

Denklem 3.1'deki $\hat{U}_i^{t_n}$ ağırlıklandırılmış şimdiki i . uyarıcıyı, $U_i^{t_n}$ şimdiki i . uyarıcı ve $U_i^{t_{n-1}}$ bir önceki i . uyarıcıyı ifade etmektedir. Her uyarıcının farklı bir şekilde etiketlenilmesi uyarıcıların genelleme ve ayırt etme özelliği nedeniyle. Önerilen modelde elde edilen tepkinin etkisi zamansal olarak geriye doğru yansıdığını düşünülmektedir. Şöyle ki:

$$\bar{T}^{t_n} = \sum_{j=0}^N \alpha^j * T^{t_n-j} \quad (3.2)$$

Denklem 3.2'deki $\bar{T}^{t_n}$ şimdiki modifiye edilmiş tepki, T^{t_n} şimdiki tepki ve α birleştirme katsayısını ($0 < \alpha < 1$) ifade etmektedir. Bu katsayı, KU ve DU'ların bitişiklik ve koşullanma sürecinde KU'nın habercilik ilkelerini sürece yansıtmak için tanımlanmıştır. Ayrıca organizma karar anında olası tepkilerin tamamını değerlendirip bu tepkiler arasında şiddeti düşük olan tepkileri

gölgelemekte ve en baskın olan tepkiyi vermektedir (gölgeleme ilkesi). Modelde kullanılan ağırlıklar:

$$w_i^{t_n} = \beta w_i^{t_{n-1}} + \frac{\bar{U}_i^{t_n} * \bar{T}^{t_n}}{100\pi} \quad (3.3)$$

şeklindedir. Burada, β sönme katsayısıdır ($0 < \beta < 1$). Bu katsayı ile pekiştirilmeyen KU'nun ağırlıkları zamanla azalacak ve KU NU'ya dönüşmektedir. Tepki ise aşağıdaki gibi hesaplanmaktadır.

$$T_k^{t_n} = \sum_{i=0}^M w_i^{t_n} * T_i^{t_n} \quad (3.4)$$

M etkin uyarıcı sayısını göstermektedir. Organizma vereceği tepki ise k tane tepki arasındaki en baskın olandır.


$$T^{t_n} = \text{maksimum}\{T_1^{t_n}, T_2^{t_n}, \dots, T_k^{t_n}\} \quad (3.5)$$

3.1.2. Modelleme Sonuçları

Uygulamalarda öğrenme katsayıları olarak $\alpha=0,3$ ve $\beta=0,997$ değerleri atayıp ağırlıkların başlangıç değeri ise sıfır olarak alınarak önerilen yöntem ile birkaç örnek uyarıcı sonucu modelin verdiği tepki ölçüldü.

-Nötr uyarıcı – tepki ilişkisi

NU herhangi bir tepkiye neden olmayan uyarıcıdır. Örneğin, Pavlov'un deneyinde koşullanma öncesi zil NU ile köpeğin salyası olan DT'si arasında bir ilişki bulunmamaktadır. Bu örnek için önerilen modelin verdiği sonuç Şekil 3.1'de gösterilmiştir.




Şekil 3.1. Nötr uyarıcı – tepki ilişkisi

Şekil 3.1’de gösterilen 1. ve 2. uyarıcı NU’lardır ve bunların tepkiye neden olmadığı görülmektedir.

-Koşulsuz uyarıcı – koşulsuz tepki ilişkisi

Önerilen modelin DU ve DT arasındaki ilişki için verdiği sonuç Şekil 3.2’de gösterilmiştir.




Şekil 3.2. Koşulsuz uyarıcı – koşulsuz tepki ilişkisi

Şekil 3.2’de 1. uyarıcı DU’dur ve DT’ye neden olmaktadır. 2. uyarıcı ise NU’dır.

-Eşzamanlı koşullanma

Deneğe bir DU ile eş zamanlı uygulanan iki NU için yapılan çalışmada, NU’lardan birine (2. uyarıcı) karşı sağlanan eşzamanlı pekiştirmeler neticesinde bu NU’nın zamanla KU gibi algılanarak deneğin bu uyarıcıya karşı verdiği DT’nin KT’ye dönüştüğü görülmektedir. Bu durum için önerilen modelin verdiği sonuç Şekil 3.3’te gösterilmiştir.




Şekil 3.3. Eşzamanlı koşullanma

Şekil 3.3'te görüldüğü gibi 1. uyarıcı DU, 2. uyarıcı NU iken zamanla KU'ya dönüşmüştür. 3. uyarıcı ise NU olup pekiştirilmediği için nötr olarak kalmıştır.

-Gecikmeli koşullanma

Bu örnekte ise, DU'dan biraz önce uygulanan NU'nın pekiştirmeler neticesinde KU'ya ve dolayısıyla verilen tepkinin de KT'ye dönüştüğü görülmektedir. Ancak bu dönüşüm bir önceki örnek sonucuna göre eşzamanlı değil gecikmeli oluşmaktadır. Bu durum için modelin verdiği sonuç Şekil 3.4'te gösterilmiştir.




Şekil 3.4. Gecikmeli koşullanma

Şekil 3.4'te 1. uyarıcı DU, 2. uyarıcı NU'dır ve zamanla KT'ye dönüşmektedir. 3. uyarıcı ise NU'dır. Şekil 3.3 ve 3.4'te bulunan ağırlık değişimleri, Erasmus (2007)'nin de belirttiği gibi DU ve NU arasındaki gecikmeyle ilişkilidir.

-Üst düzey koşullanma

Pavlov yaptığı çalışmalarda koşullanma neticesinde oluşan bir KU-KT bağının da başka bir NU'ya aktarılabilirdiğini gözlemlemiştir. Yapılan çalışmada denek öncelikle 1. uyarıcıya karşı gecikmeli olarak koşullandırılmıştır. Daha sonra ise DU ortamdan kaldırılarak koşullu olan 1. uyarıcı üzerinden gecikmeli olarak 2. uyarıcı koşullandırılmıştır. Bu durum için modelin verdiği sonuç Şekil 3.5'te gösterilmiştir.




Şekil 3.5. Gecikmeli ikincil koşullanma

Şekil 3.5'te 1. uyarıcı KU ve 2. uyarıcı zamanla KU'ya dönüşmüş NU'dır. 3. uyarıcı ise NU'dır.

-Sönme

Koşullu bir tepkinin uzun süre pekiştirilmemesi sonucu koşullanma şiddetinin zamanla azalmakta ve sönmektedir. Modelin sönme durumu için verdiği sonuç Şekil 3.6'da gösterilmiştir.




Şekil 3.6. Sönme

Şekil 3.6'da 1. uyarıcı KU'dır, KT'ye neden olmaktadır ve zamanla uyarıcı ve tepki arasındaki ilişkinin kesilmesi nedeniyle sönmektedir. 2. ve 3. uyarıcılar ise NU'lardır.

-Gölgeleme

Deneğe iki KU birlikte verildiğinde koşullanma daha çok dikkat çeken uyarıcıya karşı meydana gelmektedir (gölgeleme ilkesi). Bu durum için elde edilen sonuçlar Şekil 3.7'de verilmiştir.



Şekil 3.7. Gölgeleme

Şekil 3.7’de gösterilen 1. KU 1. KT’yi oluşturmakta ve 2. KU ise 2. KT’ye neden olmaktadır. Organizma 2 farklı tepkiye neden olan uyarıcılarla karşılaştığında, baskın olan uyarıcıya ait tepki çıktısı verir. Başlangıçta II. tepkiyi üreten organizma daha sonra I. tepkiyi vermeye başlamıştır. Bu durum, sıcak bir ekmeği almak isteyen bir kişinin ekmeğe dokunması ve sonra da ekmeğin sıcaklığından elini hızla kaçırmaması gibi düşünülebilir.

3.1.3. Modelin Uygulama Sonuçlarının Değerlendirilmesi

Önerilen öğrenme yöntemin temel özellikleri aşağıda listelenmiştir.

- Eğitim verilerinin işlenmesi tekrara dayalı değildir. Gerçek zamanlıdır yani bir veri sadece karşılaşıldığında işlenmektedir.
- Olay serilerinin ilişkilendirilmesi hafızaya bağlıdır. Sönme katsayısına bağlı olarak zamanla unutulmaktadır.
- Her KT oluştuğunda buna bağlı geçmiş olayların tepki değerini değiştirerek tekrar değerlendirilmektedir. Bu durumu şöyle örnekleyebiliriz: karnı ağrıyan biri ağrı nedenini değerlendirirken ağrıdan önce yaşadığı uyarıcı değişimlerini değerlendirmektedir.
- Uyarıcılar zamansal olarak incelendiğinden insan doğası gereği uyarıcıların anlık değeri değil uyarıcılarda bir önceki ana göre oluşan değişimi göz önüne alınmaktadır.

Önerilen modelin, daha önce önerilen klasik koşullanma modelleri davranış çıktılarıyla (Balkenius ve Morén, 1998) karşılaştırması Tablo 3.1’de özetlenmiştir.

Tablo 3.1. Karşılaştırma

	SB	TD	DR	BM	SD	ET
İzli Koşullama	+	+	+	+	+	+
Gecikmeli Koşullama	-	+	+-	+	+	+
ISI-Eğrisi	-	+	+-	+-	+	+
S-Şekli	-	-	+	+	-	+
Sönümlleme	+	+	+	+	+	+
Tekrar Kazanım	-	-	+-	-	+	-
Engelleme	+	+	+	+	+	+
İkincil Koşullama	+-	+-	+	+	-	+
Kendiliğinden Canlanma	-	-	-	-	-	-
Koşullu Ket Vurma	+	+	+	+	+	+

Sonuç olarak önerilen model insan doğasının bir parçası olan koşullanma, fobi gibi temelsiz yargıların oluşma ve sönme süreçlerini daha iyi analiz etme ve insansı olarak öğrenme tabanlı yaklaşımlar geliştirmek için de kullanılabilir. Ancak, önerilen model de daha önce önerilen modeller gibi klasik koşullanmanın tüm özelliklerini modelleyememektedir. Chester (1990) incelemiş olduğu modellerin klasik koşullanmayı modellemeye uzak olduğunu belirtmiştir. Aynı şekilde Balkenius ve Morén (1998) yapmış olduğu çalışmada klasik koşullanmanın çok basit ve temel bir kuram olduğu halde henüz tam olarak modellenemediğini ve en karmaşık öğrenme problemlerinden biri olduğunu belirtmişlerdir. Ayrıca, Balkenius ve Morén (1998) klasik koşullanmanın matematiksel olarak modellenememesinin nedeni olarak deney verisi eksikliği ve birçok deneyin etik kurallar nedeniyle gerçekleştirilemesine bağlamışlardır.

Ancak, klasik koşullanma teorisi aşağıda belirtilen deneysel sonuçlara cevap verememesi nedeniyle, klasik koşullanmanın tam olarak modellenememesinin klasik koşullanma kuramının eksikliklerinden kaynaklı olma olasılığını göstermektedir.

- Allen ve Madden (1985) ve Malone (1990) yapmış oldukları çalışmada koşullanmanın organizmanın ihtiyaçları veya beklentileri doğrultusunda gerçekleştiğini belirtmişlerdir.
- Stuart vd. (1987) koşullanmanın organizmanın geçmiş tecrübesiyle ilintili olduğunu tespit etmiştir.
- Pornpitakpan (2012) ise DU ve KU arasındaki istatistiksel bağımlılığın koşullanmanın oluşmasında önemli olduğunu gözlemlemiştir.

Bu nedenle davranışçı öğrenme kuramlarının modellenebilmesi için kuramsal eksikliklerinin giderilmesine ihtiyaç duyulmuştur.

3.2. Davranışçı Öğrenme Kuramlarının Genelleştirilmesi

Hayvanlar yaşamlarını idame edecek yeteneklerle doğarlar ancak insanlar yaşamasına yardımcı olabilecek sadece koruyucu reflekslerle doğar. Bu refleksler ile başlayan insanın öğrenme süreci daha sonra birçok farklı konuda karmaşık problemleri çözeabilen, olayları birbiriyle ilişkilendirebilen ve çevreye adapte olabilen bireylere dönüşmesine kadar uzanmaktadır. Bu sebeple öğrenme insanın en temel özelliği olarak kabul edilebilir. Öğrenme süreci psikolojiden biyolojiye kadar birçok farklı açıdan anlaşılmaya çalışılmıştır. Özellikle Watson'ın 1994 yılında yazmış olduğu ve davranışçı yaklaşımın manifestosu olarak kabul edilen çalışmasından sonra davranışçı öğrenme teorileri popüler olmaya başlamıştır. Pavlov, Watson, Thorndike ve Skinner'ın yapmış olduğu insan ve hayvan deneklerinin belirli koşullar altında nasıl davrandıklarının tespitine yönelik deneysel çalışmalar sonucunda, öğrenmeyi uyarıcı ile davranış arasında bağ kurma işi olarak gören (uyarıcı→davranış) bir yaklaşım geliştirilmiştir. Ancak Pavlov, Watson, Guthrie, Thorndike ve Skinner gibi davranışçıların çalışmalarının öznesi insan olduğu halde bu davranışçı kuramlar bazı yönleriyle çelişmekte, karşı çıkmakta veya eksik kalmaktadır(lar). Bu nedenle davranışçı kuramların genelleştirilerek birleştirilmesi ve birbirlerinin eksiklerini gidermeleri daha anlamlı olacaktır. Bu çalışmada teorilerin tartışmalı olduğu kısımlar ile ilgili deneyler yapılmıştır. Deney sonuçları ve literatürdeki çalışmalar kullanılarak Pavlov, Watson, Guthrie, Thorndike ve Skinner'ın kuramları genelleştirilmiştir.

Davranışçı öğrenme kuramları incelendiğinde, bunların birçok yönden benzerlikler, bazı konularda farklılıklar veya eksiklikler gösterdiği görülmektedir. Klasik koşullanmayla öğrenme sonucu organizma daha önce vermediği yeni bir tepki verememekte; sadece mevcut tepkinin oluşma yoğunluğu (ihtimali) ve şiddeti artmaktadır. Yani hangi DT'nin hangi uyarıcıya ve hangi şiddette yapılacağı sonradan öğrenilmektedir (Yeşilyaprak, 2012). Bu durum organizmanın yeni bir tepki verme ihtimalini yok etmektedir ve verilen tepkilerin sadece reflekse dayalı hareketlerin birleşmesiyle oluştuğu belirtilmiştir.

Aynı şekilde Watson'a göre öğrenme sadece çevresel etmenlerle alakalıdır (Yapıcı ve Yapıcı, 2005 & 2010; Topses, 2009) ve öğrenme uyarıcı- tepkinin tekrarlanma sıklığı ile ilişkilidir. Watson ve Pavlov'un kuramlarında diğerlerinden farklı olarak memnuniyet veya hoşnutsuzluk gibi psikolojik kavramlar ve pekiştirgeçlerin öğrenmeye etkisi yoktur (Yeşilyaprak, 2012). Ancak diğerleri,

içsel süreçlerin Pavlov ve Watson'ın belirttiğinin aksine önemli olduğunu göstermiştir.

Ayrıca klasik koşullanma ile ilgili yapılan çalışmalarda bazı alanlarda koşullanma sağlanırken bazı uyarıcılar için koşullanma oluşmamaktadır. Koşullanma uyarıcıların organizmanın beklenti ve ihtiyaçlarına uygunluğu oranında oluşmakta; koşullanma süresi, kalıcılık ve tepki şiddeti değişmektedir (Garcia ve Koelling, 1966). Koşullanma ortamının olumlu duygular uyandırması ve öğrenme etkinliklerinin haz verici olması da uyaran-tepki bağıını kuvvetlendirmektedir (Yeşilyaprak, 2012).

Guthrie ise yaparak öğrenilmesi gerektiğini belirtir (Topses, 2009) ancak Thorndike'in önerdiği deneme-yanılma ilkesini ret eder (Schunk, 2012; Yapıcı ve Yapıcı, 2005 & 2010). Öğrenme için sıklık ya da pekiştirme isteyen teorilerin aksine, Guthrie öğrenmenin tek bir deneme ile sağlandığını belirtmiştir (Guthrie, 1946). Ayrıca Guthrie laboratuvar şartlarında yapılan deneylerin gerçek dünyayı yansıtmadığını belirtmiş ve öğrenmede en önemli etmenin hazır oluş olduğunu belirtmiştir (Yeşilyaprak, 2012).

3.2.1. Deneysel Çalışma: Ön bilgi

Şimdiye kadar geliştirilen davranışçı kuramlarda birbiriyle çelişen ve davranışçı öğrenme teorilerinde önemli yer tutan: öğrenme sürecine ilişkin organizmanın içsel süreçlerinin etkisi ve öğrenmenin deneme yanılma yoluyla veya tek denemeyle mi gerçekleştirildiğinin anlaşılması için, bir deneysel araştırma ihtiyacı doğmuştur. Bu tez çalışması kapsamında tavuklar üzerinde kendi biyolojik yaşam alanlarında öğrenme süreçlerine dönük deneysel çalışmalar yapılmıştır. Deneysel çalışmanın laboratuvar ortamında yapılmamasının nedeni Guthrie'nin laboratuvar ortamında yapılan deneylerin gerçek öğrenmeyi yansıtmadığını belirtmesindendir. Yapılan deneyle tavukların davranış (tepki) süreçleri ve birincil ihtiyaç olan beslenmede farklı gıda türlerine olan ilgileri kayıt altına alınmıştır. Deneyde toplam 6 adet köy tavuğu ve 1 adet horoz kullanılmıştır. Deneklerin yaşlarının ortalaması 1, ağırlıklarının ortalaması ise 1,5 kg'dır. Denekler Şekil 3.8'de verilmiştir.



Şekil 3.8. Denekler

Denekler öncelikle kendilerini 6 ayı aşkın süredir aynı yerde ve aynı koşullarda besleyen, yemleyici görüntüsüne, sesine ve yemleme zamanına klasik koşullanma ilkeleri uyarınca daha önce şartlanmışlardı. Tavukların yemek saati olsun veya olmasın, yemleyiciyi yemek kabına yöneldiğini gördüklerinde etrafında toplandıkları gözlemlendi. Burada şartlanma gıda (uyarıcı) ve yeme (tepki) arasındaki doğal ilişki ile oluşmuştur. Denekler günde üç defa beslenmiştir. Beslenmeleri için her öğünde yaklaşık 150 gr buğday veya 200 gr ekmek veya bunların karışımları şeklindedir. Denekler ayrıca doğal beslenme ortamında bulunan bitkilerden, böceklerden de yemişlerdir. Bu nedenle tavuklar tamamen aç bırakılmamışlardır. 1. öğün saat 9-10 civarı, 2. öğün ise saat 13-14 civarı ve 3. öğün ise saat 17-18 civarı verilmiştir. Deney süreci ayrıca bir dijital kamera ile kayıt altına alınmıştır.

3.2.2. Deney Protokolü

Guthrie laboratuvar şartlarında gerçekleştirilen deneylerin gerçek hayatı yansıtmadığını belirtmiş ve bu nedenle deneyler tavuklar sürü halinde ve doğal yaşam alanlarındayken yapılmıştır. Bu kapsamda hayvanların birincil ihtiyaçları olan beslenme alışkanlıklarından, gıda değişikliğinin yeme alışkanlıkları üzerindeki etkisi araştırılmıştır. Organizmanın belli bir süre aynı besin türü tüketmesi sonucunda yeni bir besin türü ile karşılaştığında yeni besin türüne olan tepkisi analiz edilmiştir. Denekler deneye başlanmadan önce 4 gün boyunca sadece buğdayla beslenmişlerdir. Deneye başlamadan önceki son günün son öğününün ilk 10 dakikasının sonundaki veriler Tablo 3.2'deki gibidir.

Tablo 3.2. Deneklerin beslenme kayıtları (1-4. gün)

Gün	Öğün	Verilen yem miktarı (gr)	Tüketilen yem miktarı (gr)
4	1	150	150
	2	150	150
	3	150	150

5. gün ilk öğünde tavuklara buğday ve ekme  beraber verilmiřtir. Denekler ekmeğın tamamına yakını (%99) tükettikleri halde buğdayın sadece (%5)'ini yedikleri gözlemlenmiř ve bu durum řekil 3.9'da gösterilmiřtir.



řekil 3.9. 4 gün buğday ile beslenen deneklerin ekmeğ  olan tepkisi

Buğdayda %5'lik tüketim olması, tavuklardan birinin, tamamı beslenme bölgesinde bulunan ekmeğ  ilk etapta erişememesi veya kalabalıktan çekinmesi gibi nedenlerle olabilir. Bu durum tavukların deneme-yanılma yoluyla öğrendiklerini göstermektedir. Çünkü řekil 3.9'da görüldüğü gibi buğday yiyen tavuk daha sonra ekmeğ  fark edip ekme  yemeye başlamıřtır.

Özetle, organizma ilk seferinde hořa giden veya cezadan kurtaran bir sonuçla karşılaşmaları durumunda (ekmek yiyen tavuklar) tek seferin öğrenme için yeterli olduğunu aksi halde deneme-yanılma ile öğrenildiğini göstermiřtir. Tavuklar 5. günün 2. öğününden itibaren her öğünde 4 gündür beslenmedikleri ekme le beslenmeye başlanmıřlardır. Bu durumda deneklerin yeni gıda türüne karşı verdikleri tepki Tablo 3.3'de verilmiřtir. 8. günün son öğününde tavuklara ekme  ve buğday beraber verilmiř ve tavukların sadece buğdayı tükettiğı gözlemlenmiřtir. Bu durum řekil 3.10'da gösterilmiřtir.

Tablo 3.3. Deneklerin beslenme kayıtları (5-8. gün)

Gün	1. Öğün		2. Öğün		3. Öğün	
	Gıda Türü ve Miktarı (gr)	Tüketilen Gıda ve Yüzdesi	Gıda Türü ve Miktarı (gr)	Tüketilen Gıda ve Yüzdesi	Gıda Türü ve Miktarı (gr)	Tüketilen Gıda ve Yüzdesi
5	Ekmek:200 Buğday:250	Ekmek:99 Buğday:5	Ekmek:200	Ekmek:99	Ekmek:200	Ekmek: 70
6	Ekmek:200	Ekmek:97	Ekmek:200	Ekmek:85	Ekmek:200	Ekmek: 90
7	Ekmek:200	Ekmek:97	Ekmek:200	Ekmek:97	Ekmek:200	Ekmek: 90
8	Ekmek:200	Ekmek:99	Ekmek:200	Ekmek:85	Ekmek:200 Buğday:250	Ekmek: 2 Buğday: 70



Şekil 3.10. 4 gün ekmek ile beslenen deneklerin buğdaya olan tepkisi

3.2.3. Deney Sonucu

Deneyler Guthrie'nin belirttiği üzere deneklerin doğal ortamlarında gerçekleştirilmiştir. Deneklere yemek isteyecekleri gıda türü tercihi sunulduğunda denekler uzun süre beslendikleri gıda yerine yeni karşılaştıkları gıdayı tercih etmişlerdir. Bu durum uyarıcılara karşı organizmanın verdiği tepkiyi belirlemede içsel süreçlerin önemli olduğunu göstermiştir. Ayrıca öğrenmenin deneme yanılma ile gerçekleştiği ve bunun yanı sıra öğrenmenin tek denemede başarıya ulaşması (hoşa giden veya cezaya neden olmayan) durumunda deneme yanılmaya gerek olmadığı görülmüştür.


Deney sonuçları incelendiğinde aslında organizma çevreden aldığı uyarıcılar (çevresel ve tepkisel uyarıcılar) ile içsel uyarıcıları değerlendirmekte ve en baskın tepkiyi vermektedir. Bu en baskın tepki, daha önce başarılı (hoşa giden) sonuç üreten bir tepki var ise onu vermekte; yok ise, daha önce verdiği tepkide küçük değişiklikler oluşturarak cezaya neden olan tepkiden en uzak ve hoşa giden sonuca doğru ilerleyen bir süreç izlemektedir. Bu süreç tek denemede de başarılı

olabileceği gibi, birçok deneme sonucunda da hoş giden sonuçlar üretecek tepkiler oluşturabileceği gözlemlenmiştir. Bu açıklama insanın biyo-psiko-sosyal bir varlık olması gerçeğiyle de örtüşmektedir.

Bu bağlamda yapılan deneysel gözlemler incelendiğinde verilen tepki şiddetine bağlı olarak Skinner'ın ayırdığı gibi tepkisel veya edimsel davranış olarak ayrıştırılabilir. Ama neticede organizma uyarıcılarla karşılaştığında birçok tepki arasından baskın olan tepkiyi vermiştir. Refleksi tepkiler en baskın tepkilerdir. Bu nedenle organizma refleksi tepki için seçim yapma yani düşünme ihtiyacı duymamaktadır. Bu durum klasik koşullanmanın karmaşık insan düşüncelerini açıklayamaması, duygusal tepkiler, refleksi davranışlar, fobiler ve boş inançları daha ziyade açıklayabilmesi gerçeği ile örtüşmektedir (Pavlov, 1927; Yeşilyaprak, 2012). Yapılan deneyin de gösterdiği gibi öğrenme geçmiş tecrübelerle bağlıdır (Kamin, 1968) ve olaylar arasındaki istatistiksel bağımlılığa karşı hassastır (Rescorla, 1968).

3.3. Genelleştirilmiş Davranışçı Öğrenme Kuramının Modellenmesi

Bu bölümde genel yapısı Şekil 3.11'de gösterilmiş olan GDÖ yaklaşımı detaylarıyla matematiksel olarak modellenmiştir. Davranışçı öğrenme yaklaşımlarında, organizma uyarıcılar vasıtasıyla sürekli dış ortamla iletişim halindedir. Aynı zamanda gerçekleştirdiği eylem (tepki) sonuçları ve tepkisel uyarıcı dış ortamdan algılanmaktadır. Organizmanın içsel süreçleri ve organizma uyarıcısı da değerlendirmeye katılmaktadır. Sonuç olarak organizma bu değişkenlere bağlı olarak tepki üretmektedir. Önerilen model ve modelde bulunan parametreler kullanılma nedenleriyle beraber açıklanacaktır.



Şekil 3.11. Genelleştirilmiş davranışçı öğrenme yaklaşımı

3.3.1. Organizma Kaynaklı Uyarıcılar

Watson'a göre "mekanizma, davranışı açıklar" (Yeşilyaprak vd., 2012) yani davranışların gerçek nedeni sinir sistemidir ve davranışçıların temelde "objektif olmayan, kanıtlanamayan, somut olarak ölçülüp değerlendirilmeyen hiçbir yaklaşımın değeri yoktur" ilkesine dayandığından dolayı içsel yaşantıları reddeder ve öğrenme sürecini uyarın-tepki süreci olarak yorumlamaktadır (Veznedaroğlu ve Özgür, 2005). Öğrenmenin sadece çevresel etmenlerin (uyarıcıların) etkisiyle olduğunu iddia etmektedir (Topses, 2009).

Ancak davranışçı yaklaşımlarla ilgili, Gurthie, Thorndike ve Skinner'in kuramları, yapılan çalışmalar ve yapmış olduğumuz deneyler çerçevesinde "Davranış organizmanın dışarıdan ya da içeriden gelen uyarımlara verdiği iç ve dış tepkilerin bütünüdür" şeklinde ifade etmenin daha doğru olacağı aşikârdır (Veznedaroğlu ve Özgür, 2005; Topses, 2012).

Davranış bu şekilde tanımlandığında Garcia ve Koelling'in (1966) belirttiği her uyarıcının koşullanamaması durumu açıklanabilmektedir. Ayrıca koşullanma ortamının olumlu duygular uyandırması ve öğrenme etkinliklerinin hız verici olması da uyarın-tepki bağına kuvvetlendirmesi aynı kapsamda anlam kazanmaktadır (Yeşilyaprak vd., 2012). Bu sebeple organizmaya ait davranışçı teorisyenlere göre önerilen temel duygular ya da uyarıcılar aşağıda listelenmiştir.

- Beklenti (Pavlov)
- Gereksinim (Pavlov)
- Ortam (Pavlov; Premack ilkesi, Skinner)
- Dikkat (Guthrie; Thorndike)
- Hazır oluş (Guthrie, Thorndike)
- İlgi (Thorndike)
- İstek (Thorndike)
- Materyalin önemi (Thorndike)
- Problemin önemi (Thorndike)

Yukarıda belirtilen uyarıcılar birbirini bütünler niteliktedir. İnsan duygularının matematiksel veya hesapsal olarak modelleyen birçok çalışma yapılmıştır (Lin vd., 2012; Hartmann vd., 2012). Ancak davranışçı öğrenme kuramlarına dayalı yapay öğrenme modeli tasarlanması hedeflendiğinden duyguların modellenmesi konu dışı bırakılmıştır. Yapılan çalışmada uyarıcıların tek tek kullanılması yerine bunların ortalaması alınmıştır. Organizma uyarıcısı:


$$\overline{OU}^{t_n} = \frac{1}{9} \sum_{k=1}^9 OU_k^{t_n} \quad (3.6)$$

Burada, OU organizma uyarıcısını, $\overline{OU}$ ise organizma uyarıcılarının aritmetik ortalamalarını, k ise yukarıda sayılan organizma uyarıcılarını göstermektedir. Organizma uyarıcıları -1 ile 1 arasında değer almaktadır. Organizma uyarıcıları organizmanın öğrenmeye meyletme şiddetini göstermektedir. Organizmanın öğrenmeye hazır olduğu durumlarda 0 ile 1 arasında değer alırken, öğrenmek istemediği durumlarda ise -1 ile 0 arası değer almaktadır.

Canlı organizma, makine gibi bütünleşik sistemlerden farklı olarak maruz kaldığı uyarıcılarla eş zamanlı olarak tepki üretmemekte; üretmiş olduğu tepkiye karmaşık ve birçok parametreden oluşan çevreden de eşzamanlı bir karşıt tepki almamaktadır. Yani uyarıcı, tepki ile karşıt tepki arasındaki birçok bilinmeze atfedilebilecek rastgele zamansal gecikme mevcuttur. Bu rastgele fark davranışçı öğrenmenin modellenmesi önünde en büyük engellerden biridir. Bu engeli aşmak için organizma kaynaklı uyarıcılar, tepkisel uyarıcılar, tepkinin etkisi ve uyarıcı ağırlıklarının etkileri zamansal olarak geriye doğru dağıtılmıştır. Bu sebeple hesaplamaya katılacak olan organizma uyarıcısı aşağıdaki gibi ifade edilmiştir.


$$\overline{OU}^{t_n} = \sum_{j=0}^N \alpha^j * \overline{OU}^{t_n-j} \quad (3.7)$$

Denklem 3.7'te N sayısı birleştirilecek/ilişkilendirilebilecek uyarıcı sayısını göstermektedir. N sayısı öğrenmeyi etkileyen bir parametredir. Klasik koşullanmada DU 'yu gecikmeli takip eden uyarıcılar ve edimsel koşullanma örneği Şekil 3.12'de gösterilmiştir.



Şekil 3.12 Klasik koşullanmada bitişik olay sayısının etkisi


Şekil 3.12'den de görüldüğü gibi 1. uyarıcı DU, 2. uyarıcı eş zamanlı uyarıcı, 3, 4, 5 ve 6. uyarıcıları sırasıyla 1, 2, 3 ve 4 an gecikmeli ve 7. uyarıcı ise edimsel koşullanmadır ve bitişik olay sayısı 3 olarak alınmıştır. 7. uyarıcı ile DU arasında rastgele bir ilişki vardır. Edimsel koşullanmada ise değişen bitişik olay sayısının etkisi Şekil 3.13'te gösterilmiştir.



Şekil 3.13. Edimsel koşullanmada bitişik olay sayısının etkisi

Edimsel koşullanmada bitişik olay sayısı arttıkça koşullanmada oluşan ağırlık seviyesi yükselmektedir. Bu durum şu şekilde yorumlanabilir. Organizma gerçekleşen bir tepkinin hangi uyarıcıdan kaynaklandığını algılamaya çalışmaktadır. Denklem 3.5'de bulunan α ise birleştirme katsayısını ($0 < \alpha < 1$) göstermektedir. Birleştirme katsayısı örnek uzayda oluşan bir tepki, organizma

uyarıcısı ve tepkisel uyarıcının etkisinin geçmişe hangi derecede yansıtılacağını gösteren bir parametredir. Birleşme katsayısının etkisi Şekil 3.14'te gösterilmiştir.



Şekil 3.14. Edimsel koşullanmada birleştirme katsayısının etkisi


Birleştirme katsayısı (α) ve birleştirilen olay sayısı (N) ile bitişiklik, haber verme, ve ayırt edilmesi ilkeleri ve kısa dönemli hafızayla yakından ilişkilidir (Bouton ve Moody, 2004). Hafıza doğal öğrenmenin en temel birleşenidir (Bouton ve Moody, 2004). Çünkü unutmak, yeni öğrenilen bilginin anlamlılık gücünün geçmiş verilere göre daha yüksek olmasını sağlamaktadır. Hafıza kısa ve uzun dönem hafıza olarak sınıflandırılmaktadır. Kısa dönem hafıza, olayların birbiriyle olan zamansal ilişkilerinin takip edilmesi ve çok sayıda uyarıcı arasından anlamlı uyarıcıların belirlenerek alakasız uyarıcıların elendiği süreçtir. Uzun dönemli hafıza ise bilginin istiflendiği ve öğrenilen bilgilerin karar verme amacıyla kullanıldığı kısımdır (Bouton ve Moody, 2004).

Bitişik olay sayısı ile birleştirme katsayılarının kullanılma nedeni bir uyarıcı veya tepkinin etkisinin zamanla azalmasıdır. Bu etki süresiyle ilgili olarak yapılan çalışmalarda koşullanmanın oluşabilmesi için NU'nın DU'dan yaklaşık olarak 250 ms'nin zaman farkı içerisinde olması gerektiği ve bu etkinin zamana bağlı olarak eksponansiyel bir şekilde düştüğü ifade edilmiştir (Smith vd., 1969).

3.3.2. Uyarıcılar

Uyarıcılar organizmayı çevreden etkileyen her türlü gözlemlenebilir olgudur. Bu olgulara örnek olarak ses, ışık, renk, deride oluşan basınç ve benzeri uyarıcılar gösterilebilir. Bilindiği gibi uyarıcılardan kaynaklı oluşan ve organizma

tarafından algılanan uyarılar sinir sisteminin yapısı gereği belli bir eşik değerini aşmayıncaya kadar merkezi sinir sistemine iletilmemektedir (Şekil 3.15).



Şekil 3.15. Aksiyon potansiyeli ve safhaları (Tekin vd., 2012)

Eşik değerini aşan uyarılar merkezi sinir sistemine iletilmektedir. Şiddet artıkça aksiyon potansiyeli formunun tepe noktası değişmemekte fakat uyarının şiddetine bağlı iletilen sinyallerin yoğunluğunu artırmaktadır (Tağluk ve Tekin, 2014). Önerilen modelde ise uyarıcılar eğer uyarım gerçekleşiyorsa 1, aksi durumda 0 değerini almaktadır. Organizmanın her hangi bir t_n anında maruz kaldığı i tane uyarıcı ise $U_i^{t_n}$ şeklinde gösterilmiştir.

3.3.3. Tepki

Tepki organizmanın çevre uyarıcılara karşı uyguladığı her türlü gözlemlenebilir olgudur. Organizma her an karşılaştıkları uyarıcılara bağlı olarak olası tepkileri belirlemektedir. Tepkiler ($T_k^{t_n}$) aşağıdaki gibi hesaplanmıştır.

$$T_k^{t_n} = \sum_{i=0}^M w_{k,i}^{t_n} * T_i^{t_n} \quad (3.8)$$

Denklem 3.8'de M etkin uyarıcı sayısını göstermektedir. Organizma vereceği tepkinin belirlenmesinde baskın uyarıcıyı temel almaktadır (kazanan her şeyi alır). Yani organizma o anki uyarıcıların neden olması beklenen muhtemel tüm olası tepkiler arasında en baskın tepkiyi verir. Organizma tarafından gösterilen tepki:

$$T^{t_n} = \text{maksimum}\{T_1^{t_n}, T_2^{t_n}, \dots, T_k^{t_n}\} \quad (3.9)$$

şeklinde ifade edilebilir. Tepkinin oluşması için önerilen yaklaşım Rescorla'nın (1968) yaptığı deneylerinde gösterdiği gibi istenen tepkinin oluşmasının uygulanan KU'yla ilişkili olduğu sonucuna uymaktadır. Skinner'a göre davranışlar tepkisel ve edimsel davranışlar olarak ikiye ayrılır, önerilen modelde tepkinin şiddetine bağlı olarak bu ayrım yapılabilir. Bu durum uyarıcıların ağırlıklarına bağlı olarak değerlendirilebilir. Refleksif tepkiler baskın tepkilerdir, edimsel tepkiler ise baskın değildir. Önerilen yöntemde ağırlıkların hesaplanması sürecinde, tepkinin etkisi zamansal olarak geriye doğru dağılmaktadır. Dağıtılmış tepki ($\bar{T}^{t_n}$) aşağıdaki gibi hesaplanmaktadır.

$$\bar{T}^{t_n} = \sum_{j=0}^N \alpha^j * T^{t_n-j} \quad (3.10)$$

Bitişik olay sayısı (N) ve birleştirme katsayısının (α) etkisi detaylı olarak açıklanmıştır. Yapılan çalışmada tepki eğer oluşuyorsa 1 aksi durumda 0 değerini almaktadır.

3.3.4. Tepkisel Uyarıcı

Organizma sürekli çevreden uyarıcılara maruz kalmakta ve bu uyarıcıların bir kısmı organizmanın daha önce göstermiş olduğu tepkiye karşı çevreden aldığı geri dönüttür. Verilen tepkinin sonucunda organizmada memnuniyet veya hoşnutsuzluk oluşur ve bu durum uyarıcı-tepki bağlarının güçlenmesine veya sönmesine neden olur. Tepkisel uyarıcılarla olumlu veya olumsuz tepkiler ödüllendirebilir, cezalandırabilir veya nötr kalınabilir.

Pavlov deneylerinde tepkisel uyarıcılarla ilgili bir değerlendirmede bulunmamıştır. Bunun nedeni deneylerindeki tepkisel sonuç olan yemeğin memnuniyet verici olmasıdır. Ağırlıkların güncellenmesi için kullanılan etkisi dağıtılmış tepkisel uyarıcıyı ($\bar{TU}^{t_n}$) aşağıdaki gibi ifade etmek mümkündür.


$$\bar{TU}^{t_n} = \sum_{j=0}^N \alpha^j * TU^{t_n-j} \quad (3.11)$$

3.3.5. Uyarıcı – Tepki Bağı

Önerilen modelde uyarıcılar ve tepki arasında ağırlıklarla anlamlandırılan bir bağ bulunmaktadır. Biyolojik sinir sisteminde elektriksel geçirgenliğin değişmesi (Hughes, 1958) olarak ta yorumlanabilecek ağırlık değişimleri:


$$w_{k,i}^{t_n} = \beta w_{k,i}^{t_{n-1}} + \eta * U_i^{t_n} * \bar{T}^{t_n} * (\bar{T}U^{t_n} + \bar{O}U^{t_n}) \quad (3.12)$$

şeklinde hesaplanmaktadır. Burada, β sönme katsayısı ($0 < \beta < 1$), η ise öğrenme adım katsayısıdır. Daha önce belirtildiği gibi N ve α kısa dönem hafıza ile ilişkiliydi; sönme katsayısı (β) ise uzun dönem hafızasıyla ilişkilidir (Bouton ve Moody, 2004) ve unutma hızını gösteren bir parametredir. Freedman ve Adams'ın (2011) belirttikleri gibi makinelerde her şeyin hatırlanmasının (unutulmaması) hareketleri mükemmelleştirme ve daha az zamanda çok daha fazla şey öğrenebilme gibi birçok avantajının olduğu halde bu durum aynı zamanda bu ilgisiz, anlamsız ve güncel olmayan birçok bilginin de saklanması anlamına gelmektedir. Bu ciddi hafıza karışıklığına neden olabilecek bir durumdur. Bu sebeple unutmak yeni şeyler öğrenmenin anahtarıdır. Önerilen modelde öğrenme uyarıcı-tepki bağının kurulması olarak yorumlandığından, unutma daha ziyade ağırlıkların sönümlemesi olarak ifade edilmiştir. Ayrıca bu değer öğrenmenin kararlı hale gelmesinde de önem teşkil etmektedir. Şekil 3.16'da farklı sönme katsayılarına bağlı ağırlık değişimleri gösterilmiştir.



Şekil 3.16. Sönme katsayısının etkisi

Farklı öğrenme adım katsayıları kullanıldığında oluşan ağırlık değişimleri Şekil 3.17'de gösterilmiştir.



Şekil 3.17. Öğrenme adımının etkisi


Şekil 3.17’de görüldüğü gibi düşük öğrenme katsayıları (yani unutkan organizmalar) öğrenmede ağırlıkları daha düşüktür. Bu sebeple bu değerin 1’e olabildiğince yakın bir değer olarak atanması gerekmektedir. Bu şekilde atanan değer ve küçük seçilen bir öğrenme adım katsayısı öğrenmenin küçük adımlarla gerçekleştirilen bir süreç olması ve en son verilen tepkiye benzer bir tepki verilmesini açıklamaktadır. Öğrenme adım katsayısı klasik geri beslemeli algoritma ile öğrenen YSA’da da kullanılmaktadır. Doğru öğrenme adımı seçmek, geri beslemeli öğrenen YSA’da olduğu gibi önemlidir. Çünkü çok küçük adımlar öğrenme sürecini yavaşlatmakta ama diğer taraftan daha hassas hale getirmektedir. Ancak ağırlıklarda yavaş artışlar yerel minimumlar nedeniyle optimum ağırlıkların bulunamamasına, yüksek adım değerleri öğrenme sürecini hızlandırdığı halde düşük hassasiyet nedeniyle genel minimumu atlaması olasılığını artırmaktadır. Ayrıca çok daha yüksek katsayılar ise ağırlıkların ıraksamasına neden olabilmektedir (Dabney ve Barto, 2012).

Bu durumun çözümü olarak klasik geri beslemeli öğrenmelerde adaptif öğrenme adımları kullanan algoritmalar önerilmiştir (Abdul ve Salman, 2008). Önerilen yöntemde öğrenme adım katsayısı (η) sabit küçük bir değer olarak atanması yerine değişken olarak seçilmesi Pavlov’un öğrenme süreçlerinde daha önce oluşturulan uyarıcı-tepki bağının tekrar oluşması sürecinin hızlı olması ilkesi gereği önemlidir. Bu parametrenin seçiminde birçok farklı yol izlenebilir. Örneğin, Dabney ve Barto (2012) geliştirdikleri çevrimiçi geçici fark öğrenmesi yönteminde adaptif öğrenme katsayısı kullanmıştır. Önerdikleri yöntemde öğrenme katsayıları için minimum ve maksimum değerleri bulunmakta ve daha sonra geliştirdikleri algoritmaya göre bu aralıktaki öğrenme adım katsayılarını kullanmaktadır. Önerilen yöntemde öğrenme katsayısı basitçe:

$$\eta_i^{t_n} = (\text{Öğrenme sayısı} + 1) * \eta_0 \quad (3.13)$$

Denklem 3.13’de bulunan η_0 atanan başlangıç öğrenme adım katsayısı ve Öğrenme sayısı ise organizmanın uyarıcı-tepki arasındaki bağın kurulma sayısıdır. Öğrenme sayısı ’nın tespiti biyolojik sinir sistemlerinde kanal geçirgenliğinin hesaplanmasında önemli bir problem olması nedeniyle literatürde birçok yöntem önerilmiştir (Alvarez vd., 2012; Carter vd., 2008).

Denklem 3.10’da görüldüğü gibi, her ağırlık bir önceki ağırlık değerine bağlı olarak hesaplanmaktadır. Bu durumda başlangıç ağırlıkları organizmanın geçmiş yaşantısını göstermektedir. Bu durum Stuart vd. (1987) ve Kamin (1968) belirttikleri gibi koşullanmanın organizmanın geçmiş tecrübesiyle ilintili olduğunu göstermektedir. Farklı başlangıç koşullarına sahip uyarıcıların koşullanması sırasında oluşan ağırlık değişimleri Şekil 3.18’de gösterilmiştir.



Şekil 3.18. Koşullanmada başlangıç ağırlıklarının etkisi

3.3.6. İstatistiksel İlişki

Davranışçı öğrenme kuramlarında uyarıcıların kendi aralarında ya da tepki ile aralarındaki istatistiksel ilişkiyle ilgili önermeler mevcuttur. Pornpitakpan (2012) klasik koşullanmanın oluşması için DU ile KU arasındaki istatistiksel bağımlılığın önemli olduğunu belirtmesi örnek olarak verilebilir. Bu çalışmada iki farklı benzerlik ilişkisi kullanılmıştır. Bunlar; Darvishi (2010) tarafından önerilen faz, zaman ve genlik kaymalarından etkilenmeyen benzerlik katsayısı (bundan sonra tezde benzerlik olarak ifade edilecektir) ve korelasyon değişkenleridir.

-Benzerlik

Yapılan çalışmada Darvishi (2010) tarafından önerilen sinyaller arası benzerlik ölçen bir yaklaşım kullanılmıştır. Bu benzerlik yaklaşımının seçilmesinin nedeni bu yöntemin ürettiği sonucun sinyaller arasındaki zaman, genlik ve faz kaymaları ile genlik ölçeklendirmesinden etkilenmemesidir. Hesaplama aşağıdaki aşamalarla yapılmaktadır.

1. Aşama: İki veri dizisinden biri kontrol verisi olarak seçilmesi (Y) ve aritmetik ortalama değerinin (μ_Y) bulunması,
2. Aşama: İkinci serinin her değeri (ya da zaman kayması sınırı olarak belirlenen değere kadar) için tek tek kaydırılarak yeni diziler (X_k) elde edilmesi ve bu dizinin aritmetik ortalama değerinin (μ_{X_k}) bulunması,
3. Aşama: Her kayma değeri (k) için benzerlik değerinin hesaplanması

$$S_k = \frac{\sum_{i=1}^m (X_{k_i} - \mu_{x_i})(Y_i - \mu_Y)}{\sqrt{\sum_{i=1}^m (X_{k_i} - \mu_{x_i})^2 \sum_{i=1}^m (Y_i - \mu_Y)^2}} \quad (3.14)$$

4. Aşama: Hesaplanmış benzerlik değerlerinden en yüksek olanı benzerlik ölçütü olarak atanması

$$Benzerlik(X, Y) = maksimum\{S_1, S_2, \dots, S_k\} \quad (3.15)$$

olarak sayılabilir. Yapılan çalışmada kullanılan benzerlik ölçütü insan gibi kısa süreli hafızaya sahip organizmalarda uyarıcılar arasındaki ilişkinin hesaplanmasında kullanılmıştır.

-Korelasyon

Korelasyon iki dizi arasındaki benzerlik ölçüsüdür ve -1 ile 1 arasında bir değer almaktadır.

$$Korelasyon(X, Y) = \frac{\sum_{i=1}^n (X_i - \mu_X)(Y_i - \mu_Y)}{\sqrt{\sum_{i=1}^n (X_i - \mu_X)^2} \sqrt{\sum_{i=1}^n (Y_i - \mu_Y)^2}} \quad (3.16)$$

Bir sonraki bölümde önerilen modelin davranışçı modelleri gerçekleştirme yeteneği test edilmiş ve bu model temel alınarak yeni bir yapay öğrenme yöntemi önerilmiştir.

3.4. Özetçe

Bu bölümde klasik koşullanma modellenmeye çalışılmıştır. Önerilen modelin başarısını tespit etmek amacıyla klasik koşullanmanın özelliklerini

gerçekleştirme kabiliyeti test edilmiştir. Elde edilen sonuçlar önerilen modelin literatürdeki diğer modeller gibi klasik koşullanmanın tüm özelliklerini gerçekleştiremediği gözlemlenmiştir. Yapılan çalışma neticesinde insanın biyo-psiko-sosyal bir varlık olması gerçeği göz önüne alınarak davranışçı öğrenme kuramları sadeleştirilmiş ve genelleştirilmiştir. Kuramların arasındaki en temel farklar içsel süreçlerin ve öğrenmenin gerçekleşme sürecinin tek denemede veya deneme yanılma ile olduğuna bağlıdır. Yapılan deneyle içsel süreçlerin tepki seçimi konusunda etkin olduğu gözlemlenmiştir. Ayrıca öğrenme süreci deneme-yanılma sürecinin tek seferde olumlu (hoşa giden) veya cezadan kurtaran davranışlara neden olması durumunda, tek deneme ile de gerçekleşebileceği şeklinde yorumlanmıştır. Genelleştirilmiş kuram daha sonra matematiksel olarak modellenmiştir.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. Önerilen Yaklaşımın Davranışçı Kuramları Sağlama Yeteneği

Önerilen matematiksel model 2. Bölümde tanımı yapılmış olan Pavlov, Watson, Guthrie, Thorndike ve Skinner'ın davranışçı yaklaşım teorilerine ne ölçüde uyum sağladığı ve gerçekte uygulanabilirliğini değerlendirmek amacıyla model birçok yönüyle teste tabi tutuldu. Testler sonucunda elde edilen sonuçlar uyarıcıların ağırlık değişimleri temel alınarak değerlendirilmiştir. Çalışmada kullanılan model parametreleri Tablo 4.1'de özetlenmiştir.

Tablo 4.1. Öğrenme parametreleri

Parametre	Değer
Sönme Katsayısı (β)	0,995
Birleştirme Katsayısı (α)	0,95
Öğrenme Katsayısı (η)	0,04
Bağlı Olay Sayısı (N)	3

Bu bölümde ayrıca önerilen davranışçı öğrenme modelinin insan davranışlarını modellemedeki başarısı, YSA ile elde edilen başarı ile karşılaştırılmıştır.


4.1.1. Pavlov'un Yaklaşımı

Pavlov teorisinde tepkisel ve organizma uyarıcısını değerlendirmeye almamıştır. Pavlov deneylerinde koşullanma tepkisinden sonra deneğin beslenmesi nedeniyle organizma uyarıcısı olumlu tepkisel uyarıcı ile ödüllendirilmiştir. Bu durum koşullanmanın oluşması için Allen ve Madden (1985) ile Malone'nun (1990) belirttikleri gibi organizmanın ihtiyaçlarının veya beklentilerinin karşılanması gerekmektedir. Önerilen model ile klasik koşullanmanın Bölüm 2'de anlatılmış tüm özellikleri başarılı bir şekilde gerçekleşmiştir.

-Koşullanma

Koşullanma DU ile NU arasındaki zamansal farka göre sınıflandırılmaktadır (Balkenius ve Moren, 1998).


Eş zamanlı koşullanma: Organizmanın eş zamanlı olarak NU ve DU'nun uygulanması ile oluşan koşullanma türüdür. Şekil 4.1'de 4 adet farklı başlangıç değerine sahip uyarıcının DU olan 1. uyarıcıyla eş zamanlı olarak koşullanma süreçlerinde elde edilen koşullanma ağırlıkları gösterilmiştir.



Şekil 4.1. Eş zamanlı koşullanma

Şekil 4.1.'de görüldüğü gibi geçmiş yaşantıya atfedilebilecek olan farklı başlangıç ağırlıklarına sahip 2, 3, 4 ve 5. NU'lar DU (1. uyarıcı) ile eşzamanlı olarak uygulanan koşullanma süreci sonunda DU ile aynı ağırlıklara ulaşmaktadır.

Gecikmeli koşullanma: Şekil 4.2.'de farklı başlangıç değerlerine sahip 6 adet NU ile 1 adet DU'nun koşullanma süreçlerinde elde edilen koşullanma ağırlıkları gösterilmiştir.




Şekil 4.2. Gecikmeli koşullanma

Şekil 4.2'den de görüldüğü gibi gecikmeli koşullanma sürecinde farklı başlangıç ağırlıklarına sahip 2 - 6. NU'lar DU (1. uyarıcı) ile koşullandığında DU'dan daha düşük ağırlıklar elde edilmektedir. Organizma koşullanma sürecinden sonra maruz kaldığı uyarıcılardan daha yüksek şiddete bir tepki yok ise koşullandığı KT'yi verecektir. Şekil 4.1 ve 4.2.'deki koşullanma süreçleri

incelendiğinde gecikmeli koşullanma ile oluşan ağırlık değeri eşzamanlı koşullanma ile elde edilen ağırlık değerlerinden daha düşük olduğu görülmektedir.

-Bitişiklik ve habercilik

DU ile NU arasındaki farklı zamansal gecikme sürelerine sahip uyarıcıların ağırlık değişimleri Şekil 4.3.'te gösterilmiştir.




Şekil 4.3. Farklı bitişiklik değerlerine sahip uyarıcıların ağırlık değişimi

Şekil 4.3.'te 1. uyarı DU 2., 3., 4. ve 5. uyarıcılar ise sırasıyla eş zamanlı ile 1, 2 ve 3 örnek gecikmeli NU'lardır. Gecikme arttıkça uyarıcıların aldıkları ağırlıklar azalmaktadır. Yani koşullanma gücü azalmaktadır. Elde edilen bu sonuç literatürde var olan sonuçlara uymaktadır.

-Pekiştirme

DU ve NU arasında koşullanmanın gerçekleşmesi için pekiştirme olması gerekmektedir. Şekil 4.4.'te eş zamanlı pekiştirilmiş NU ve DU ilişkisi gösterilmiştir.




Şekil 4.4. Pekiştirme

Şekil 4.4'te DU (1. uyarıcı) ile koşullanan NU'ların (2, 3, 4 ve 5. uyarıcılar) koşullanma süreci gösterilmiştir. Koşullanmanın gerçekleşebilmesi için NU ve DU ilişkisinin pekiştirilmesi gerekmektedir. Öğrenme küçük adımlar ile gerçekleştiğinden pekiştirme olmaması durumunda istenen seviyede öğrenme gerçekleşmediği literatürde belirtilmiştir (Malaka ve Hammer, 1996; Balkenius ve Moren, 1998; Yeşilyaprak, 2012).

-Sönme

KU ile KT arasındaki ilişki bir süre pekiştirilmediğinde aradaki ilişki sönme eğilimine girmektedir (Şekil 4.5).




Şekil 4.5. Sönme

Sönme sürecinde organizma ilgiliyse veya dışarıdan tepkisel uyarıcı ile desteklendikçe unutmaya süreci tamamen gerçekleşmez. Bu durum Yapıcı ve Yapıcı'nın (2005 ve 2010) belirttiği gibi insanlarda koşullanma yoluyla öğrenmenin daha kalıcı olmasının nedeni olarak kabul edilebilir.

-Genelleme ve ayırt etme

Biri DU (1. uyarıcı), dördü (2., 3., 4. ve 5. uyarıcı) gecikmeli (sırasıyla eşzamanlı ile 1, 2 ve 3 örnek) ve geri kalan ikisi (6. ve 7. uyarıcı) rastgele uyarıcı ile karşılaşan organizmanın koşullanma sürecindeki ağırlık değişimi Şekil 4.6.'da gösterilmiştir.



Şekil 4.6. Uyarıcıların genelleşmesi ve ayırt edilmesi

Şekil 4.6'dan görüldüğü gibi 2-5. uyarıcılar, DU (1. uyarıcı) ile koşullanmış iken rastgele oluşan 6-7 uyarıcılar koşullanmamıştır (yani, pekiştirilemediğinden DU-NU bağı kurulamamıştır) Bu uyarıcıların arasındaki benzerlik ve korelasyon Tablo 4.2 ve 4.3'te özetlenmiştir.

Tablo 4.2. Uyarıcılar arasında benzerlik ilişkisi

Uyarıcı	1	2	3	4	5	6	7
1	1	1	1	1	1	0,064	0,046
2	1	1	1	1	1	0,064	0,046
3	1	1	1	1	1	0,064	0,046
4	1	1	1	1	1	0,064	0,046
5	1	1	1	1	1	0,064	0,046
6	0,064	0,064	0,064	0,064	0,064	1	0,100
7	0,046	0,046	0,046	0,046	0,046	0,100	1


Tablo 4.3. Uyarıcılar arasındaki korelasyon ilişkisi

Uyarıcı	1	2	3	4	5	6	7
1	1	1	-0,142	-0,142	-0,142	0,010	0,010
2	1	1	-0,142	-0,142	-0,142	0,010	0,010
3	-0,142	-0,142	1	-0,142	-0,142	0,010	-0,045
4	-0,142	-0,142	-0,142	1	-0,142	-0,009	0,010
5	-0,142	-0,142	-0,142	-0,142	1	-0,015	-0,015
6	0,010	0,010	0,010	-0,009	-0,015	1	-0,010
7	0,010	0,010	-0,045	0,010	-0,015	-0,010	1


Şekil 4.6 ve Tablo 4.2 incelendiğinde organizmanın KU'ya benzer diğer uyarıcılara da KU'ya verdiği tepkinin aynısını verme eğiliminde olduğu, benzer olmayan olay serilerinde ise KU'dan kaynaklanan tepkiden farklı tepkiler verdiği gözlemlenememektedir. Bu durum literatüre verilerine de uymaktadır (Schunk, 2012; Fer vd., 2011). Tablo 6.3 incelendiğinde elde edilen korelasyon değerleri ile uyarıcılar arasında bir ilişki gözlemlenememektedir. Bunun nedeni korelasyonun zamansal gecikmelere karşı hassas oluşudur.

-Gölgeleme

Şekil 4.7(a)'da iki ayrı koşullanma süreci gösterilmiştir. 1. ve 3. uyarıcılar DU, 2. uyarıcı eşzamanlı ve 4. uyarıcı ise gecikmeli uyarıcıdır. Şekil 4.7(b)'de ise aynı anda koşullanmış 2. ve 4. uyarıcıya maruz kalan organizma tepkisi baskın olan uyarıcıya ait tepkiyi gerçekleştirmiştir. Yani Şekil 4.7.'deki örnekte organizma 1. tepkiyi vermiştir.



Şekil 4.7(a). Gölgeleme: İki farklı koşullanma süreci




Şekil 4.7(b). Gölgeleme: Koşullanmış iki uyarıcının eş zamanlı uygulanması

Şekil 4.7'de görüldüğü gibi aynı anda farklı şiddetlerde uyarıcılara maruz kalan organizma en yüksek tepki şiddetine göre tepki üretmektedir.

-Öğrenilmiş acizlik

Öğrenilmiş acizliği olumsuz koşullanma olarak ifade etmek mümkündür; yani bu durum organizmayı olumsuz olarak desteklemek olarak ta belirtilebilir. Bu durumun modellenmesi sonucunda oluşan ağırlık değişimi Şekil 4.8'de gösterilmiştir.




Şekil 4.8. Öğrenilmiş acizlik

Şekil 4.8'de de görüleceği üzere organizma başarısızlığı öğrenilmiştir.

-Kendiliğinden geri gelme

Koşullanmış olan bir uyarıcı pekiştirilmemesi sonucunda sönmektedir. Ancak organizmanın ilgisinin sönmemesi durumunda tamamen unutulmamaktadır. Organizma herhangi bir anda maruz kaldığı uyarıcılardan kaynaklı tepkiler arasında en baskın tepkiyi verme eğilimindedir. Bu durumda tam unutma gerçekleşmediği için herhangi bir anda sönmüş olsa bile Şekil 4.9.'da gösterildiği gibi organizma söz konusu uyarıcıyla ilişkili olan tepkiyi gösterilebilmektedir.




Şekil 4.9. Kendiliğinden geri gelme

Şekilden görüldüğü gibi organizma öğrenilmiş ancak daha sonra tekrar edilmediği halde hala desteklendiği için tam olarak sönmemiş veya öğrenilmemiş ama desteklenmiş olduğundan zayıf birçok uyarıcı-tepki bağı mevcuttur. Organizma maruz kaldığı uyarıcıların neden olabileceği en baskın tepkiyi üretecektir. Şekil 4.9'da 2. uyarıcıya ait tepki de tam olarak unutulmamış bir tepkidir ve bu sönmüş tepki (1. uyarıcıya ait tepki) şiddetinden daha düşük bir tepki grubu ile karşılaşıldığında organizma sönmüş tepkiyi vermiştir.

-Dereceli koşullandırma

Şekil 4.10'da üç adet uyarıcı gösterilmiştir. Bu uyarıcılardan 1. uyarıcı koşullu, 2. uyarıcı eşzamanlı ve 3. uyarıcı ise gecikmeli uyarıcıdır.




Şekil 4.10. Dereceli koşullandırma

Şekil 4.10’da görüldüğü gibi koşullu şartlandırıcıya (1. uyarıcı) bağlı olarak yeni koşullanma (2. ve 3. uyarıcı) oluşmaktadır. 1. uyarıcı DU değil, daha önce koşullanmış bir uyarıcıdır. Sönmemesinin nedeni ise pekiştirilmesine devam edilmesidir.

-Tekrar kazanım

Şekil 4.11’de DU (1. uyarıcı), eşzamanlı (2. uyarıcı) ve gecikmeli (3, 4 ve 5. uyarıcılar) uyarıcıların koşullanma, sönme ve tekrar koşullanma süreçleri simüle edilmiştir.




Şekil 4.11. Tekrar kazanım

Şekil 4.11’de görüldüğü gibi öğrenme adım katsayısının adaptif olması nedeniyle her öğrenmeden sonra tekrar öğrenme daha hızlı olmaktadır. Yani, Pavlov’un (1927) belirttiği gibi bir şeyi ikinci defa öğrenme, ilk öğrenmeden daha hızlı iken üçüncü öğrenmeden daha yavaştır. Şekil 4.11’de koşullanmanın gerçekleştiği τ_1 , τ_2 ve τ_3 ’ün sırasıyla 950, 650 ve 400 örnektir.

-Geçmiş yaşantı

Önerilen modelde geçmiş yaşantı başlangıç ağırlıkları ile ifade edilmektedir. Yani farklı başlangıç değerleri, farklı geçmiş tecrübeye atıf edilebilir ve farklı başlangıç değerlerine sahip uyarıcıların koşullanma süreci Şekil 4.12’de gösterilmiştir.




Şekil 4.12. Geçmiş yaşam

Şekil 4.12’de görüldüğü gibi koşullanma sürecinde ağırlık değişimleri, Stuart vd.’de (1987) belirttiği gibi organizmanın geçmiş tecrübesiyle ilintilidir.

-Doğal uyarıcı ve diğer uyarıcılar arasındaki istatistiksel ilişki

Pornpitakpan (2012) DU ve KU arasındaki istatistiksel bağımlılığın koşullanmanın oluşmasında önemli olduğunu belirtmiştir. Bu ilişkiyi tespit etmek için biri DU, biri eş zamanlı, dördü gecikmeli ve ikisi rastgele uyarıcının koşullanma sürecinde elde edilen ağırlıklar Şekil 4.13.’te gösterilmiştir.



Şekil 4.13. İstatistiksel ilişki

Sürece ilişkin DU ile diğer uyarıcılar arasında benzerlik ve korelasyon ilişkisi Tablo 4.4'te verilmiştir.

Tablo 4.4. DU ile diğer uyarıcılar arasındaki istatistiksel ilişki

Özellik	Uyarıcılar						
	1	2	3	4	5	6	7
Benzerlik	1	1	1	1	1	0,064	0,046
Korelasyon	1	1	-0,142	-0,142	-0,142	0,010	0,010


Şekil 4.13 ve Tablo 4.4 incelendiğinde koşullanmanın oluşmasında DU ile diğer uyarıcılar arasındaki istatistiksel ilişkinin önemli olduğu görülmektedir.

4.1.2. Watson'ın Yaklaşımı

Önerilen model ile Watson'ın yaklaşımlarının Kuramsal Temeller'de anlatılmış ilkeleri ve deneyi başarılı bir şekilde gerçekleştirilmiştir.

-En son, sıklık ve bağ ilkeleri

Önerilen GDÖ modelinde uyarıcı ağırlıklarının değişimi öğrenme katsayıları olan sönme (β) ve öğrenme adım (η) katsayılarıyla ilişkilidir. Seçilen parametre değerleri ile ağırlık değişimlerinin hızı belirlenmektedir. Ancak doğal olanı bu adımların küçük seçilmesi yani ağırlık değişimlerinin düşük olmasıdır. Bu durumda organizma bir uyarıcıya verdiği en son tepkiyi tekrarlama ihtimali diğerlerine göre daha yüksektir. Ayrıca koşullanmanın oluşabilmesi için uyarıcı tepki bağının tekrarlanması gerekmektedir. Şekil 4.14'te bir DU (1. uyarıcı) ve bir NU'dan (2. uyarıcı) oluşan öğrenme süreci modellenmesi sonucunda elde edilen ağırlıklar gösterilmiştir.




Şekil 4.14. En son, sıklık ve bağ ilkeleri

Şekil 4.14'te organizmanın bir uyarıcıya verdiği en son tepkinin tekrar verilme olasılığının yüksek olması modelde öğrenme katsayılarının küçüklüğü ile ilişkilidir. Modelde bulunan öğrenme katsayılarının küçük seçilmesinin psikolojik nedenleri olduğu kadar biyolojik nedenleri de vardır. Bu katsayıları biyolojik sinir sisteminin elektriksel geçirgenliğiyle ilişkilendirmek de mümkündür (Hughes, 1958).

-Küçük Albert Deneyi

Küçük Albert deneyinde Watson, Albert adında bir bebeği daha önce korkmadığı beyaz tavşandan ve daha sonra beyaz peluş oyuncaklardan korkması için şartlandırmıştır. Bu deneyin modellenmesi sürecinde oluşan ağırlık değişimleri Şekil 4.15'te gösterilmiştir.




Şekil 4.15. Küçük Albert Deneyi

Şekil 4.15'teki 1. uyarıcı beyaz tavşanla beraber uygulanan ve bebeğin korkmasına neden olan yüksek zil sesini, 2. uyarıcı ise beyaz tavşanı ifade etmektedir. Bu deneyin gerçekleşmesinde zil sesinin korkuya neden olması nedeniyle organizmaya olumsuz tepkisel uyarıcı görevi görmüştür. Görüldüğü gibi 2. uyarıcının ağırlığı negatife (olumsuz tepkiye) doğru değişmiştir.

4.1.3. Guthrie'nin Yaklaşımı

-Bitişiklik

Şekil 4.16'da biri DU (1. uyarıcı), biri eşzamanlı (2. uyarıcı), gecikmeli (3-6. uyarıcı) ve biri rastgele (7. uyarıcı) uyarıcıdan oluşan organizma koşullanma sürecindeki ağırlık değişimleri gösterilmiştir.




Şekil 4.16. Bitişiklik ve bağ

Şekil 4.16'da 3., 4., 5., ve 6. uyarıcılar ile DU arasındaki gecikme sırasıyla 1, 2, 3, ve 4 örnekleme anıdır ve DU ile NU arasında gecikme arttıkça koşullanma şiddeti azalmaktadır. Tasarlanan modelde ilişkilendirilecek uyarıcı sayısı ile Guthrie'nin kuramında DU ile NU arasında zamansal gecikme ile ilişkilidir. Ancak birleştirilecek olay sayısı denek türüne göre değişiklik göstermesi beklendiği için modelde değişken olarak verilmiştir. Ayrıca, Guthrie kuramında “eğer bir uyarıcıdan sonra birden fazla tepki oluşursa uyarıcı ile en yakın tepki arasında bir bağ oluşacaktır” ilkesini önermiştir. Önerilen modelde de tepkinin yakın olduğu uyarıcılarla olan bağının daha yüksek olduğu ve uyarıcı ile tepki arasındaki gecikme arttıkça bu bağın gücünün (ağırlığının) birleştirme katsayısının üstel haliyle orantılı olarak düştüğü görülmüştür.

-Dikkat ve hazır oluş

Organizmanın uyarıcı-tepki bağıını kurmaya (öğrenmeye) olan ilgisi organizma uyarıcısı ile gösterilmiştir. Organizma uyarıcısı hesaplanırken davranışçı öğrenme kuramlarında organizma ile alakalı olarak tanımlanmış olan dokuz uyarıcıdan ikisi dikkat ve hazır oluştur. Organizma uyarıcısının değişiminin öğrenme sürecine olan etkisi modellenerek elde edilen ağırlık değişimleri Şekil 4.17’de gösterilmiştir.




Şekil 4.17. Dikkat ve hazır oluş

Şekil 4.17’de 1. uyarıcı DU, 2. uyarıcı dikkatli ve hazır bir organizma, 3. uyarıcı ise tam dikkati veya hazır olmamış bir organizma için oluşan ağırlık değişimleri gösterilmiştir. Organizmanın uyarıcıya verdiği dikkat azaldıkça ya da organizmanın tepkiye hazır olmaması durumunda öğrenme sürecinde başarının azaldığı görülmektedir.

-Olumsuz davranışları değiştirme yöntemleri

Guthrie olumsuz davranışları değiştirmek için üç yöntem önermiştir (Yapıcı ve Yapıcı, 2005 ve 2010; Topses, 2009). Bunlar:


Eşik yöntemi: Burada tepki verilemeyecek kadar zayıf uyarıcılar ile davranışın değiştirilmesi süreci gerçekleşmiş ve elde edilen ağırlık değişimleri Şekil 4.18’de verilmiştir.



Şekil 4.18. Eşik yöntemi


Şekil 4.18’de 1. uyarıcı olarak $t_n=250$ anında ilk olumsuz uyarıcıya maruz kalmıştır. Bir süre sonra organizma artık ilk olumsuz uyarıcıya alışmış olduğundan, 1. uyarıcı için olumsuz tepki vermemiştir. $t_n=750$ anında ise ikinci bir olumsuz uyarıcı ile karşılaşan organizma bir süre sonra bu olumsuz uyarıcıya alışmakta ve tepkisi olumsuzdan nötre dönmüştür.

Yorma yöntemi: Organizmaya değiştirilmek istenen davranışa ait uyarıcının aşırı yoğun şekilde verilmesi durumunda bir süre sonra organizma bu uyarıcıdan yavaş yavaş sıkılmasına neden olmaktadır. Yani organizma uyarıcısının şiddeti zamanla azalmaktadır. Azalan organizma uyarıcı şiddeti ise uyarıcı ağırlıklarının yavaş yavaş düşmesine yani tepkinin sönmesine neden olmaktadır (Şekil 4.19).



Şekil 4.19. Yorma yöntemi

Bağdaşmayan uyarıcılar yöntemi: Şekil 4.20’de bağdaşmayan uyarıcılar yöntemi ile davranış değiştirme yönteminin simülasyon sonucu verilmiştir.




Şekil 4.20. Bağdaşmayan uyarıcılar yöntemi

Şekil 4.20’den de görüldüğü üzere iki adet uyarıcı bulunmaktadır. 2. uyarıcı olumsuz tepkisel uyarıcı ile olumsuz tepkiye neden olan DU’ya (1. uyarıcı) koşullanmıştır.

4.1.4. Thorndike’in Yaklaşımı

-Bağlaşımcılık

Şekil 4.21’de biri DU (1. uyarıcı), biri eşzamanlı (2. uyarıcı), üçü farklı gecikme anı olan gecikmeli uyarıcı (3-5) ve 2 adet rastgele uyarıcının (6, 7) bulunduğu koşullanma süreci gösterilmiştir.



Şekil 4.21. Bağlaşımcılık

Şekil 4.21’de gösterilmiş olan biri DU (1. uyarıcı), biri eşzamanlı (2. uyarıcı), üçü gecikmeli (3., 4. ve 5. uyarıcılar) ve iki tane rastgele uyarıcıdan oluşan tepki ile uyarıcılar arasındaki benzerlik ve korelasyon değerleri Tablo 4.5’te verilmiştir.

Tablo 4.5. Uyarıcılar ve tepki arasındaki ilişki


Özellik	Uyarıcı:						
	1	2	3	4	5	6	7
Benzerlik	1	1	1	1	1	0,064	0,046
Korelasyon	1	1	-0,142	-0,142	-0,142	0,010	0,010

Tablo 4.5’teki değerler ve Şekil 4.21’de verilen grafikler göz önüne alındığında koşullanma süreci sonunda uyarıcı ve tepki arasında benzerlik ilişkisi olduğu görülmektedir.


-Deneme yanılma

Deneme yanılma ile öğrenme başarılı yani organizmayı tatmin edici sonuçlar veren tepkilerin doğal olarak desteklenmesine dayanmaktadır. Bu durum tepkisel uyarıcının modeldeki etkisi ile ifade edilmektedir. Başarı çevreden alınan dönüte göre belirlenen bir sonuçtur. Organizmanın nötr çevresel tepkiler alması durumunda uyarıcı-tepki bağı uyarıcıların başlangıç ağırlıklarına bakılmaksızın sönme katsayısıyla ile orantılı olarak sönmektedir. Bu durum Şekil 4.22(a)’da gösterilmiştir.


Organizmanın rastgele nötr ve olumsuz tepkisel uyarıcılar ile karşılaşması durumunda oluşan ağırlık değişimleri Şekil 4.22(b)’de gösterilmiştir. Görüleceği gibi olumsuz dönütler sadece sönme sürecini hızlandırmıştır. Organizmanın olumlu, rastgele nötr ve olumlu ve olumsuz tepkisel uyarıcı ile uyarılması ile oluşan ağırlık değişimleri sırasıyla Şekil 4.22(c), (d) ve (e)’de gösterilmiştir.




Şekil 4.22(a). Tepkisel uyarıcı: Sürekli nötr




Şekil 4.22(b). Tepkisel uyarıcı: Rastgele olumsuz veya nötr



Şekil 4.22(c). Tepkisel uyarıcı: Sürekli olumlu




Şekil 4.22(d). Tepkisel uyarıcı: Rastgele olumlu veya nötr




Şekil 4.22(e). Tepkisel uyarıcı: Sürekli olumsuz

-Küçük adımlar

Thorndike öğrenmeyi küçük adımlarla gerçekleşen bir süreç olarak yorumlamıştır. Önerdiğimiz modelde seçilen öğrenme katsayıları ile öğrenme adımları belirlenmektedir.



Şekil 4.23(a). Farklı katsayılara sahip uyarıcılar: farklı öğrenme katsayısı




Şekil 4.23(b). Farklı katsayılara sahip uyarıcılar: farklı sönme katsayısı

Şekil 4.23(a)'da farklı öğrenme katsayısına sahip uyarıcılara sahip bir organizmada öğrenme süreci sonucunda oluşan ağırlık değişimleri gösterilmiştir. Burada 1. uyarıcı DU ve diğer uyarıcılar (2., 3. ve 4. uyarıcılar) eşzamanlı uyarıcılardır ve öğrenme katsayıları olarak sırasıyla 0.04, 0.04, 0.08 ve 0.12 değerleri atanmıştır. Şekil 4.23(b)'de farklı sönme katsayılarına sahip uyarıcılara maruz kalan organizmanın öğrenme süreci simüle edilmiştir. Burada ise 1. uyarıcı DU ve geri kalan 2., 3. ve 4. uyarıcılar ise eşzamanlı uyarıcılardır ve sönme katsayıları sırasıyla 0,995, 0,995, 0,985 ve 0,975 şeklindedir. Özetle, öğrenme katsayısı artıkça öğrenme şiddeti artış göstermiştir. Unutma katsayısı düştükçe


organizma daha hızlı unutmuş ve öğrenme sürecinin sonucunda oluşan öğrenme ağırlıkları daha da düşmüştür.

-Tekrar kuralı

Tekrar ve pekiştirme aynı anlama gelen bir kavramdır. Tekrar ile oluşan koşullanma süreci Şekil 4.24(a)'da ve tekrar etmeme durumunda uyarıcı-tepki bağında oluşan sönme süreci Şekil 4.24(b)'de gösterilmiştir.



Şekil 4.24(a). Tekrar: Tekrar edilme




Şekil 4.24(b). Tekrar: Tekrar edilmeme

Şekil 4.24(a)'da 1. uyarıcı DU, 2. uyarıcı ise NU'dır. Şekil 4.24(b)'de ise 1. uyarıcı DU ve 2. uyarıcı ise KU'dır. Görüldüğü gibi tekrar ile koşullanma oluşurken KU tekrar edilmediğinden sönmiştir.

-Bağlantı kurarak geçiş kuralı

Eski uyarıcı ile yeni uyarıcı arasında bağlantı kurarak eski uyarıcıya verilen tepkinin yeni uyarıcıya da verilmesi sürecinin ağırlıkları Şekil 4.25'te gösterilmiştir.



Şekil 4.25. Bağlantı kurarak geçiş kuralı

Şekil 4.25'te gösterilen DU ile diğer uyarıcılar arasındaki istatistiksel ilişki Tablo 4.6'da gösterilmiştir.


Tablo 4.6. DU ile diğer uyarıcılar arasındaki ilişki

Özellik	Uyarıcılar					
	1	2	3	4	5	6
Benzerlik	1	1	1	1	0,046	0,052
Korelasyon	-0,142	1	-0,142	-0,142	-0,021	0,040

Görüldüğü gibi DU ile uyarıcı arasında koşullanmanın gerçekleşmesi için benzerlik ilişkisi bulunması gerekmektedir.

-Transfer (Geçiş) Kuralı

Eski öğrenilenler, yeni şeylerin öğrenilmesine kolaylık sağlamaktadır. Bu durumun modellenmesi sonucu oluşan ağırlık değişimleri Şekil 4.26'da gösterilmiştir.




Şekil 4.26. Transfer kuralı

Şekil 4.26’da 1. uyarıcı DU, 2. uyarıcı ise başlangıçta NU’dır. 2. uyarıcı farklı DU’ya göre farklı gecikme değerleri ile koşullanmıştır. Üç farklı aşamada gerçekleşen koşullanma süreci sonucunda NU, eşzamanlı KU’ya dönüşmüştür.

-Etki kuralı

Önerilen modelde gerçekleşen bir tepkiden dolayı oluşan tatmin tepkisel uyarıcı ile ifade edilmiştir. Peş peşe olumlu ve olumsuz tepkisel uyarıcıya maruz kalan organizmanın öğrenme süreci sonucu oluşan ağırlık değişimleri Şekil 4.27’de gösterilmiştir.



Şekil 4.27. Etki kuralı


Bu süreçte organizma ilk 1500 örnekte olumlu tepkisel uyarıcı ikinci 1500 örnekte ise olumsuz tepkisel uyarıcıya maruz kalmıştır. Şekil 4.27’de görüldüğü

gibi uyarıcı ağırlığı bize ilk 1500 örnek için Thorndike'ın çalışmalarında belirttiği gibi uyarıcı-tepki bağıını güçlendirmiş, diğer 1500 örnek için ise zayıflatmıştır (Yeşilyaprak, 2012).


-Organizma ile alakalı kurallar

Thorndike organizma ile alakalı: güdülenme, hazır bulunuşçuluk, çeşitli tepki, tutum-tavır ve öğrenilen materyalin temel unsurlarına tepki gösterme kurallarını önermiştir. Daha önce de izah edildiği gibi, önerilen modelde organizma uyarıcısı 9 ayrı uyarıcı ile ifade edilmiştir (bunlar: beklenti, gereksinim, ortam, dikkat, hazır oluş, ilgi, istek ve materyalin ve problemin önemidir). Organizma uyarıcısı bu değerlerin ortalaması olarak hesaplanarak ve 0 ile 1 arasında skorlandırılmıştır. Bu değerler organizmanın durumu ve karar verilecek duruma ait uyarıcıların özelliklerine bağlı olarak belirlenmektedir. Bu durum Allen ve Madden (1985) ve Malone'un (1990) yapmış oldukları çalışmada koşullanmanın organizmanın ihtiyaçları veya beklentileri doğrultusunda gerçekleştiğini gösterdikleri çalışmalarına da uymaktadır.

Ayrıca Dalla ve Shors (2009) yaptıkları çalışmada cinsiyet farkının öğrenme üzerinde etkili olduğunu belirtmişlerdir. Bu farklı cinsiyetlerin uyarıcılara karşı farklı organizma uyarıcısı oluşturmaları olarak açıklanabilir. Organizma uyarıcılarının ağırlıksal açıdan etkisi: organizmanın türüne, cinsiyetine veya fiziksel ve kimyasal yapısına bağlı olarak değişiklik gösterebilmektedir. Organizma uyarıcılarının değişimleri Şekil 4.28(a) ve (b)'de gösterilmiştir.



Şekil 4.28(a). Organizma uyarıcısının şiddeti: düzenli olarak azalma




Şekil 4.28(b). Organizma uyarıcısının şiddeti: Rastgele olarak belirlenme

Şekil 4.28(a)'da organizma uyarıcısının şiddetinin yavaş yavaş düşmesi sonucu oluşan ağırlık değişimleri gösterilmiştir. Bu durum organizmanın yavaş yavaş bir tepkiden sıkılması olarak ve süreç sonunda bu tepkiden uzak durmaya çalışması olarak yorumlanabilir. Şekil 4.28(b)'de ise iki adet rastgele organizma uyarıcısı bulunan örnek bulunmaktadır. Şekilde de görüldüğü gibi rastgele oluşan organizma uyarıcısı uyarıcı-tepki bağının kuvvetlenmesine engel olmuştur.


4.1.5. Skinner'in Yaklaşımı

-Pekiştirme ve ceza

Şekil 4.29(a) ve (b)'de ödüllendirilen ve cezalandırılan iki ayrı organizmanın verdiği tepkiler gösterilmiştir.



Şekil 4.29(a). Pekiştirme: ödüllendirme




Şekil 4.29(b). Pekiştirme: cezalandırma

Şekil 4.29(a)'da organizma uyarıcısı ile ödüllendirilen bir organizmada ağırlık değişimi gösterilmiştir. Görüldüğü gibi edimsel koşullanmada organizma pekiştirici uyarıcıyla izlenen tepkiler tekrarlanma eğilimindedir ve pekiştirici uyarıcılar, edimsel davranışların meydana gelme olasılığını artırılmıştır. Şekil 4.29(b)'de olumsuz organizma uyarıcısına maruz bırakılan bir organizmadaki uyarıcı ağırlıklarının değişimi gösterilmiştir. Görüldüğü gibi organizma cezalandırıldığı tepkilerden uzak durmaya çalışmıştır.

-Sönme

Organizmanın pekiştirilmemesi yani desteklenmemesi durumunda oluşan ağırlık değişimleri Şekil 4.30'da gösterilmiştir.




Şekil 4.30. Sönme


Şekil 4.30'da organizma uyarıcısının nötr kalması nedeniyle oluşan uyarıcı-tepki bağındaki sönme görülmektedir.

-Biçimlendirme

Daha güçlü koşullanma bağı oluşturmak için birden fazla uyarıcı pekiştirilerek edimsel olarak koşullanmakta bunların toplam etkisi ile istenen tepki oluşturulmaktadır. İki uyarıcı ile davranış biçimlendirme örneği Şekil 4.31'de gösterilmiştir.



Şekil 4.31(a). Davranış biçimlendirme: farklı uyarıcıların edimsel koşullanması




Şekil 4.31(b). Davranış biçimlendirme: iki farklı uyarıcının uygulanması

4.31(a)'da iki ayrı uyarıcı farklı zamanlarda olumlu olarak pekiştirilerek uyarıcı-tepki bağı güçlendirilmiştir. Dolayısıyla, daha sonra iki uyarıcıyla eşzamanlı uyarılan organizmanın istenen tepkiyi verme olasılığı daha yüksektir.

-Genelleme

Koşullanmış uyarıcıya benzer uyarıcılara da organizma aynı tepkiyi vermektedir ve bu durum Şekil 4.32’de gösterilmiştir.



Şekil 4.32. Genelleme

Şekil 4.32’de uyarıcı ağırlıkları verilen uyarıcıların kendi aralarındaki benzerlik ve korelasyon değerleri Tablo 4.7’de verilmiştir.


Tablo 4.7. Uyarıcılar arasındaki benzerlik

Uyarıcı	Benzerlik			Korelasyon		
	1	2	3	1	2	3
1	1	1	0,070	1	-0,142	-0,003
2	1	1	0,070	-0,142	1	-0,003
3	0,070	0,070	1	-0,003	-0,003	1

Görüldüğü üzere benzer uyarıcılar Skinner’ın da belirttiği gibi benzer tepkiler üretmektedir.

-Ayırt edici uyarıcı

Bu süreçte organizma istenen tepkiyi ürettiğinde olumlu tepkisel uyarıcı ile uyarılmakta ve uyarıcı ile eşzamanlı uyarıcılar desteklenmiş olacağından ayırt edilmektedir. Bu durum Şekil 4.33’te gösterilmiştir.



Şekil 4.33. Ayırt edici uyarıcı

Şekil 4.33'te görüldüğü gibi eşzamanlı uyarıcı (2. uyarıcı) daha yüksek ağırlığa sahip olmuş ve böylece ayırt edilmiştir.


4.1.6. Arduino ile Modelleme

Önerilen modelin gerçek hayattaki başarısının test edilmesi için Arduino Mega 2560 adlı bir mikrodeneççi kartı ve algılayıcılar kullanılarak Pavlov'un deneyi modellenmiştir. Arduino Mega 2560 kartının özellikleri Tablo 4.8'de verilmiştir (<http://arduino.cc>).

Tablo 4.8. Arduino Mega 2560 mikrodeneççi kartının özellikleri (<http://arduino.cc>)


Çalışma Gerilimi	5V
Giriş Gerilimi (Önerilen)	7-12V
Dijital I/O Giriş Sayısı	54
Analog Giriş Sayısı	16
DC Giriş Akımı (I/O)	40 mA
Flash Hafıza	256 KB
SRAM Hafıza	8 KB
EEPROM Hafıza	4 KB
İşlemci Hızı	16 MHz

Yapılan deneysel çalışmada algılayıcı olarak hareket detektörü ve dokunma algılayıcısı kullanıldı. Hareket detektörü koşullanması istenen uyarıcı yani kapı sesini (2. uyarıcı), dokunma algılayıcısı, rastgele bir uyarıcı (3. uyarıcı) olarak kullanıldı. Anahtarlar ise sırasıyla hareket dedektörüne eş zamanlı olarak uygulanacak uyarıcıyı (yemek), organizma uyarıcısı ve tepkisel uyarıcının yerine kullanıldı. Kurulan devre Şekil 4.34'te gösterilmiştir.



Şekil 4.34. Pavlov'un Deneyi

Yapılan deneyde koşullanma sonucu oluşan ağırlık değişimleri devreye bağlı SD hafıza kartına kaydedildi. Elde edilen ağırlık değişimi Şekil 4.35'te gösterilmiştir.



Şekil 4.35. Ağırlık değişimi

Yapılan deneyde önerilen modelin gerçek ve anlık veriler ile başarılı sonuçlar üretebildiği görülmüştür.


4.2. Önerilen Davranışsal Öğrenme Modelinin Analizi

Yapılan çalışmada Pavlov, Watson, Guthrie, Thorndike ve Skinner'ın önerdikleri davranışçı öğrenme kuramlarının çeliştikleri noktalardan olan içsel süreçlerin karar vermedeki etkisi deneysel olarak test edilmiştir. Deney sonuçları ve davranışçı kuramlarla ilgili yapılan çalışmalar ışığında davranışçı öğrenme kuramları genelleştirilmiştir. Daha sonra genelleştirilmiş kuram matematiksel olarak modellenmiş ve önerilen modelin Pavlov, Watson, Guthrie, Thorndike ve

Skinner'ın önerdikleri kuramlarının tüm özelliklerini sağladığı deneysel olarak tespit edilmiştir. Elde edilen sonuçlar önerdiğimiz kuramın insan öğrenmesini gerçekleştirebildiğini göstermiştir. Bu bölümde ise önerilen modelin genel özellikleri ile ürettiği tepki, ihtiyaç duyduğu işlemsel yük ve hafıza ihtiyacı incelenmiştir.

4.2.1. Önerilen Modelin Genel Özellikleri

Önerilen model Şekil 4.36'da gösterildiği gibi uyarıcıların ağırlıklandırılması ve bu ağırlıkların her tepki sonrası güncellenmesi esasına göre çalışmaktadır.



Şekil 4.36. Modelin yapısı

Yapılan çalışmada önerilen modelin özellikleri aşağıda listelenmiştir.

- İnsan gibi sürekli öğrenmektedir.
- Tepkisel uyarıcı ile çıktıların hata kontrolü yapılmaktadır.
- Organizma uyarıcısı ile organizmanın tepkiye odaklanması sağlanmaktadır.
- Önerilen model süreç içerisinde öğrenme ve unutma kabiliyetine sahiptir. Olayları sırasına göre işler ve sönme katsayısı ile ilişkili olarak unutmaktadır.
- Eğitim verilerinin işlenmesi tekrar tabanlı değil, gerçek zamanlıdır. Bir veri sadece karşılaşıldığında işlenmektedir.

4.2.2. Önerilen Modelin Özellikleri

Öğrenme sisteminin kararlılığının test edilmesi amacıyla Denklem 3.8 tek bir uyarıcı ve tepki için yeniden aşağıdaki gibi yazılabilir.

$$T^{tn} = w^{tn} * U^{tn} \quad (4.1)$$

Transfer fonksiyonu ise:

$$TF = \frac{T(s)}{U(s)} = W(s) \quad (4.2)$$

olur. Burada sistemin transfer fonksiyonu olarak tanımlanan ağırlıkların değişimi Denklem 4.3'teki gibi ifade edilebilir.

$$w^{t_n} = \beta w^{t_{n-1}} + \eta * U^{t_n} * \bar{T}^{t_n} * (\overline{TU}^{t_n} + \overline{OU}^{t_n}) \quad (4.3)$$

Denklem 4.3'te görüleceği üzere uyarıcı, tepki, tepkisel uyarıcı ve organizma uyarıcılarının alacağı değerlere göre ağırlıklar güncellenmektedir. Bu değerlerin çarpımı ψ^{t_n} olarak gösterilirse tek uyarıcı için ağırlık denklemi:

$$w^{t_n} = \beta w^{t_{n-1}} + \eta * \psi^{t_n} \quad (4.4)$$

olur. Her iki tarafında z dönüşümü alınır ise, yeni ağırlıklar:

$$W^z = \beta z^{-1} W^z + \eta * \psi^z \quad (4.5)$$

$$W^z = \frac{\eta \psi^z}{(1 - \beta z^{-1})} \quad (4.6)$$

Elde edilen sistemin karakteristik yapısını özetlemek için bazı özellikleri aşağıda sıralanmıştır.

-Kararlılık


Denklem 4.6'da kutup noktası $z = \beta$ değeridir. β , 0 ile 1 arasında tanımlandığından ψ^z fonksiyonu kararlı olduğu sürece sistem de kararlıdır. Yani sistem sınırlı girişe karşılık sınırlı çıktı üretmektedir.

-Nedensellik

Önerilen modelde tepki, tepkisel uyarıcı ve organizma uyarıcısı zamansal olarak geriye yayılmıştır. Görüldüğü gibi herhangi bir andaki çıktı (tepki) değeri o an ve daha önceki anlarda oluşan girişlere göre belirlenmektedir. Yani sistem nedenseldir. Denklem 4.6'da gösterilen ağırlık fonksiyonunun yakınsama bölgesi (ψ^z sabit veya kutbu olmayan bir fonksiyon olarak alınmıştır) ise Şekil 4.37'de gösterildiği gibi:

$$|\beta z^{-1}| < 1 \text{ veya } |\beta| < |z| \quad (4.7)$$

şeklindedir.



Şekil 4.37. Sistemin yakınsama bölgesinin şematik gösterimi

ψ^z sabit veya kutbu olmayan bir fonksiyon olarak kabul edilirse Şekil 4.37'daki yakınsama bölgesinden de görüleceği üzere önerilen sistem nedenseldir.

-Hafıza

Önerilen modelde tepki, tepkisel uyarıcı ve organizma uyarıcısı zamansal olarak geriye yayılmamaları ağırlık hesaplanırken değerlendirmeye alındığı için sistem hafızalıdır.

-Doğrusallık

Önerilen model klasik yapay öğrenme yaklaşımlardan farklı olarak sürekli öğrenmektedir. Bu öğrenme sürecinin bir sonucu olarak ağırlıklar sürekli güncellenmektedir. Herhangi bir t^n anı için (sabit ağırlık değerleri için) sistem toplamsallık ve ölçeklendirme özelliklerine sahiptir yani doğrusaldır. Ancak her t^n anı için ağırlıklar değişebilmektedir.

4.2.3. Önerilen Modelin Eğitim Sürecinin İncelenmesi

Bu bölümde modelin yapay öğrenme açısından özellikleri incelenmiştir.

-Öğrenme türü

Yapay öğrenme temelde üç farklı şekilde gerçekleşmektedir. Bunlar:

- Gözetimli öğrenme: öğrenme eğitim kümesindeki istenen çıktı değerleri ile giriş değerleri kullanılarak sistemin girdi ve çıktıları arasında ilişkinin kurulduğu öğrenme biçimidir (örneğin, YSA, DVM).
- Gözetimsiz öğrenme: eğitim kümesinde çıktı değerleri kullanılmadan gerçekleşen öğrenme biçimidir (örneğin, kendi kendini organize eden haritalar).

- Takviyeli öğrenme: öğrenme sürecinde istenen çıktı değeri yerine farklı bir değişkenin doğrulama amacıyla kullanıldığı öğrenme biçimidir (örneğin, genetik algoritma).

Önermiş olduğumuz modelde öğrenme sürecinin kontrol edildiği parametreler, öğrenme adımının etkisini belirleyen organizma uyarıcısı, tepkisel uyarıcı, uyarıcı ve tepki (hesaplanan) değerleridir. Bu yöntemde öğrenme ödüle dayalı olduğundan takviyeli öğrenme yaklaşımı olduğu düşünülebilir.

-Veri işleme

Verilerin işleme tarzına bağlı olarak yapay öğrenme yöntemleri sınıflandırılmaktadır. Eğitim kümelerinin oluşumu:

- İşlenen veri miktarının sürekli arttığı,
- İşlenen veri miktarının sürekli azaldığı,
- Tüm veri kümesinin tek seferde işlendiği,
- Veri setinin seriler halinde parçalı olarak işlendiği,


yaklaşımlar olarak ayrıştırılmaktadır. Önerilen model örnek-artırımlı bir yaklaşımdır. Her veri sadece bir kez işlenmektedir. Ancak dağıtılmış değişkenlerin hesaplanması için ilişkili (kısa dönem hafıza) olay sayısı kadar veri saklanmakta ve bu veriler sürekli güncellenmektedir.

-Eğitim sürecinin tamamlanması (ağırlıkların optimizasyonu)

Önerilen model en yaygın kullanılan eğitim yaklaşımları olan genel hatayı en aza indirmeyi hedefleyen yapısal risk azaltma (örneğin, DVM) ve eğitim kümesinde hatayı en aza indirmeyi hedefleyen gözlemsel risk azaltma (örneğin, geri beslemeli öğrenme) yaklaşımlarından farklı olarak optimal ağırlığı hesaplama gibi bir motivasyonu yoktur. Ağırlık sürekli olarak her verilen tepkiden sonra güncellenmektedir. Ağırlık değişim hızı ise öğrenme ve unutma katsayıları ile belirlenmektedir.

-Hafıza

Önerilen modelde unutma hızı unutma katsayısı ile kontrol edilmektedir. Başlangıç değeri 1 olan ağırlığın farklı unutma katsayıları ile elde edilen ağırlık değişimleri Şekil 4.38'de gösterilmiştir.




Şekil 4.38. Unutma süreci - unutma katsayısı değişimi

Şekil 4.38’de görüldüğü gibi oluşan bir değerın unutulması unutma katsayısı ile ters orantılıdır.

-Gürültüye dayanıklılık

Önerilen modelin gürültüye karşı dayanıklılığını test etmek için girdilere farklı oranlarda (yüzdelik cinsinden) gürültü eklenmiştir. Gürültü rastgele oranda ve dağılımda sinyallere eklenmiştir. Farklı oranlarda gürültü eklenmesi sonucu oluşan ağırlık değişimleri Şekil 4.39’da gösterilmiştir.




Şekil 4.39. Ağırlık – gürültü oranı değişimi

Şekil 4.39’da görüldüğü gibi gürültünün artması sistem kararlılığını ya da öğrenmeyi etkilememekte ama ağırlık değerlerini değiştirmektedir. Elde edilen sonuç modelin gürültüye karşı oldukça dayanıklı olduğunu göstermektedir.

4.2.4. Önerilen Modelin Ürettiği Tepkinin Analizi


Önerilen model matematiksel açıdan karar üretme süreci daha önce anlatılmıştı. Burada sistemin verdiği karar, ürettiği sonuçlar bağlamında değerlendirilmiştir. İncelemelerde sürekli öğrenebilen Şekil 4.40'ta tek uyarıcı/tepki içeren model herhangi bir anda ürettiği kararlar analiz edilmiştir.




Şekil 4.40. Tek uyarıcı-tepki

Şekil 4.40'ta verilen modelde tepki sayısı artıkça karar uzayı da daha karmaşık bir ilişki sergilemektedir. Önerilen modelde uyarıcı – tepki bağı; temel sinirsel seviyede öğrenmeyi (sinaptik plastisite) açıklayabileceği gibi bir davranışı, beceriyi veya kavramı öğrenmeyi de anlamak ve modellemek için kullanılabilir. Modelde kesikli çizgi ile gösterilen eşik seviyeyi ifade eden blok dijital uygulamalarda veya sinaptik seviye öğrenme modellerinde kullanılabilir.

Sinaptik bağlantılarda ancak eşik değerini aşan uyarımlar iletebilir. Eğer uyarım gerçekleşiyorsa 1, aksi durumda 0 değerini almaktadır. Şiddet artıkça aksiyon potansiyel formunun tepe noktası değişmemekte fakat uyarının şiddetine bağlı iletilen sinyallerin yoğunluğunu artırmaktadır (Tağluk ve Tekin, 2014). Dijital uygulamalarda da aynı şekilde uyarıcılar 0 veya 1 değerini almaktadır. Bu değer ayrımı uyarıcı şiddetinin belirlenecek bir eşik değerini aşması ile kontrol edilebilir. Daha üst seviyelerde, yani sinaptik uyarılar yerine davranış, beceri veya bir konuda bilginin öğrenilme süreci analog olarak modellenmesi daha doğru bir yaklaşım olacağı düşünülmektedir. Bu durumda Şekil 4.40'ta kesikli çizgi ile gösterilen bloktaki eşik geçirgenliği yapısına ihtiyaç duyulmayacaktır. İki durumda da modellerin unutma ve öğrenme süreci Şekil 4.41'de gösterilmiştir.



Şekil 4.41(a). Öğrenme: sinaptik seviyede öğrenme



Şekil 4.41(b). Öğrenme: üst seviyede öğrenme

İki uyarıcı ve tek tepki türü olan bir modelin yapısı Şekil 4.42’te verilmiştir.




Şekil 4.42. Sinirsel seviyede uyarıcı-tepki bağı

Modelde tek bir tepki türü olması durumunda uyarıcı tepki bağı daha önce belirtildiği gibi sinaptik plastisite ile açıklanabilir. Eşik değerini aşmayan uyarıcılar

iletilmemektedir. Tepkinin şiddeti ise ağırlıklar ile belirlenmektedir. Bu durumda sistemin tepkisi aşağıdaki gibi hesaplanabilir.

$$T^{tn} = w_1^{tn} U_1^{tn} + w_2^{tn} U_2^{tn} \quad (4.8)$$

Bu durumda karar uzayı tepki₁'e eşit olacak yani; uyarıcılardan herhangi birinin eşik değeri aşması durumunda sistemin çıktısı olarak tepki₁ üretilecektir. Modelde tek bir ilişki söz konusu olduğunda doğrusal bir yaklaşım gösterdiği görülmektedir. Önerilen model Şekil 4.43'te gösterildiği gibi iki ayrı tepki türünü üretebilmektedir.




Şekil 4.43. İki uyarıcı ve iki tepki türü olan model yapısı

Bu şekilde iki adet tepki türünün söz konusu olduğunda denklem aşağıdaki gibi olacak ve karar uzayı dağılımı ise Şekil 4.44'teki gibi olacaktır.

$$T_1^{tn} = w_{1,1}^{tn} U_1^{tn} + w_{1,2}^{tn} U_2^{tn} \quad (4.9)$$

$$T_2^{tn} = w_{2,1}^{tn} U_1^{tn} + w_{2,2}^{tn} U_2^{tn}$$

$$T = \begin{cases} 0 & T_1 < 0 \text{ \& } T_2 < 0 \\ T_1 & (T_1 > 0 \mid T_2 > 0) \text{ \& } T_1 \geq T_2 \\ T_2 & (T_1 > 0 \mid T_2 > 0) \text{ \& } T_1 < T_2 \end{cases} \quad (4.10)$$




Şekil 4.44. İki tepkili uzay karar dağılımı

Karar eğrisi ise aşağıdaki denkleme göre belirlenebilir.


$$(w_{1,1} - w_{2,1})U_1 + (w_{1,2} - w_{2,2})U_2 = 0 \quad (4.11)$$

Tepki tür sayısı arttıkça karar uzay dağılımı daha da karmaşık hale gelmektedir.

Şekil 4.45'te 3 ve 4 tepkili modelin karar uzay dağılımı verilmiştir.



Şekil 4.45(a). Uzak karar dağılımı: iki tepkili



Şekil 4.45(b). Uzak karar dağılımı: üç tepkili

Şekil 4.44 ve 4.45'teki uzak ya da karar dağılımları önerilen modelin karar yüzeyini ifade etmekte ve dış bükey şeklindedir.

4.2.5. Önerilen Modelin İşlemsel Yük Analizi

Önerilen algoritma karar vermek için çok az işlemsel ihtiyacı bulunmaktadır. Önerilen yaklaşımın algoritması Şekil 4.46'da sunulmuştur.

Tablo 4.9. Kullanılan zaman (10 adet testin ortalaması)

Uyarıcı Sayısı	Ağırlık Güncelleme (sn)	Tepki Üretme (sn)
1	$0,3924 \times 10^{-5}$	$0,0604 \times 10^{-5}$
2	$0,3924 \times 10^{-5}$	$0,0604 \times 10^{-5}$
5	$0,3924 \times 10^{-5}$	$0,0604 \times 10^{-5}$
10	$0,4830 \times 10^{-5}$	$0,0604 \times 10^{-5}$
20	$0,4830 \times 10^{-5}$	$0,0604 \times 10^{-5}$
50	$0,6943 \times 10^{-5}$	$0,0604 \times 10^{-5}$
100	$0,9659 \times 10^{-5}$	$0,0604 \times 10^{-5}$
500	$0,3607 \times 10^{-4}$	$0,0302 \times 10^{-4}$
1000	$0,7154 \times 10^{-4}$	$0,0906 \times 10^{-4}$
10000	$0,7993 \times 10^{-3}$	$0,1465 \times 10^{-3}$

Tablo 4.9’da gösterilen zaman bilgisi aynı zamanda işlemsel yük yoğunluğunu da gösteren bir parametredir. Tepki sayısı artıkça aşağıda belirtilen zamansal süreçler artmaktadır. Ancak önerilen modelin kullanılacağı sisteme bağlı olarak (CPU hızı, RAM vb...) örnekleme frekans limitlerinin yeniden hesaplanması gerekmektedir.

4.2.6. Önerilen Algoritmanın Hafıza İhtiyacı

Önerilen modelde çok fazla değişken kullanmadığından hafıza ihtiyacı azdır. Hafızaya alınması gereken parametreler aşağıda listelenmiştir (uyarıcı sayısı 2 ve bağlı olay sayısı ise 3 ve tepki sayısı ise 1 olarak alınmıştır).

Tablo 4.10. İhtiyaç duyulan hafıza değişkenleri ve boyutu

Değişken Adı	Boyut (Vektörel)	Boyut (B)	Türü
Bağlantı katsayısı	[1 1]	8	Double
Sönme katsayısı	[1 1]	8	Double
Öğrenme katsayısı	[1 2]	16	Double
Maksimum öğrenme katsayısı	[1 1]	8	Double
Bitiştirilecek uyarıcı sayısı	[1 1]	8	Double
Organizma uyarıcısı	[1 9]	72	Double
Tepkisel uyarıcı	[1 1]	8	Double
Tepki	[1 1]	8	Double
Ortalama organizma uyarıcısı	[1 1]	8	Double
Dağıtılmış organizma uyarıcısı	[3 2]	48	Double
Dağıtılmış tepkisel uyarıcı	[3 2]	48	Double

Dağıtılmış tepki	[3 2]	48	Double
Ağırlıklar	[1 2]	16	Double
Değişken	[1 1]	8	Double
TOPLAM		312 B	

Tablo 4.10’da verilen hafıza ihtiyacı uyarıcı sayısı ve bağlı olay sayısına bağlı olarak Tablo 4.11’de özetlenmiştir.

Tablo 4.11. Uyarıcı ve bağlı olay sayısına bağlı hafıza ihtiyacı (B)

Bağlı Olay Sayısı	Uyarıcı Sayısı						
	1	2	5	10	20	50	100
1	176	216	336	536	936	2136	4136
2	200	264	456	776	1416	3336	6536
5	272	408	816	1496	2856	6936	13736
10	392	648	1416	2696	5256	12936	25736
20	632	1128	2616	5096	10056	24936	49736
50	1352	2568	6216	12296	24456	60936	121736
100	2552	24168	12216	24296	48456	120936	241736

Örneğin, 100 uyarıcı ve bağlı olay sayısının 100 olması durumunda önerilen modelin verilerinin eş zamanlı olarak işlenmesi ve saklanması için gerekli alan 241.736 B olacaktır. Tablo 4.12’de farklı sayıda tepki ve uyarıcı için hafıza ihtiyacı özetlenmiştir (bağlı olay sayısı 3 olarak alınmıştır).

Tablo 4.12. Uyarıcı ve tepki sayısına bağlı hafıza ihtiyacı (B)


Tepki	Uyarıcı Sayısı						
	1	2	5	10	20	50	100
1	224	312	576	1016	1896	4536	8936
2	264	376	712	1272	2392	5752	11352
5	384	568	1120	2040	3880	9400	18600
10	584	888	1800	3320	6360	15480	30680
20	984	1528	3160	5880	11320	27640	54840
50	2184	3448	7240	13560	26200	64120	127320
100	4184	6648	14040	26360	51000	124920	248120

Tablodan görüleceği üzere önerilen modelin hafıza ihtiyacı düşük seviyelerdedir. Bu sebeple önerilen model birçok mikrodenetçi veya

mikroişlemcide rahatlıkla kullanılabilme potansiyeline sahip olduğu düşünülmektedir.

4.2.7. Önerilen Modelin Yapay Sinir Ağları ile Karşılaştırılması

Önerilen modelinin davranışçı insan öğrenme kuramlarının tüm ilkelerini modelleyebildiği tespit edildi. Klasik koşullanma ve edimsel koşullanmanın modellenmesi için en sık kullanılan yapay öğrenme yöntemlerinden biri YSA'dır (Liu ve Ding, 2008 ve 2009; Clouse vd., 1997; Gaudiano ve Chang, 1997; Lew vd., 2001; Ruan vd. 2009; Ren ve Ruan 2009. Bu sebeple elde edilen modelin başarısını vurgulamak amacıyla popüler makine öğrenme yöntemlerinden YSA'nın insanın öğrenme süreci modelleyebilme başarısı test edilmiştir. YSA ürettiği kararlar açısından Şekil 4.47'de gösterilen noktalarda (A, B, C, D, E ve F noktaları) test edilmiştir.



Şekil 4.47. Öğrenme eğrisi

Şekil 4.47'de gösterilen noktalara (A, B, C, D, E ve F) kadar olan veriler ile eğitilen ağlar aşağıda gösterilen test verisi ile test edilmiştir. YSA ve önerilen model ile elde edilen sonuçlar Tablo 4.13'te verilmiştir.

Tablo 4.13. Test sonuçları

Test Noktaları	Test Verileri							
	[0, 0]		[0, 1]		[1, 0]		[1, 1]	
	YSA	Model	YSA	Model	YSA	Model	YSA	Model
A	0	0	0	0	0	1	0	1
B	0	0	0	1	1	1	1	1
C	0	0	0	1	1	1	1	1
D	0	0	0	1	1	1	1	1
E	0	0	0	1	1	1	1	1
F	0	0	0	1	1	1	1	1

Tablo 4.13'teki sonuçlar incelendiğinde mevcut YSA'nın öğrenme sürecini tam olarak modelleyemediği görülmüştür.

4.2.8. Önerilen Yöntemin Yapay Öğrenmeden Farkları

İnsanlar çevreye adaptasyondan karmaşık bilimlere kadar birçok açıdan hızlı öğrenme kabiliyetine sahiptir ve yaşamları boyunca birçok farklı konuda öğrenmekte ve karar üretmektedirler. Yapay öğrenme yöntemleri genellikle uzmanlara karar vermelerinde destek aracı olarak birçok farklı uygulamada kullanılmaktadır. Bu nedene öğrenme ve karar üretme performansları açısından pek fazla karşılaştırma çalışması yapılmamıştır. Bu çalışmalardan birinde Culverhouse vd. (2003) yaptıkları çalışmada eğitilmiş uzmanların görüntüde plankton türünü ayırt etmedeki başarısı makine öğrenme yöntemleriyle kıyaslanmıştır. Uzmanların başarısı %67-83 iken makine öğrenme yöntemlerinin başarısı %84-95 oranında olduğu belirtmişlerdir. Ayrıca, Heldman vd. (2014) Parkinson hastalığının tespiti için geliştirdikleri yaklaşımın uzmanlardan daha başarılı sonuç verdiğini gözlemlemişlerdir.

Belki de bu alanda spesifik çalışmalardan biri IBM'in geliştirmiş olduğu Deep Blue/Deeper Blue ile dünya şampiyonu Garry Kasparov 1996 ve 1997'deki iki şahtı maçıdır. Kasparov'un 4-2 yendiğı ilk mahtı sonra, yazılımı daha da geliştirilen IBM bilgisayar bu sefer Kasparov'u 3½-2½ yenilmiştir (http://en.wikipedia.org/wiki/Deep_Blue_versus_Garry_Kasparov). Elde edilen sonuç basitçe beş seçkin insanının (Stephen Hawking, fizikçi; Elon Musk, mucit ve girişimci; Nick Bostrom, felsefeci; James Barrat, yazar; Vernor Vinge, matematikçi) da belirttiğı gibi yapay zekânın insana kıyasen daha hızlı geliştiğine ve bunun da insan türünün sonu olabileceğidir (<http://time.com/3614349/artificial-intelligence-singularity-stephen-hawking-elon-musk/>). Ancak öte yandan, makine öğrenmesi yöntemlerinin karar verme süreci insan öğrenme yaklaşımlarına kıyasen daha yüksek doğrulukta ve daha az maliyet (karar destek amacıyla yapılan testler) ve zaman ihtiyacı duyması (Levi, 1989) nedenleriyle artık vazgeçilmez olmaya başlamıştır. Bu etkin özelliklerine rağmen yapay zeka yaklaşımlarının temel bazı kısıtlamaları vardır. Bunlar:

1. Spesifik alanlarda ve koşullarda uzmanlaşmışlardır. Bu alan veya koşulların dışında başarısı ciddi oranda düşmektedir.
2. Genel anlamda (bazı yöntemlerde ağırlıklandırma mevcuttur) tüm veriler eşit değerde kabul edilmektedir.

3. Makine öğrenmesi yöntemleri bilgiyi daha etkin şekilde işleyebilme potansiyeline sahiptirler. İç dinamiklerin optimal değerlerini bulmak için tüm verilerden faydalanma potansiyeline sahiptirler, yani unutmazlar. İnsan ise unutmaktadır.
4. Sürekli öğrenemezler, sadece eğitim sürecinde öğrendikleri değerlere göre karar üretmektedirler.

Önerilen yaklaşım ise diğer yapay öğrenme yöntemleriyle karşılaştırıldığında aşağıda listelenmiş üstünlükleri vardır.

1. İnsan gibi sürekli öğrenebilmektedir.
2. Olay serilerinin ilişkilendirilmesi hafızaya bağlıdır. Sönme katsayısına bağlı olarak zamanla unutulmaktadır.
3. Eğitim verilerinin işlenmesi tekrarlı değildir. Gerçek zamanlıdır; yani bir veri sadece karşılaşıldığında işlenmektedir. Önerilen modelde ağırlık güncelleme yaklaşımı klasik yöntemlerden daha farklıdır.
4. Uyarıcılar sıralı olarak incelendiğinden insan doğası gereği uyarıcıların anlık olarak değerlendirilmektedir.

4.1. Davranışsal Öğrenme Bazlı Yapay Öğrenme Yöntemi

Önerilen modelin davranışçı insan öğrenme kuramlarını gerçekleştirdiği gösterilmiş ve özellikleri detaylı olarak incelenmiştir. Bu bölümde ise modelin başarısı yapay öğrenme yöntemleriyle karşılaştırılmıştır. Bilindiği gibi birçok yapay öğrenme yöntemi bulunmaktadır. Yapılan çalışmada bu yöntemlerden en yaygın olan ileri beslemeli yapay sinir ağı karşılaştırmalarda kullanılmıştır. Ağı öğrenme algoritması olarak ise hızlı öğrenebilen ve yüksek genelleştirme kabiliyetine sahip AÖM kullanılmıştır (Huang vd., 2006; Kaya et al., 2014). Ayrıca birçok algoritmanın temelini teşkil eden kYK ise karşılaştırmalarda kullanılan ikinci yapay öğrenme algoritmasıdır (Al-Nabi ve Ahmed, 2013). Karşılaştırma iki ayrı kategoride yapılmıştır. Bunlar sınıflandırma ve regresyon problemleridir. Önerilen modelin başarısının test edilmesi için yapılan deneyler ve elde edilen sonuçlar bu bölümde anlatılmıştır.

4.1.1. Deney Prosedürü

Önerilen modelde organizma uyarıcısı (modelin odaklanmasını gösteren bir parametredir) en yüksek değeri olan “1” değerini almıştır. Üretilen tepkiye karşılık ortamdan geri alınan tepkisel uyarıcı ise:

- Sınıflandırma uygulamalarında:

$$TU = \begin{cases} +1, & T = \tilde{T} \\ -1, & T \neq \tilde{T} \end{cases} \quad (4.12)$$

- Regresyon uygulamalarında:

$$TU = \begin{cases} +1, & \tilde{T} - \varepsilon \leq T \leq \tilde{T} + \varepsilon \\ -1, & \tilde{T} - \varepsilon > T \text{ || } T > \tilde{T} + \varepsilon \end{cases} \quad (4.13)$$

değerlerini almaktadır. Burada $\tilde{T}$ beklenen tepkiyi göstermektedir. Önerilen davranışçı modelde örnek artırımı olarak öğrenmektedir. t_n . veri için öğrenme süreci aşağıdaki gibidir.

1. t_n . girdilerin bir önceki (t_{n-1}). ağırlıklar ile ağırlıklandırılarak çıktının hesaplanması,
2. Hesaplanan t_n . çıktı ile veri kümesindeki t_n . çıktının karşılaştırılarak başarı oranının bulunması,
3. Ağırlıkların güncellenmesi,

Önerilen yöntemi karşılaştırmak için yığın artırımı YSA yaklaşımı kullanılmıştır. Öğrenme süreci n. veri için aşağıda anlatıldığı gibi tüm verilere tek tek uygulanmıştır.

1. Eğitim kümesinin belirlenmesi: 1-(t_{n-1}). veriler eğitim kümesi olarak atanması, (eğitim kümesi: girdi ve bunlara ait çıktılarından oluşmaktadır)
2. Test kümesinin belirlenmesi: t_n . veri test kümesi olarak atanması,
3. Eğitim kümesi ile YSA'nın eğitilmesi,
4. Eğitilmiş YSA kullanılarak test verisinin çıktısının belirlenmesi,
5. Başarı oranlarının hesaplanması

Ayrıca tüm veri setleri yığın öğrenme yaklaşımı kullanan kYK ile de test edilmiştir. Yapılan testlerde güvenilir sonuçlar elde etmek açısından her modele aşağıda belirtilen öğrenme katsayıları atanmış ve tüm denemelerde bu katsayılar sabit bırakılmıştır. Diğer bir ifadeyle, parametre optimizasyonu gerçekleştirilmemiştir. Davranışçı öğrenmede kullanılan parametreler:

- Sönme katsayısı (β) = 0,590
- Öğrenme adım katsayısı (η)=0,008
- Birleştirme katsayısı (α)=0,25;
- Birleştirilecek/ilişkilendirilebilecek uyarıcı sayısı (N) =1

YSA'nın parametreleri:

- YSA yapısı: İleri beslemeli YSA

- Gizli katman sayısı=1
- Gizli katmandaki nöron sayısı=5
- Gizli katmandaki transfer fonksiyonu= “Hardlim”
- Eğitim yöntemi = Aşırı öğrenme makineleri (AÖM)

kYK'nin parametreleri:

- En yakın komşu sayısı=1
- Mesafe ölçme yaklaşımı=Öklid mesafe ölçüm yaklaşımı

$$d(X, Y) = \left(\sum_{s=1}^p (X_s - Y_s)^2 \right)^{\frac{1}{2}} \quad (4.14)$$


4.1.2. Sınıflandırma

Sınıflandırma amacıyla farklı karakteristiklere sahip gerçek veri setleri kullanılmıştır. Kullanılan veri setlerinin yapısı ve elde edilen sonuçlar (başarı ve zaman açısından) incelenmiştir. Sınıflandırma için başarı oranı aşağıdaki gibi hesaplanmıştır.

$$\text{Başarı}(\%) = 100 * \frac{\text{Doğru Sınıflandırılan Veri Sayısı}}{\text{Tüm Veri Sayısı}} \quad (4.15)$$

-Diyabet veri seti

Diyabet veri seti Smith vd. (1988) tarafından bir araya getirilmiş ve UCI'de paylaşılmaktadır (Bache ve Lichman, 2013). Veri seti 21 yaşın üzerinde 768 bayana ait geçmiş yaşantı bilgileri ve kan değerlerinden oluşan klinik verileri içermektedir. Yapılan çalışmada hastaların diyabet hastası olup olmadığının tespiti klinik verilere bağlı olarak yapılmaya çalışılmıştır. Bu amaçla önerilen öğrenme yapısı ve YSA karşılaştırılmıştır. Her veri için tek tek öğrenme ve test işleminin yapılması gerektiğinden öğrenme süreci aşırı hızlı olan AÖM kullanılmıştır. Öğrenme doğruluklarının uyarıcı sırasına göre Şekil 4.48'de gösterilmiştir.




Şekil 4.48. Diyabet veri setinin sınıflandırma doğruluğu

Önerilen davranışçı öğrenme modeliyle ortalama %65,2344 ve YSA ile %66,9271 doğruluk elde edilmiştir. Tüm verilerin beraber kullanıldığı kYK algoritması ile elde edilen sınıflandırma başarı oranı %76,95'tir. Ayrıca aynı veri seti ile Huang vd. (2006) YSA (AÖM ile eğitilmiş) ile %77,57, YSA (geri beslemeli öğrenme ile eğitilmiş) ile %74,73 ve DVM ile %77,31 doğruluk oranlarına ulaşmıştır.

-Karaciğer hastası veri seti

Karaciğer hastası veri seti UCI'de paylaşılmış bir başka veri setidir (Bache & Lichman, 2013). Ramana vd. (2011 ve 2012) tarafından düzenlenen veri seti her örnek için 10 özellik (yaş, cinsiyet ve kan değerleri) ve karaciğer hastası olup olmadıkları bilgisini içermektedir. Davranışçı öğrenme ve YSA ile elde edilen ortalama sınıflandırma başarıları Şekil 4.49'da gösterilmiştir.




Şekil 4.49. Karaciğer hastalığı veri setinin sınıflandırma doğruluğu

Davranışçı öğrenme kullanan modelin ortalama başarısı %71,3793, YSA'nın ise %71,2069 olarak bulunmuştur. Aynı veri setinde tüm veriler kullanıldığında (yığın veri işleme tekniği) kYK ile ulaşılan doğruluk oranı %71,87 olmuştur. Görüldüğü gibi bu veri seti için her üç yöntem aşağı yukarı aynı başarıyı göstermiştir.

-Epilepsi veri seti

Andrzejak vd. (2001) tarafından oluşturulan epileptik EEG veri seti 5 farklı veri kümesini içermektedir (A-E). D veri kümesi epileptik bölgeden okunmuş EEG sinyallerini, E veri kümesi ise epilepsi krizi sırasında kaydedilen EEG sinyallerini içermektedir. Yapılan örnek çalışmada EEG sinyallerinden zaman ve frekans düzleminde istatistiksel özellikler çıkarılmıştır (aritmetik ortalama, medyan ortalama, standart sapma, maksimum, minimum, çarpıklık, basıklık, enerji, aktif bant genişliği vb...). Davranışçı öğrenme ve YSA ile elde edilen ortalama başarı oranları Şekil 4.50'de karşılaştırılmıştır.




Şekil 4.50. D-E epilepsi verilerinin sınıflandırma doğruluğu

Önerilen davranışçı öğrenme algoritmasıyla elde edilen doğruluk oranı %63,50, YSA ile %57,5 olarak belirlenmiştir. Aynı veri seti kYK ile tüm verilerin beraber kullanıldığında %100 oranında bir doğruluk bulunmuştur.

-EMG veri seti

Eom vd. (2002) tarafından oluşturulmuş olan veri kümesi; 5 deneye ait saldırgan ve normal fiziksel hareketlere ait EMG kayıtları içermektedir ve UCI'de paylaşılmaktadır (Bache & Lichman, 2013). EMG sinyallerinden zaman ve frekans düzleminde istatistiksel özellikler çıkarılarak veri kümesi oluşturulmuştur.

Davranışçı öğrenme ve YSA ile EMG veri setinden elde edilen ortalama doğruluk oranları Şekil 4.51’de verilmiştir.



Şekil 4.51. EMG veri setinin sınıflandırma doğruluğu

Davranışçı öğrenme ile elde edilen ortalama doğruluk %55, YSA’da ise %50 olarak bulunmuştur. Aynı veri setine kYK uygulandığında ise %75 oranında doğruluk bulunmuştur.

4.1.3. Regresyon


Önerilen yöntemin başarısını ölçmek için iki adet farklı veri seti kullanılmıştır. Bu veri setlerinden biri yapay *Sinc* veri seti, diğeri ise Bermuda’da bulunan ölçüm istasyonunda kayıt altına alınan ortalama deniz suyu yüksekliği veri setleridir. Regresyon problemlerinde doğruluk (OKH) aşağıdaki gibi hesaplanmıştır.

$$OKH = E[(f - y)^2] \quad (4.16)$$

Denklem 4.16’da E beklenen değeri, f tahmin edilmiş veriyi ve y ise çıkış değerini göstermektedir.


-Gürültülü *Sinc* veri seti

Yapılan çalışmada gürültü eklenmiş *Sinc* verisi kullanılmıştır. Bu veri seti Huang vd. (2006) tarafından paylaştırılmıştır. Bu veri seti Şekil 4.52’de gösterilmiştir.



Şekil 4.52. Gürültülü *Sinc* veri seti


Davranışçı öğrenme ve YSA ile *Sinc* veri setinden elde edilen OKH değerleri Şekil 4.53'te verilmiştir.



Şekil 4.53. *Sinc* veri setinin regresyon doğruluğu


-Bermuda su seviyesi veri seti

ABD ticaret bölümüne bağlı NOAA'nın Atlantik Okyanusunda bulunan Bermuda'da 2695540 nolu gözlem istasyonunda kayıtlarını tuttuğu aylık ortalama su seviyesi önerilen yaklaşımla tahmin edilmeye çalışılmıştır (http://tidesandcurrents.noaa.gov/sltrends/sltrends_station.shtml?stnid=2695540). Bermuda veri setinde Şekil 4.54'te gözlem değerleri gösterilmiştir (NOAA).



Şekil 4.54. Deniz seviyesi yüksekliği (NOAA)

Sisteme giriş olarak ay bilgisi (1-12) verilmiş ve çıkış olarak ise aylık ortalama su seviyesi çıktısı tahmin edilmeye çalışılmıştır. Elde edilen hata değerleri Şekil 4.55’te gösterilmiştir.



Şekil 4.55. Bermuda veri setinin regresyon doğruluğu

Önerilen davranışçı öğrenme yöntemi ile oluşan OKH 0,1342 iken YSA’da ise 0,2020 bulunmuştur. Davranışçı öğrenmede ilk süreçte hata sıfıra yakın seyrederken daha sonra yükselmiştir. Bunun nedeni veri setinde zamansal açıdan eksik veri olduğu düşünülmektedir.

4.1.4. Yapay Öğrenme Sonuçların Değerlendirilmesi

Önerilen model örnek-artırımlı yaklaşım ile veri setini işlemektedir. Yani yeni bir örnek ile karşılaştığında onu işler ve öğrenme katsayılarını buna göre gözden geçirmektedir. Bu kısımda kullanılan YSA ise yığın-örnekleme yaklaşımını kullanmaktadır. Yeni bir örnek geldiğinde o ana kadar gelen tüm örnekleri beraber değerlendirerek yeni ağırlıklar bulmaktadır. Yığın öğrenmede ise örnekler tek tek işlenmektedir, tüm veriler bir bütün halinde işlenmiştir. Yapılan çalışmada

önerilen GDÖ, YSA ile elde edilen sonuçlar ve aynı veri setlerine kYK uygulandığında elde edilen sonuçlar Tablo 4.14'te gösterilmiştir.

Tablo 4.14. Yapılan çalışmaların doğruluk sonuçları

Veri Kümesi:		Diyabet (%)	Karaciğer (%)	Epilepsi (%)	EMG (%)	Sinc (OKH)	Bermuda (OKH)	
Artımlı Öğrenme	Örnek	GDÖ	65,2344	71,3793	63,50	55,00	0,2381	0,0199
	Yığın	YSA	66,9271	71,2069	57,50	50,00	0,2187	0,2020
Yığın		kYK	76,95	71,87	100	75	0,0115	0,1070

Tablo 4.14'te görüldüğü gibi artımlı öğrenmede davranışçı öğrenme modeli YSA ile doğruluk açısından benzer sonuçlar üretmiştir. Ancak yığın öğrenme yaklaşımı olarak kullanılan kYK'den daha düşük sonuçlar üretmiştir. Bu durumun nedenleri aşağıda açıklanmıştır.

- Yığın öğrenmede öğrenme parametrelerinin optimizasyonu daha rahattır. Optimize edilen parametrelerle öğrenme yaklaşımı veri setine adapte olmakta ve daha başarılı sonuçlar vermektedir. Çünkü artırımlı öğrenme yöntemlerinde elde edilen başarı veri sıralamasıyla doğrudan ilişkili olduğundan optimal parametreler veri sıralamasıyla bağlıdır.
- kYK'nin veri kümesine adapte olması için çok fazla parametreye ihtiyaç duyulmamaktadır.
- Önerilen yaklaşım unutma özelliği nedeniyle daha ziyade dinamik verileri sınıflandırmada başarı göstermesi beklenmektedir. Bu dinamik alanlara örnek olarak müşteri talepleri, robotik çalışmalar ile haberlerin, e-postaların, sosyal ağ paylaşımlarının sınıflandırılması ve filtrelenmesi gösterilebilir (Read vd., 2012).
- Önerilen öğrenme modeli doğal bir yaklaşımı olup, kullandığı öğrenme altyapısı davranışçı öğrenme kuramlarına dayanmaktadır. Ayrıca örnek-artırımlı veri analizi de doğal veri işleme yaklaşımıdır.
- Örnek-artırımlı yaklaşım daha az hafıza ve işlemsel kapasite bulunan yaklaşımlarda kullanılabilir (Read vd., 2012).

- Önerilen model veri sıralamasıyla ilişkilidir. Veri sıralamasının değişmesi başarıyı değiştirmektedir. Veri sıralaması rastgele değiştiğinde elde edilen başarı oranları Tablo 4.15’te verilmiştir.

Tablo 4.15. Yapılan çalışmaların doğruluk sonuçları (rastgele sıralamalı)

Veri Seti	Deneme					Sıralı
	1	2	3	4	Ortalama	
Diyabet	65,230	64,580	65,230	65,230	65,070	65,230
Karaciğer	71,380	71,380	71,380	71,380	71,380	71,380
Epilepsi	60,750	65,000	61,750	67,750	63,810	63,500
EMG	50,000	51,250	60,000	56,250	54,380	55,000
<i>Sinc</i>	0,256	0,245	0,299	0,309	0,277	0,238
Bermuda	0,076	0,046	0,059	0,071	0,063	0,020

- Önerilen modelin karar verme sürecinde kullanmış olduğu zaman süreçleri Tablo 4.16’da verilmiştir.

Tablo 4.16. Yapılan çalışmaların zamansal sonuçları (sn)

	Veri Seti					
	Diyabet	Karaciğer	Epilepsi	EMG	<i>Sinc</i>	Bermuda
Veri Boyutu	768x8	580x10	400x43	80x17	5000x1	765x1
GDÖ	3,2852	3,0451	8,4373	0,6765	0,6959	0,0937
YSA	1,4370	0,8757	0,4671	0,0517	6,4584	0,6659

Tablo 4.16’da görüldüğü gibi, veri setinde bulunan özellik sayısı arttıkça önerilen yöntemin öğrenme ve karar verme süreci de uzamaktadır. Öte yandan davranışçı öğrenme modeli; öğrenme fazında AÖM’ye kıyasen regresyon problemlerinde çok daha hızlı öğrenebilmektedir. Huang vd., (2006) yaptığı çalışmada AÖM ile öğrenmenin geri beslemeli öğrenmeye kıyasen yaklaşık 255 kat (3,0116/0,0118 sn) daha hızlı öğrenebildiğini göstermiştir. Ayrıca, Huang vd. (2006) yaptığı çalışmasında tek bir YSA (AÖM ile eğitilen) eğitimi için geçen süreyi diyabet veri setinde 0,0118 sn ve *Sinc* veri setinde ise 0,125 sn hesaplamıştır. Aynı çalışmada geri beslemeli yayılım ile eğitilen YSA için eğitim süreci 3,016 sn olarak hesaplanmıştır. Bu veri seti için öğrenme süreci neredeyse önerilen modelle aynı seviyelerde olduğu görülmektedir.

4.2. Örnek Uygulama: Ortalama Deniz Su Seviyesinin Tahmini

ODSS son yüz yılda, 5.000 yıldır gözlemlenmeyen oranlarda artmaktadır ve bu yükselmenin başlıca nedeni global ısı artışından kaynaklı eriyen buzlardır


(Church ve White, 2006). Küresel ısınma haricinde jeofiziksel birçok dinamik neden ODSS seviyesi etkilenmektedir. Bunların bir kısmı: deniz altı akıntılar, erozyon ve nehir suları olarak sayılabilir (Sun vd., 2012).

ODSS'nin hesaplanması yaklaşık 1900 yıllardan beri özellikle denizcilikteki önemi nedeniyle farklı yöntemlerle ölçülmekteydi (Parker, 1992). Ancak, günümüzde insan kaynaklı küresel ısınmadan dolayı ODSS yükselmesi kıyı şeritlerinin ile düşük yükseklikteki alanların ve ekosistemin korunması açısından daha da önem arz etmektedir (El-Shazly, 2005; Fankhauser, 1995; Pashova ve Popova, 2011). Dünyanın şeklinden ve basınç, su yoğunluk farkları gibi dinamik nedenlerle ODSS dünyanın tümünde değişiklik göstermektedir (El-Shazly, 2005). Bu sebeple dünyada birçok istasyonda ODSS düzenli olarak ölçülmekte ve NOAA, PSMSL ve Hawaii Üniversitesi Su Seviye Merkezi gibi kuruluşlarca geleceğe dönük politikalar geliştirmek amacıyla bu bilgileri ilgili kuruluşlarla paylaşılmaktadırlar (Fankhauser, 1995).

Parker (1992) yaptığı çalışmasında ODSS değerinin tahmin edilmesinin zorluklarına işaret etmiştir. Bu tür zor tahminler için genelde istatistiksel ve harmonik bazlı yöntemler kullanılmaktadır (Ghorbani vd., 2010; Hunter, 2009). Bunların yanı sıra Pashova and Popova (2011) ve Sztobryn (2013) ODSS değerini tahmin etmek için YSA'yı kullanmış ve önermişlerdir. YSA ODSS tahmin sürecinde zaman boyutunda alınan tüm verilere eşit derecede etki değeri addetmesi ve hiçbir veriyi unutmaması nedeniyle yapılan tahminin doğruluk derecesini negatif yönde etkileyebileceği düşünülmektedir. Zaman serisi olarak alınan verilerin eşit derecede etki etmesi bu sürecin sabit ivmeye sahip olduğu anlamına gelir ki elde olan veriler (literatürde) böyle olmadığını göstermektedir. Tahmin edilmeye çalışılan olayın zamansal olarak yakın olan örneklerin anlam derecesi uzak olan örneklerden daha etkili olduğu varsayımı ile bu tez kapsamında önerilen yöntemin ODSS tahmin başarısı test edilmiştir ve YSA'dan daha başarılı sonuçlar ürettiği gözlemlenmiştir.

4.2.1. Veri Seti

Daha önce yapılan ODSS tahmin çalışmaları genelde yerel bölgeler için ODSS değerini tahmin etmeye çalışmaktaydılar (El-Shazly, 2005; Pashova ve Popova, 2011; Karimi vd., 2013; Makarynsky vd., 2004). Çalışmada ise kullanılan verilen PSMSL adlı kurumunun web sayfasından indirilmiştir (<http://www.psmsl.org>). PSMSL'de kayıtlı ODSS ölçüm istasyonları Şekil 4.56'da gösterilmiştir.



Şekil 4.56. PSMSL’de kayıtlı ölçüm istasyonları (<http://www.psmsl.org>)

Bu istasyonlardan farklı coğrafik konumlara sahip ve Şekil 4.56’da halka içine alınarak gösterilen 7 adet istasyonun özellikleri Tablo 4.17’de verilmiştir.

Tablo 4.17. Seçilen istasyonlar ve özellikleri


No	Konum	Veri Kayıt Aralığı	Tamlık Oranı	Ülke
638	64.150583 °N 21.939889 °W	1951–2013	%91,1	İzlanda
913	65.246233 °S 64.257417 °W	1958–2013	%97,8	Antarktika
2171	39.378472 °N 31.168639 °W	2006–2013	%100	Portekiz
1111	41.285000 °N 70.096667 °W	1965–2013	%97,4	ABD
1391	27.083333 °N 142.183333 °E	1975–2013	%99,1	Japonya
1673	20.150000 °S 57.500000 °E	1986–2013	%96,4	Moritus Adası
2093	38.121411 °N 13.371331 °E	2001-2013	%100	İtalya

4.2.2. Deney Prosedürü

ODSS’nin tahmini için bazı çalışmalarda meteorolojik veriler girdi olarak kullanılmıştır (Karimi vd., 2013; El-Shazly, 2005). Ancak aylık ODSS değeri meteoroloji (kısa dönemli etki) ile ilintili olduğu halde daha ziyade ay ve güneşin etkisi, su altı akıntıları ve küresel ısınma ile daha fazla ilintilidir (uzun dönemli etki) (Sun vd., 2012; Ghorbani vd., 2010). Bu sebeple Pashova ve Popova (2011)


yaptıkları gibi geçmiş veriler kullanılarak yeni veriler tahmin edilmiştir. Önerilen yöntemin başarısını tespit etmek için üç farklı deney yapılmıştır.

1. Deney: Şekil 4.57’de gösterildiği gibi sorgu verisinden önceki verileri kullanılarak sorgu değerinin tahmin edilmesidir.



Şekil 4.57. 1. Deneyin prosedürü

2. Deney: Şekil 4.58’de gösterildiği üzere, 1. deneyden farklı olarak tek bir veri sorgulaması yerine bir grup sorgu verisi değerinin tahmin edilmesidir.



Şekil 4.58. 2. Deneyin prosedürü

3. Deney: Tüm veriler kullanılarak geleceğe dönük tahminde bulunulmasıdır.

Üç deney prosedürü eş zamanlı olarak AÖM ile eğitilmiş YSA ve GDÖ uygulanmıştır. Doğruluk aracı olarak ise OKHK ve OMYH kullanılmıştır.


$$OMYH = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{f_i - y_i}{y_i} \right| \quad (4.17)$$

$$RMSE = \sqrt{E[(f - y)^2]} \quad (4.18)$$

Burada E beklenen değer, f tahmin edilmiş ve y ise gerçek değeri göstermektedir. Bu uygulamada bölüm 8’de regresyon amacıyla kullanılan tepkisel uyarıcı (Denklem 4.19) yaklaşımından farklı olarak aşağıdaki gibi tanımlandı.

$$TU = \begin{cases} R_{p_1}, & T > \tilde{T} + \varepsilon \\ R_r, & \tilde{T} + \varepsilon > T > \tilde{T} - \varepsilon \\ R_{p_2}, & T < \tilde{T} - \varepsilon \end{cases} \quad (4.19)$$

Bir önceki veri için üretilen tepki ve beklenen tepki arasındaki ilişkiye bağlı olarak tepkisel uyarıcı değeri R_{p_1} , R_r veya R_{p_2} değerlerinden biri atanmaktadır. Bu durum Şekil 4.59’da gösterilmiştir.



Şekil 4.59. Veri tüpü

Şekil 4.59’da ε verinin gerçek veriye olan kabul edilebilir uzaklığıdır aynı zamanda DVM’de olduğu gibi veri tüpü kalınlığı olarak ta yorumlanabilir (Drucker vd., 1997). Tepkisel uyarıcı ise takviyeli öğrenmede bulunan takviye terimi olarak ifade edilebilir. Bu terim insan öğrenmesinde olduğu gibi cezalandırma/ödüllendirme amacıyla kullanılmaktadır (Bjork, 2013). ε ise ceza/ödül sınırını göstermektedir. Periyod tahminlerinde tepkisel uyarıcıların ortalaması alınarak bu ortalama tepkisel uyarıcı değeri tepkisel uyarıcı yerine alınmıştır. Burada birleştirilecek/ilişkilendirilebilecek uyarıcı sayısı ve birleştirme katsayısı ODSS üzerinde kısa dönemde etkili dinamiklerle, sönme ve öğrenme adım katsayıları ise ODSS üzerinde uzun dönemde etkili dinamiklerle ilişkilendirmek mümkündür.

4.2.3. Sonuçlar ve Değerlendirme

Yapılan uygulamada GDÖ ve YSA için kullanılan parametreler Tablo 4.18 ve 4.19’da verilmiştir.

Tablo 4.18. Kullanılan önerilen davranışçı öğrenme modelinin katsayıları

Sönme (β)	Öğrenme Adım (η)	Tepkisel Uyarıcı			Birleştirme	
		Ceza	Ödül	Tüp	Olay Sayısı	Değeri
		(R_{p_1})	(R_{p_2})	(R_r)	(ε)	(N)
0,99	0,01	-1	2	1	0,012	3

Tablo 4.19. YSA’nın öğrenme parametreleri

Katmanlardaki Nöron Sayısı			Transfer	Öğrenme Türü
Giriş	Gizli	Çıkış Katmanı	Fonksiyonu	
1	5	1	Triangular basis	Regresyon


-1. Deneyin sonuçları

Seçilmiş olan 7 istasyonda önceki veriler kullanılarak bir sonraki ayın ODSS değerinin tahmin edilmesi sonucu oluşan hata değerleri Tablo 4.20’de özetlenmiştir.


Tablo 4.20. Hata değerleri

İstasyon ID	Davranışçı Öğrenme		Yapay Sinir Ağları	
	OMYH	OKHK	OMYH	OKHK
638	1,07984	0,010375	1,142132	0,011033
913	0,92173	0,008919	0,815145	0,007916
1111	0,731767	0,007114	0,825223	0,008068
1391	4,49103	0,038647	4,718434	0,041048
1673	0,900068	0,008732	1,019203	0,009915
2093	0,806542	0,007864	0,699803	0,006847
2171	0,889141	0,008679	0,829211	0,008116
Ortalama	1,40287	0,01290	1,43559	0,01328

Elde edilen ortalama OMYH ve OKHK değerleri önerilen davranışçı öğrenme yönteminin YSAya kıyasen biraz daha düşük hata değerlerine sahip olduğunu göstermektedir. Hata değerlerine biraz daha detaylandırmak için 638. istasyonun her bir veri için elde edilen hata değerleri (OMYH ve OKHK) Şekil 4.60’ta gösterilmiştir.




Şekil 4.60(a). Hata oranları: OKHK




Şekil 4.60(b). Hata oranları: OMYH

Şekil 4.60 incelendiğinde veri miktarının artmasının doğruluğu artırmadığı gözlemlenmiştir. Bunun nedeninin ODSS değerinin trend içermesidir. Ayrıca OKHK ve OMYH denklemleri incelendiğinde iki hata operatörü de yönsüzdür. Aynı istasyona ait regresyon eğrileri ise Şekil 4.61’de verilmiştir.




Şekil 4.61(a). Regresyon eğrisi: GDÖ



Şekil 4.61(b). Regresyon eğrisi: YSA

Bu regresyon eğrileri incelendiğinde davranışçı öğrenme yönteminin YSA'dan daha başarılı olduğu görülmektedir. Tahmin edilen ODSS'leri ve gerçek ODSS ise Şekil 4.62'de gösterilmiştir. Bu şekildeki gerçek-tahmin edilen ODSS'leri incelendiğinde davranışçı öğrenme yönteminin uzun dönem trendi ve kısa dönem dalgalanmaları rahatlıkla tespit ettiği görülmektedir. YSA ise sadece uzun dönem trendi tespit etmede başarılı sonuçlar üretmiştir.



Şekil 4.62. ODSS değerleri (638. istasyon)


-2. Deneyin sonuçları

Bu deneyde bir periyodun tahmin edilebilme becerisi test edilmiştir. Bu amaçla 638. ve 2093. istasyonun belirtilen periyotlardaki değerlerinin tahmin edilmesi sonucu oluşan hata oranları Tablo 4.21'de gösterilmiştir.

Tablo 4.21. Belirli aralıktaki ODSS tahmini

İstasyon No	Tahmin Periyodu (Yıl)	Davranışçı Öğrenme		YSA	
		OMYH	OKHK	OMYH	OKHK
638	0,5	0,635022	0,006167	1,028068	0,010055
	1	1,043158	0,010057	0,924319	0,008992
	2	1,655218	0,01613	1,055725	0,010321
	3	1,967272	0,019131	1,029699	0,010037
	5	0,906597	0,00874	1,049375	0,010231
	10	0,975984	0,009425	1,070948	0,01044
	15	2,735923	0,026433	1,079864	0,010534
	20	1,588424	0,015469	1,111559	0,010852
	30	1,089913	0,010497	1,108198	0,010798
	45	0,939056	0,009057	1,12086	0,010923
	Ortalama	1,353657	0,013111	1,057861	0,010318
2093	0,5	1,372453	0,013491	0,765671	0,007544
	1	0,850246	0,008285	0,856616	0,008366
	2	3,01277	0,029386	0,690684	0,006742
	3	1,610998	0,015718	0,90761	0,008929
	5	2,058914	0,02011	0,906592	0,008927
	10	0,905729	0,008839	0,857677	0,008434
	Ortalama	1,635185	0,015971	0,830808	0,008157

Tablo 4.21’deki hata oranlarına bakıldığında YSA’nın daha başarılı olduğu görülmektedir. 5 yıllık bir dönem için tahmin edilen ODSS ve gerçek ODSS değerleri Şekil 4.63’te gösterilmiştir.



Şekil 4.63. 5 Yıllık ODSS değerinin tahmin edilmesi

- El-Shazly (2005) yaptığı çalışmasında İskenderiye'deki ODSS değerini genelleştirilmiş regresyon YSA yöntemi ile kestirdiği çalışmasında elde ettiği en düşük OKH değeri 11,9'dur.
- Pashove ve Popova (2011) ise geri beslemeli dağılım ile öğrenen YSA kullandığı çalışmasında elde ettiği en düşük OKHK değeri 5,69 cm/gündür.
- Makarynskyy vd. (2004) ise YSA kullanarak elde ettiği OKHK değeri gerçek değerlerin %10 seviyelerindedir.

-3. Deneyin sonuçları

107

Yapılan uygulamada 638 nolu istasyona ait 10 yıllık verilerden elde edilen eğilim değeri 2,632 mm/yıl seviyesinde olduğunu önerilen yöntem ile tespit etmiştir. NOAA ise aynı istasyon için eğilim olarak $2,33 \pm 0,5$ mm/yıl bulmuştur (http://tidesandcurrents.noaa.gov/sltrends/sltrends_global_station.htm?stnid=010-001). Bu değerlerin birbirine yakın olması önerilen yöntemin başarılı olduğunun bir diğer göstergesidir.

4.3. Özetçe

Yapmış olduğumuz çalışmada önerilen model ile klasik koşullanma dahil tüm diğer davranışçı yaklaşımların modellenemediği görülmüştür. Bu sonuç şu ana kadar klasik koşullanmanın tam özellikleriyle modellenememesinin nedeninin klasik koşullanma kuramındaki eksiklikler olduğunu göstermiştir. Bu bölümde elde edilen sonuçlar incelendiğinde, önerilen GDÖ yönteminin tüm davranışçı yaklaşım ilkelerini modelleyebildiği görülmüştür. Bu bölümde önerilen modelin özellikleri birçok açıdan analiz edilmiştir. Model sistemsel açıdan kararlı, nedensel, hafızalı, doğrusal ve zamana bağlı bir yaklaşımdır. Öğrenme yaklaşımı olarak ise takviyeli ve örnek-artırımlı bir yaklaşımdır. Sürekli öğrenen modelin işlemsel yük ve hafıza ihtiyaçları göz önüne alındığında güçlü donanımsal altyapıya ihtiyaç duymadan çalışabileceği görülmüştür. Ancak karar verilecek tepki tür sayısı ve uyarıcı sayısının artmasına bağlı olarak donanımsal ihtiyaçlar da artmaktadır. Ayrıca, önerilen model YSA ile karşılaştırılmış ve genel yapay öğrenme yöntemlerinden farklı tarafları gösterilmiştir.

Daha sonra önerilen davranışçı yapay öğrenme yöntemi birçok veri setine sınıflandırma ve regresyon amacıyla uygulanmıştır. Elde edilen sonuçlar zaman ve doğruluk açısından AÖM ve kYK ile karşılaştırılmıştır. YSA önerilen model ile benzer koşullar altında örnek bazlı olarak kullanılmıştır. kYK ise verilere yığın halinde uygulanmıştır. GDÖ, YSA ve kYK için sabit parametreler atanmış ve tüm testlerde bu parametreler veri setine göre optimize edilmeden kullanılmıştır. Elde edilen sonuçlar baz alınarak önerilen modelin başarısı ile kendisini kanıtlamış olan YSA'nın başarısı ile karşılaştırıldığında, bu modelin yeteri kadar başarılı olduğu görülmüştür. Modelin özellikle unutma-öğrenme kabiliyeti nedeniyle zaman sıralı veri setlerinde daha başarılı olduğu da görülmüştür. Zaman sıralı veri setlerinde başarısını test etmek için ODSS veri seti önerilen davranışçı öğrenmeye dayalı yapay öğrenme yöntemi AÖM ile eğitilen YSA ile karşılaştırılmıştır. Elde edilen sonuçlar OMYH, OKHK ve yöntemlerin eğilim ve dalgalanmaları takip edebilme kabiliyetleri açısından değerlendirilmiştir. Uygulama sonucunda gelecek ay (7 istasyonun ortalaması) ve 638. ve 2093. gözlem istasyonlarının dönemsel ODSS

değerinin kestiriminde, elde edilen hata oranları sırasıyla %1,40 (%0,73-4,49), %1,35 (0,85-2,74) ve %1,64 (%0,85-3,01). Bu değerler birçok ölçüm cihazının hata oranından daha düşük olması sebebiyle kabul edilebilir bir seviyedir. Ayrıca, önerilen yöntem ile 638. istasyonun geleceğe dönük eğimi tespit edilen eğim 2,632 mm/yıl, NOAA'nın tahminine ($2,33 \pm 0,5$ mm/yıl) yakındır. Bu da yöntemin başarılı olduğunun bir diğer göstergesidir.

5. SONUÇ VE ÖNERİLER

5.1. Bu Tez Çalışmasında Elde Edilen Sonuçlar

Davranışçı yaklaşım insanı öğrendiklerinin şekillendirdiği temeline dayanmaktadır, bu sebeple pek çok psikolojik rahatsızlığın tesadüfi yanlış öğrenmeden kaynaklandığını iddia eden bilim insanları da literatürde yer almıştır (Watson, 1914). Özellikle klasik koşullanma insan davranışlarının manüple edilme aracı olarak görülmüştür (Allen ve Madden, 1985). Aynı zamanda temel insani dürtülerin (fobi, refleks, tik, vb...) de açıklandığı davranışçı öğrenme yaklaşımları, daha sonra yapılan çalışmalar ile yeni bir boyuta ulaşmış ve içsel süreçleri de kabul edebilir hale gelmiştir (Skinner, 1950). Davranışçı öğrenme yaklaşımları korku odaklı psikolojik rahatsızlıkların ve istenmeyen davranışların giderilmesi konularında uzun bir süredir psikoterapi alanında kullanılmaktadır (Sungur ve Yalnız, 1999; Türkçapar ve Sargın, 2012). Bu tez çalışmasında Pavlov, Watson, Guthrie, Thorndike ve Skinner'in davranışçı insan öğrenme teorileri temel alınarak yeni bir yapay öğrenme yöntemi önerilmiştir. Bu tezde yapılan çalışmaların sonuçları aşağıdaki gibi özetlenebilir.

1. Pavlov, Watson, Guthrie, Thorndike ve Skinner'in davranışçı insan öğrenme teorileri ve teorilerle ilgili önerilen insan davranışlarına benzer tepki üretebilen matematiksel modeller derlenerek özetlenmiştir.
2. Bu çalışmada ise klasik koşullanma dâhil şimdiye kadar öngörülen tüm davranışçı öğrenme kuramları aynı matematiksel model ile gerçekleştirilmiştir. Bu da klasik koşullanmanın şu ana kadar modellenememesinin nedeni teorik eksikliklerinin de olabileceğini göstermektedir.
3. Bölüm 4.4'te elde edilen sonuçlardan önerilen yöntemin sınıflandırma ve regresyon gibi problemlerde başarıyla kullanılabilme potansiyeline sahip olduğu anlaşılmıştır. Yöntemin başarısı insan karar verme sürecini iyi bir şekilde taklit edebilmesi, karar süreci küçük adımlarla ilerlemesi, sürekli olarak öğrenebilmesi ve unutma kabiliyetinin olması gibi özelliklerine bağlanabilir.
4. Ayrıca, elde edilen sonuçlar önerilen davranışçı yapay öğrenme yöntemi özellikle zamansal sıralı verinin analizinde yüksek başarıyla kullanılabilme potansiyeline sahip olduğunu göstermiştir.
5. Önerilen davranışçı öğrenme yöntemi kararlı bir yapıda olup, öğrenme ve karar verme sürecinde düşük hafıza ihtiyacı ve az işlemsel yük oluşturmaları

nedeniyle gerçek zamanlı olarak çalışabilme kabiliyetinde olduğu simülasyonlar ve mikrodenetleyici ile yapılan deneylerde görülmüştür.

6. Önerilen davranışçı öğrenme yönteminin, literatürde bulunan diğer yöntemler gibi başarısı seçilen parametrelerle (sönme, öğrenme adım ve birleştirme katsayıları ile birleştirilecek/ilişkilendirilebilecek uyarıcı sayısı) ilişkili olduğu görülmüştür. Bu parametrelerin atanması deneme yanılma ile olabileceği gibi ayrıca modellenen ya da öğrenilen sistemin iyi analizi ile yapılabilmektedir.

5.2. Gelecekte Yapılabilecek Çalışmalarla İlgili Öneriler

Bu tezin çıktısı sadece yapay öğrenme alanında olmayıp, elde edilen genelleştirilmiş davranışçı öğrenme yaklaşımı aşağıdaki alanlarda da kullanılabilir.

1. Davranışçı öğrenme kuramlarından psikolojik terapide faydalanılabilmektedir (Sungur ve Yalnız, 1999; Türkçapar ve Sargın, 2012), ayrıca klasik koşullanma ile refleksi davranışlar ile fobi süreçlerinin anlaşılmasında ve yönetilmesinde kullanılmaktadır (Li vd., 2007; Yoshida vd., 2004). Tezin konusu olan öğrenme süreci en temel seviyede uyarıcı-tepki bağının gücüyle ilişkilidir. Ancak önerilen kuram ve modelde uyarıcı hareket/davranış/beceri/bilgi olarak ta yorumlanabilir. Önerilen modelin birçok davranışın nedeni daha da anlamlandırılabilmesi için kullanılabilir. Modelde davranışlar içsel süreçler, uyarıcılar ve tepkisel uyarıcılarla kontrol edilmektedir. Bir canlıda genetik faktörlerin yanında çevre, aile ve toplum bir davranışın gerçekleşme nedeni olduğu düşünülmektedir. Bu açıdan bir davranışın (alışkanlık) veya duygunun (sevinç, korku) oluşturulmasını veya sönümlenmesini modelde kabaca parametrelerle ifade etmek mümkündür. Modelin parametreleri değiştirilerek (unutma, öğrenme ve birleştirme katsayıları) spesifik canlı türü veya daha özelde sadece kişiye indirmek de mümkündür. Bu sebeple önerilen davranışçı öğrenme modeli bu alanda değerlendirilebilme potansiyeline sahiptir.
2. Önerilen model insan gibi öğrenme ve davranış üretme kabiliyetine sahip olduğundan oyun geliştiricileri tarafından kullanılabilir. Laslier vd. (2001) belirttikleri gibi davranışçı öğrenme diğer öğrenme yöntemlerinden farklı olarak geçmişte yaşanan olaylardan faydalanılarak, mevcut durumda yapılacak en iyi hareketi yapmaya ve en kötü hareketten uzak tutmaya çalışan tavrı sergilemektir. Bu nedenle bilgisayara karşı oynanan oyunlarda oyuncunun (bilgisayar rakibinin) hareketlerine davranışçı yaklaşım ile algoritmanın karar vermesi mümkündür. Diğer bir ifadeyle, modelin

parametreleri oyuncunun kabiliyeti ve belirlediği zorluk seviyesine göre adaptif veya sabit olarak seçilerek oyuncuya göre karşıt hamleler geliştirmek mümkündür.

3. Önerilen genelleştirilmiş kuram Pavlov, Watson, Guthrie, Thorndike ve Skinner'ın kuramlarını kapsayacak şekilde olduğu için bu kuramların ortaya çıkardığı ya da desteklediği tüm alanlarda daha kapsayıcı değerlendirme yapılabileceği düşünülmektedir. Bu tip alanlara örnek olarak aşağıdaki çalışmalar sayılabilir.
 - ✓ Satın alma süreçleri,
 - ✓ İnsana ait öğrenme sürecinin fizyolojik yapısı
 - ✓ İnsansı robot kontrolü
4. Önerilen yöntem aynı zamanda akıllı kontrol sistemi olarak ta kullanılabilir. Bu amaçla klasik tek kontrollörlü yaklaşım yerine organizma uyarıcısı ile sistem durumu/konforu ve tepkisel uyarıcı ile sistem çıkışı kontrol edilebilir. Bu sayede kullanıcı alışkanlıklarını tanıyan bir kontrol sistemi olarak kullanılabileceği düşünülmektedir.

KAYNAKLAR

- Abdul M., Salman W. (2008). Adaptive Learning Rate Versus Resilient Backpropagation For Numeral Recognition. *J. of Al-Anbar University for pure science*. 2(1), 1-12.
- Allen C.T., Madden T.J. (1985). A Closer Look at Classical Conditioning. *The Journal of Consumer Research*. 12(3), 301-315.
- Al-Nabi D.L.A., Ahmed S.S. (2013). Survey on Classification Algorithms for Data Mining:(Comparison and Evaluation). *Computer Engineering and Intelligent Systems*, 4(8), 18-24.
- Alpaydın E. (2004). *Introduction to Machine Learning*. The MIT Press, Cambridge, Massachusetts.
- Alvarez O., Gonzalez C., Latorre R. (2012). Counting Channels: A Tutorial Guide on Ion Channel Fluctuation Analysis. *Advan in Physiol Edu*. 26, 327-341.
- Andrzejak R.G., Lehnertz K., Mormann F., Rieke C., David P., Elger C.E. (2001). Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E*. 64(6), 061907-1-8.
- Antonietti A., Casellato C., Garrido J.A., D'Angelo E., Pedrocchi A. (2015). Spiking cerebellar model with multiple plasticity sites reproduces eye blinking classical conditioning. *IEEE 7th International Neural Engineering Conference*, pp. 296-299.
- Austermann A., Yamada S. (2008). Learning to Understand Multimodal Rewards for Human-Robot-Interaction using Hidden Markov Models and Classical Conditioning. *2008 IEEE Congress on Evolutionary Computation*. pp. 4096-4103.
- Bache K., Lichman M. (2013). UCI Machine Learning Repository. [<http://archive.ics.uci.edu/ml>], Irvine, CA: University of California, School of Information and Computer Science.
- Balkenius C., Morén J. (1998). Computational models of classical conditioning: a comparative study. *Proceedings of the fifth international conference on simulation of adaptive behavior on From animals to animats*. 5.
- Balkenius C., Moren J. (1999). Dynamics of a Classical Conditioning Model. *Autonomous Robots*. 7, 41-56.
- Berry S.D., Hoffmann L.C., (2011). Hippocampal theta-dependent eyeblink classical conditioning: Coordination of a distributed learning system. *Neurobiology of Learning and Memory*. 95, 185-189.
- Bjork D.W. (2013). *B.F. Skinner: A Life [Paperback]*. American Psychological Association, Washington, DC.
- Bouton M.E., Moody E.W. (2004). Memory processes in classical conditioning. *Neuroscience and Biobehavioral Reviews*. 28, 663-674.
- Cai J., Ruan X., (2009). Self-balance control of Inverted Pendulum Based on Fuzzy Skinner Operant Conditioning. *2009 International Conference on Information Technology and Computer Science*. 518-521.

- Carter B.C., Vershinin M., Gross S.P. (2008). A Comparison of Step-Detection Methods: How Well Can You Do? *Biophysical Journal*. 94, 306–319.
- Chang R.C., Stout S., Miller R.R. (2004). Comparing excitatory backward and forward conditioning. *Quarterly Journal of Experimental Psychology: Section B*, 57(1), 1-23. State University of New York at Binghamton, New York, USA.
- Chester D.L. (1990). A Comparison of some Neural Network Models of Classical Conditioning. *5th IEEE International Symposium on Intelligent Control*. 1163-1168.
- Cheung J.Y., Chance D.C., Lawton A. (1992). An Examination of Real-Time Neuronal Models in a Classical Conditioning Framework. *IEEE International Joint Conference on Neural Networks*. 3, 504-509.
- Church J., White N. (2006). A 20th century acceleration in global sea-level rise. *Geophys Res Lett*. 33, (L01602). doi:10.1029/2005GL02482[5].
- Church J., White N., Aarup T., Wilson W., Woodworth P., Domingues C., Hunter J., Lambeck K. (2008). Understanding global sea levels: past, present and future. *Sustain Sci*. 3(1), 9–22. <http://dx.doi.org/10.1007/s11625-008-0042-4>.
- Clouse R.L., Kim S., Waldron M.B. (1997). An Adaptive Threshold Learning Algorithm for Classical Conditioning. *IEEE Proceedings of the 19th Annual International Conference In Engineering in Medicine and Biology Society*. 3, 1380-1382.
- Courville A.C., Daw N.D., Gordon G.J., Touretzky D.S. (2003). Model Uncertainty in Classical Conditioning. *Advances in neural information processing systems*.
- Culverhouse P.F., Williams R., Reguera B., Herry V., González-Gil S. (2003). Do experts make mistakes? A comparison of human and machine identification of dinoflagellates. *Marine Ecology Progress Series*. 247, 17-25.
- Dabney W., Barto AG. (2012). Adaptive Step-Size for Online Temporal Difference Learning. *Association for the Advancement of Artificial Intelligence*. pp. 1-7.
- Dalla C., Shors T.J. (2009). Sex differences in learning processes of classical and operant conditioning. *Physiology & Behavior*. 97, 229–238.
- Darvishi A. (2010). Translation Invariant Approach for Measuring Similarity of Signals. *Journal of Advances in Computer Research*. 1(1), 19-27.
- Davidson T.L., Sample C.H., Swithers S.E. (2014). An application of Pavlovian principles to the problems of obesity and cognitive decline. *Neurobiology of Learning and Memory*. 108, 172–184.
- Delamater A.R., Westbrook R.F. (2014). Psychological and neural mechanisms of experimental extinction: A selective review. *Neurobiology of Learning and Memory*. 108, 38–51.
- Dragoi V. (1997). A Dynamic Theory of Acquisition and Extinction in Operant Learning. *Neural Networks*. 10(2), 201–229.
- Drucker H., Burges C.J., Kaufman L., Smola A., Vapnik V. (1997). Support Vector Regression Machines. *Neural Information Processing Systems*, MIT Press. 9, 155-161.
- El-Shazly A.H. (2005). The Efficiency of Neural Networks to Model and Predict Monthly Mean Sea Level from Short Spans Applied to Alexandria Tide Gauge. *Pharaohs to Geoinformatics, FIG Working Week and GSDI-8*, Cairo, Egypt.

Eom K.H., Choi Y.J., Sirisena H. (2002). EMG pattern classification using SOFMs for hand signal recognition. *Soft Computing*. 6(6), 436-440.

Erasmus L.D. (2007). Classical Conditioning Implementation with RealNeuron Networks. *IEEE, AFRICON*. pp. 1-7. DOI: 10.1109/AFRCON.2007.4401545

Ertuğrul O. F., Tağluk M. E. (2014). Learning with classical conditioning. *IEEE 22nd Signal Processing and Communications Applications Conference*. pp. 927-930.

Fankhauser S. (1995). Protection versus retreat: the economic costs of sea-level rise. *Environment and Planning A*. 27(2), 299-319.

Fer S., Cırık İ., Altun S., Çolak E., Özkılıç R., Şahin E., Avcı S., Yüksel S., Turan H. (2011). *Öğrenme Öğretme Kuram Ve Yaklaşımları*. Anı Yayıncılık, Ankara, pp.:18-64.

Freedman S.T., Adams J.A. (2011). Filtering Data Based on Human-Inspired Forgetting. *IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics*. 41(6), 1544-1555.

Garcia J., Koelling R. A. (1966). Relation of cue to consequences in avoidance learning. *Psychonomic Science*. 4, 123-124.

Gaudio P., Chang C. (1997). Adaptive obstacle avoidance with a neural network for operant conditioning: experiments with real robots. *IEEE International Symposium on Computational Intelligence in Robotics and Automation*. pp.13-18.

Gershman S.J., Niv Y. (2012). Exploring a latent cause theory of classical conditioning. *Learn Behav*. 40, 255–268.

Ghorbani M. A., Khatibi R., Aytekin A., Makarynsky O., Shiri J. (2010). Sea water level forecasting using genetic programming and comparing the performance with artificial neural networks. *Computers & Geosciences*. 36(5), 620-627.

Guthrie E. R. (1946). Psychological Facts and Psychological Theory. *Psychological Bulletin*. 43, 1-20.

Guthrie E.R. (1934). Reward and Punishment. *Psychological Review*. 41, 450-460.

Hartmann K., Siegert I., Glüge S., Wendemuth A., Kotzyba M., Deml B. (2012). Describing Human Emotions Through Mathematical Modelling. *Proceedings of the MATHMOD*. pp. 15-17.

Hassan H.M., Al-Hamadi A. (2008). On Comparative Evaluation of Thorndike's Psycho-Learning Experimental Work Versus an Optimal Swarm Intelligent System. *IEEE Computer Society, CIMCA 2008, IAWTIC 2008, ve ISE 2008*. pp. 1083-1088.

Hawking S., Mlodinow L. (2006). *Zamanın Daha Kısa Tarihi*. Çeviren, Ögünç S., Doğan Kitapçılık. Bölüm 3.

Heldman D. A., Espay A. J., LeWitt P. A., Giuffrida J. P. (2014). Clinician versus machine: Reliability and responsiveness of motor endpoints in Parkinson's disease. *Parkinsonism and Related Disorders*. 20, 590-595.

<http://arduino.cc>

http://en.wikipedia.org/wiki/Deep_Blue_versus_Garry_Kasparov, 2015.

http://tidesandcurrents.noaa.gov/sltrends/sltrends_global_station.htm?stnid=010-00148, 2014.

- http://tidesandcurrents.noaa.gov/sltrends/sltrends_station.shtml?stnid=2695540, 2014
- <http://time.com/3614349/artificial-intelligence-singularity-stephen-hawking-elon-musk/>, 2015.
- <http://www.psmsl.org>, 2015.
- Huang G-B., Zhu Q-Y., Siew C-K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*. 70, 489–501.
- Hughes J. R. (1958). Post-tetanic Potentiation. *Physiological Reviews*. 38(1), 91–113.
- Hunter J. (2009). Estimating sea-level extremes under conditions of uncertain sea-level rise. *Climatic Change*. 99, 331–350.
- Itoh K., Miwa H., Matsumoto M., Zecca M., Takanobu H., Roccella S., Carrozza MC., Dario P., Takanishi A. (2005). Behavior Model of Humanoid Robots based on Operant Conditioning. *Proceedings of 2005 5th IEEE-RAS International Conference on Humanoid Robots*. pp. 220-225.
- Kamin L. J. (1968). Attention-like processes in classical conditioning. In Jones, M. R. (Ed.) *Miami symposium on the prediction of behavior: aversive stimulation*, Miami: University of Miami Press. pp.9–31,
- Karimi S., Kisi O., Shiri J., Makarynsky O. (2013). Neuro-fuzzy and neural network techniques for forecasting sea level in Darwin Harbor, Australia. *Computers & Geosciences*. 52, 50–59.
- Kaya Y., Kayci L., Tekin R., Ertuğrul Ö.F., (2014). Evaluation of texture features for automatic detecting butterfly species using extreme learning machine, *Journal of Experimental & Theoretical Artificial Intelligence*, 26(2), 267-281.
- Klopf A. H. (1988). A neuronal model of classical conditioning. *Psychobiology*. 16(2), 85–125.
- Klopf A.H. (1989). Classical conditioning: Phenomena predicted by a drive-reinforcement model of neural function. In Byrne, J.H. and W.O. Berry, editors, *Neural Models of Plasticity: Experimental and Theoretical Approaches*, Academic Press. 6, 94-103.
- Kucharavy D., De Guio R. (2007). Application of S-Shaped Curves. *TRIZ-Future Conference 2007: Current Scientific and Industrial Reality*, Frankfurt: Germany.
- Laslier J. F., Topol R., Walliser B. (2001). A behavioral learning process in games. *Games and Economic Behavior*. 37(2), 340-366.
- Levi K. (1989). Expert Systems Should be More Accurate than Human Experts: Evaluation Procedures from Human Judgment and Decisionmaking. *IEEE Transactions on Systems, Man and Cybernetics*. 19(3), 647-657.
- Lew SE., Wedemeyer C., Zanutto BS. (2001). Role of Unconditioned Stimulus Prediction in the Operant Learning: a Neural Network Model. *IEEE International Joint Conference on Neural Networks*. 1, 331-336.
- Li G., Quirk G.J., Nair S.S. (2007). Modeling Acquisition and Extinction of Conditioned Fear in LA Neurons using Learning Algorithm. *Proceedings of the 2007 American Control Conference*, New York, USA, pp. 552-557.

- Lin J., Spraragen M., Zyda M. (2012). Computational Models of Emotion and Cognition. *Advances in Cognitive Systems*. 2, 59-76.
- Liu C., Zhang B. (1996). An Urn Model for Instrumental Conditioning. *IEEE International Conference on Systems, Man, and Cybernetics*. 3, 2327-2332.
- Liu S., Ding Y. (2008). An Adaptive Network Policy Management Framework Based on Classical Conditioning. *Proceedings of the 7th World Congress on Intelligent Control and Automation*, Chongqing, China. pp. 3336-3340.
- Liu S., Ding Y. (2009). A Classical Conditioning Model for Policy-based Management. *International Conference on Networks Security, Wireless Communications and Trusted Computing*. pp. 249-252.
- Loebnitz N., Grunert K.G. (2015). Evaluative conditioning of food technologies. *Psychology & Marketing*, 32(7), 725-741.
- Makarynskyy O, Makarynska D, Kuhn M, Featherstone WE (2004). Predicting sea level variations with artificial neural networks at Hillarys Boat Harbour. *Western Australia. Estuarine, Coastal and Shelf Science*. 61(2), 351-360.
- Malaka R., Hammer M. (1996). Real-time models of classical conditioning. *IEEE International Conference on Neural Networks*. 2, 763-778.
- Malaka R., Lange R., Hammer M. (1995). A constant prediction model for classical conditioning. In Elser, N. and R. Menzel, editors, *Learning and Memory: Proceedings of the 23rd Gottingen Neurobiology Conference*, Thieme-Verlag, Stuttgart, New York. 1, 75.
- Malone J.C. (1990). *Theories of learning A historical Approach*. Wadsworth Publishing Company, Belmont, California. 3, 55-91.
- McCulloch W., Pitts W. (1943). A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*. 5(4), 115-133.
- Meek C., Thiesson B., Heckerman D. (2002). The Learning-Curve Sampling Method Applied to Model-Based Clustering. *Journal of Machine Learning Research*. 2, 397-418.
- Miguez G., Laborda M.A., Miller R.R. (2014). Classical conditioning and pain: Conditioned analgesia and hyperalgesia. *Acta Psychologica*. 145, 10-20.
- Miller R.R. (2006). Challenges facing contemporary associative approaches to acquired behavior. *Comparative Cognition & Behavior Reviews*. 1, 77-93.
- Morgan J.S., Patterson E.C., Klopff A.H. (1990). A Drive-Reinforcement Neural Network Model of Simple Instrumental Conditioning. *IEEE International Joint Conference on Neural Networks*. 2, 227 – 232.
- Morris MJ. (2000). The Artie Simulation of Operant Conditioning. *Mexican Journal of Behavior Analysis*. 26, 251-271.
- Naim MM., Towill DR. (1994). System Dynamics and Learning Curves. *International System Dynamics Conference*. Business Decision-Making, 164-173.
- Novianto R., Williams M.A., Gärdenfors P., Wightwick G. (2014). Classical conditioning in social robots. *Social Robotics*, Springer International Publishing, pp. 279-289.
- Parker BB (1992). Sea Level as an Indicator of Climate and Global Change. *The Marine Technology Society Journal*. 25(4).

- Pashova, L., Popova, S. (2011). Daily sea level forecast at tide gauge Burgas, Bulgaria using artificial neural networks. *Journal of Sea Research*. 66(2), 154-161.
- Pavlov I. P. (1927). Conditioned reflexes. *Dover Publications*.
- Pornpitakpan C. (2012). A critical review of classical conditioning effects on consumer behavior. *Australasian Marketing Journal*. 20, 282–296.
- Ramana B.V., Babu P., Surendra M., Venkateswarlu N.B. (2011). A Critical Study of Selected Classification Algorithms for Liver Disease Diagnosis. *International Journal of Database Management Systems*. 3(2), 101-114.
- Ramana B.V., Babu P., Surendra M., Venkateswarlu N.B. (2012). A Critical Comparative Study of Liver Patients from USA and INDIA: An Exploratory Analysis. *International Journal of Computer Science Issues (IJCSI)*. 9(3), 506-516.
- Read J., Bifet A., Pfahringer B., Holmes G. (2012). Batch-incremental versus instance-incremental learning in dynamic and evolving data. *Advances in Intelligent Data Analysis XI*, Springer Berlin Heidelberg. pp. 313-323.
- Ren H., Ruan X., (2009). Applying of Recurrent Network Based on Skinner's Operant Conditioning in Robot. *IEEE International Conference on Intelligent Human-Machine Systems and Cybernetics*. pp. 351-354.
- Rescorla R. A. (1968). Probability of shock in the presence and absence of CS in fear conditioning. *Journal of comparative physiological psychology*. 66, 1–5.
- Rescorla R.A., Wagner, A.R. (1972). A theory of Pavlovian conditioning: Variations in the effectiveness of reinforcement and nonreinforcement. In A. H. Black & W. F. Prokasy (Eds.), *Classical Conditioning II: Current Research and Theory*, New York, NY: Appleton-Century-Crofts, pp. 64-99.
- Ruan X., Gao Y., Song H. (2009). Operant Conditioning Automata Model and a Bionic Autonomous Learning Process. *IEEE International Conference on Intelligent Computing and Intelligent Systems*. 2, 200-204
- Ruan X., Ren H. (2009-b). Bionic Learning Algorithm Based on Skinner's Operant Conditioning and Control of Robot. *WASE International Conference on Information Engineering*, IEEE Computer Society. 2, 62-65.
- Ruan X-G., Ren H-G., Wang Q-Y. (2009). Self-balance Control of Two-wheeled Robot Based on Skinner's Operant Conditioning. *IEEE International Workshop on Intelligent Systems and Applications*. pp. 1-4.
- Sağlam İ. (2009). Bazı Öğrenme Kuramları ve Din Öğretimi. *T.C. Uludağ Üniversitesi, İlahiyat Fakültesi Dergis*. 18(2), 251-266.
- Salotti J.M., Lepretre F. (2008). Classical and Operant Conditioning as Roots of Interaction for Robot. *Proceedings of the Workshop From Motor to Interaction Learning in Robots, Conference on Intelligent Robotics Systems*, Nice.
- Samuel A. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal*. 3, 210–229.
- Schmajuk N.A., DiCarlo J.J. (1992). Stimulus Configuration, Classical Conditioning, and Hippocampal Function. *Psychological Review*. 99(2), 268-305.
- Schneiderman N., Fuentes I., Gormezano I. (1962). Acquisition and extinction of the classically conditioned eyelid response in the albino rabbit. *Science*. 136, 650–652.

- Schunk D. H. (2012). *Learning Theories An Educational Perspective*. Pearson, 6. Baskı.
- Shechner T., Hong M., Britton J.C., Pine D.S., Fox N.A. (2014). Fear conditioning and extinction across development: Evidence from human studies and animal models. *Biological Psychology*. 100, 1–12.
- Skinner B.F. (1950). Are Theories of Learning Necessary? *The Psychological Review*. 57(4), 193-216.
- Smith J.W., Everhart J.E., Dickson W.C., Knowler W.C., Johannes R.S. (1988) Using the ADAP learning algorithm to forecast the onset of diabetes mellitus. *In Proceedings of the Symposium on Computer Applications and Medical Care*, IEEE Computer Society Press. pp. 261-265.
- Smith M.C., Coleman S.R., Gormezano I. (1969). Classical conditioning of the rabbit's nictitating membrane response at backward, simultaneous, and forward CS-US interval. *Journal of comparative and physiological psychology*. 69(2), 226-31.
- Stuart E.W., Shimp T.A., Enge R.W. (1987). Classical Conditioning of Consumer Attitudes: Four Experiments in an Advertising Context. *Journal of Consumer Research*. 14, 334-349.
- Sun X., Lv T., Gao Y., Su F., Zhang T., Fan J. (2012). Quantitative analysis of sea level rise caused by continental input. *IEEE International Geoscience and Remote Sensing Symposium*. pp. 515-518.
- Sungur M. Z., Yalnız Ö. (1999). Şizofreni Tedavisinde Bilişsel-Davranışçı Yaklaşımlar. *Klinik Psikiyatri Dergisi*. 2, 160-166.
- Sutton R.S., Barto A.G. (1981). Toward a modern theory of adaptive networks: expectation and prediction. *Psychological review*. 88.2, 135.
- Sutton R.S., Barto A.G. (1990). Time-derivative models of Pavlovian reinforcement. *In Gabriel, A. and J. Moore, editors, Learning and Computational Neuroscience: Foundations and Adaptive Networks*, MIT Press, Cambridge, Mass and London. 12:497-537.
- Sztobryn, M. (2013). Application of Artificial Neural Network into the Water Level Modeling and Forecast. *TransNav: International Journal on Marine Navigation and Safety of Sea Transportation*. 7(2), 219-223.
- Tagluk, M. E, Tekin, R. (2014). The influence of ion concentrations on the dynamic behavior of the Hodgkin–Huxley model-based cortical network. *Cognitive Neurodynamics*. 8(4), 287-298.
- Tagluk, M. E, Ertugrul, O. F. (2015). A Review of Computational Classical Conditioning Models. *American Journal of Psychology and Behavioral Sciences*. 2(2), 33-40.
- Tekin R., Tağluk M.E., Ertuğrul Ö.F. (2012). Harici Uyarı Akımı Ve İyonik Konsantrasyonların Hodgkin-huxley Sinir Modeli Üzerindeki Etkileri. 20. *Sinyal İşleme ve İletişim Uygulamaları Kurultayı*. pp. 1-4.
- Thompson A.K., Stein R.B., Chen X.Y., Wolpaw J.R. (2006). Modulation in spinal circuits and corticospinal connections following nerve stimulation and operant conditioning. *Proceedings of the 28th IEEE EMBS Annual International Conference*, New York City, USA. FrA02.2, 2138-2141.

- Todd T.P., Vurbic D., Bouton M.E. (2014). Behavioral and neurobiological mechanisms of extinction in Pavlovian and instrumental learning. *Neurobiology of Learning and Memory*. 108, 52–64.
- Topses G. (2009). *Gelişim ve Öğrenme Psikolojisi*. Nobel Yayın Dağıtım / Eğitim Dizisi, 3. Baskı, Ankara. pp. 214-233.
- Topses G. (2012). Davranışçı ve Varoluşçu-Hümanistik Psikolojik Danışma Kuramlarının Ayırtedici ve Örtüşen Nitelikleri. *International Journal of New Trends in Arts, Sports & Science Education*, 1(3), 67-75.
- Türkçapar M. H., Sargın A. E. (2011). Bilişsel Davranışçı Psikoterapiler: Tarihçe ve Gelişim. *Bilişsel Davranışçı Psikoterapi ve Araştırmalar Dergisi*. pp. 7-17.
- Türkçapar M.H., Sargın A.E. (2012). Cognitive Behavioral Psychotherapies: History and Development. *Journal of Cognitive-Behavioral Psychotherapy and Research*. 1(1), 7-14.
- Vervliet B., Geens M. (2014). Fear generalization in humans: Impact of feature learning on conditioning and extinction. *Neurobiology of Learning and Memory*. 113, 143–148.
- Veznedaroğlu R.L., Özgür A.O. (2005). Öğrenme Stilleri: Tanımlamalar, Modeller ve İşlevleri. *İlköğretim Online*. 4(2), 1-16.
- Wagner A.R. (1981). SOP: A model of automatic memory processing in animal behavior. In Spear, N.E. and R.R. Miller, editors, *Information Processing in Animals: Memory Mechanisms*, Erlbaum, New Jersey. 85(1), 5-44.
- Watson J.B. (1914). Psychology as the Behaviorist Views It. *Psychological Review*. 101(2), 248-253.
- Watson J.B. (1959). *Behaviorism*. University of Chicago Press, Chicago. pp. 82.
- Watson J.B., Rayner R. (1920). Little Emotional Albert, Conditioned emotional responses. *Journal of Experimental Psychology*. 3, 1-14.
- Yapıcı M. (2006). Öğrenme-öğretme sürecinde olumsuz pekiştirici. *International Journal of Human Sciences*. 1(1), 1-10.
- Yapıcı Ş., Yapıcı M. (2005). *Gelişim ve Öğrenme Psikolojisi*. Anı Yayıncılık, pp. 179-199.
- Yapıcı Ş., Yapıcı M. (2010). *Eğitim Psikolojisi*. Anı Yayıncılık, 2. Baskı, pp.187-207.
- Yeşilyaprak B., Aydın B., Bilgin M., Can G., Ersanlı K., Kılıç M., Kısaç İ., Korkmaz İ., Küçükkaragöz H., Küllahoğlu Ş., Öztürk B., Uçar E. (2012). *Eğitim Psikolojisi Gelişim-Öğrenme-Öğretim*. Ankara: Pegem Akademi.
- Yoshida M., Okamura I., Uematsu K. (2004). Involvement of the cerebellum in classical fear conditioning in goldfish. *Behavioural Brain Research*. 153(1), 143–148.

EKLER

EK-1. Etik Kurul Kararı



İNÖNÜ ÜNİVERSİTESİ TIP FAKÜLTESİ

DENEY HAYVANLARI ETİK KURULU KARARI

Toplantı Tarihi : 26-03-2015
Toplantı Yeri : Tıp.Fak.Toplantı Salonu-Malatya
Araştırma Protokol no.su : 2015/A-31
Deneyde Kullanılacak Hayvanın Türü : Tavuk ve Horoz
Deneyde Kullanılacak Hayvanın Soyu : Tavuk ve Horoz
Deneyde Kullanılacak Hayvanın Cinsiyeti : ☒E ☒D ☐Farketmez
Deneyde Kullanılacak Hayvanın Sayısı : 6 Adet Tavuk, 1 Adet Horoz
Deneyde Kullanılacak Hayvanın Yaşı ve Ağırlığı : 1 / 1,5 kg

Doç. Dr. Mehmet Emin Tağluk'un yürütücüsü olduğu "Davranışsal Öğrenme Kuramlarının Genelleştirilmesi" isimli 2015/A-31 Protokol no.lu çalışmanın dosyası incelendi.

Adı geçen araştırmanın; araştırma protokolüne tamamen uyulmak, İnönü Üniversitesi Tıp Fakültesi Deney Hayvanları Etik Kurul Yönergesi'nde belirtilen hususlar yerine getirilmek ve sorumluluk araştırmacılara ait olmak üzere çalışmanın yapılmasında herhangi bir etik sakınca bulunmadığına oy birliği ile karar verildi.

Doç.Dr.M.Arif ALADAĞ
Başkan

Prof. Dr. Nigar VARDI
Üye

Doç. Dr. Yılmaz ÇİĞREMİŞ
Üye

Vet.Hek.M.Zafer BOZDAĞ
Üye

Yrd.Doç.Dr.Mehmet KARATAŞ
Üye

Yrd.Doç.Dr. Mustafa KARAKAPLAN
Üye

Salih AVCI
Sivil Üye

Katılmadı
Ahmet GÖNÜLLÜOĞLU
Sivil Üye

EK-2. Önerilen GDÖ Yönteminin Sınıflandırma Kodu

```
clc; clear all; close all
load datasett
% data=giriş verisi; target=çıkış verisi

% Başlangıç Değerleri
StimulusExtinction_coef=0.590;      % Sönme katsayısı
LearningRate=0.008;                % Öğrenme adım katsayısı
Connection_coef=0.25;              % Birleştirme katsayısı
numberOfContiguousObservation=1;    % Birleştirilecek olay sayısı
numberOfObservation=length(target); % Olay sayısı
numberOfStimulus=size(datam,1);    % Uyarıcı sayısı
numberOfResponse=2;                % Tepki tür sayısı

% Uyarıcılar
for i=1:numberOfObservation
    Stimulus(:,i)=datam(:,i);
    for j=1:numberOfResponse
        if i==1
            ObtainedResponse(i,j)=sum(initialweight(j,:)*Stimulus(:,i)); else
            eval(['ObtainedResponse(i,j)=sum(WS',int2str(j) '(i-1,:)*Stimulus(:,i));']);
        end
    end
    temp1=find(ObtainedResponse(i,:)==max(ObtainedResponse(i,:))-1;
    if length(temp1)>1 || isempty(temp1)
        temp1=find(initialweight(:,1)==max(initialweight(:,1)))-1;
        if isempty(temp1);temp1=round(rand);end
    end
    Reaction(i)=temp1(1);
    if Reaction(i)==0
        OResponse(i,1)=1;OResponse(i,2)=0;
    else
        OResponse(i,2)=1;OResponse(i,1)=0;
    end
    if Reaction(i)==target(i);ReinforcingStimulus(i)=1;else
ReinforcingStimulus(i)=-1;end
    OrganismPreparatory(i)=1; %Sürekli ilgili
    for j=1:numberOfResponse
        if i==1
            eval(['WS',int2str(j) '(i,:)=initialweight(j,:);']);
        elseif i==2
            m_R(i)=OResponse(i,j);m_OP(i)=OrganismPreparatory(i);
            m_RS(i)=ReinforcingStimulus(i);
            for n=1:numberOfStimulus
                temp=LearningRate*m_OP(i)*m_RS(i)*Stimulus(n,i)*m_R(i);
                eval(['WS',int2str(j) '(i,n)=StimulusExtinction_coef*initialweight(j,n)+
temp;']);
            end
        end
    end
end
```

```

        end
    else
        m_R(i)=0;m_OP(i)=0;m_RS(i)=0;
        for k=0:numberofContiguousObservation
            m_R(i)=m_R(i-1)+OResponse(i-1+k,j)*Connection_coef^k;
            m_OP(i)=m_OP(i-1)+OrganismPreparatory(i-1+k)*Connection_coef^k;
            m_RS(i)=m_RS(i-1)+ReinforcingStimulus(i-1+k)*Connection_coef^k;
        end
        m_R(i)=m_R(i)+0.0001;
        for n=1:numberofStimulus
            temp=LearningRate*m_OP(i)*m_RS(i)*Stimulus(n,i)*m_R(i);
            eval(['WS',int2str(j),'(i,n)=tansig(StimulusExtinction_coef*WS',int2str(j),'(i-1,n)+
temp);' ]);
        end
    end
end
end

dogru=zeros(1,numberofObservation);
for i=1:numberofObservation
    if Reaction(i)==target(i)
        dogru(i)=1;
    end
end

Basari=100*sum(dogru)/numberofObservation; oran=5;
for i=1:numberofObservation/oran
    ortdogru(i)=sum(dogru(oran*(i-1)+1:oran*i))/oran;
end

```

EK-3. Önerilen GDÖ Yönteminin Regresyon Kodu (MATLAB)

```
clc; clear all; close all
load datasett
% data=giriş verisi; target=çıkış verisi

% Başlangıç Değerleri
StimulusExtinction_coef=0.590;      % Sönme katsayısı
LearningRate=0.008;                 % Öğrenme adım katsayısı
Connection_coef=0.25;               % Birleştirme katsayısı
numberOfContiguousObservation=1;    % Birleştirilecek olay sayısı
numberOfObservation=length(target); % Olay sayısı
numberOfStimulus=size(datam,1);    % Uyarıcı sayısı
numberOfResponse=1;                 % Tepki tür sayısı
epsilon=0.15;                       % Regresyon tüpü

% Uyarıcılar
for i=1:numberOfObservation
    Stimulus(:,i)=datam(:,i);
    if i==1
        ObtainedResponse(i)=sum(initialweight*Stimulus(:,i));
    else
        ObtainedResponse(i)=sum(WS(i-1,:)*Stimulus(:,i));
    end
    if (ObtainedResponse(i)>=target(i)-epsilon)&&(ObtainedResponse(i)<target(i)+epsilon)
        ReinforcingStimulus(i)=1;
    else
        ReinforcingStimulus(i)=-1;
    end
    OrganismPreparatory(i)=1; %Sürekli ilgili
    if i==1
        WS(i,:)=initialweight;
    elseif i==2
        m_R(i)=ObtainedResponse(i);m_OP(i)=OrganismPreparatory(i);
        m_RS(i)=ReinforcingStimulus(i);
        for n=1:numberOfStimulus
            temp=LearningRate*m_OP(i)*m_RS(i)*Stimulus(n,i)*m_R(i);
            WS(i,n)=StimulusExtinction_coef*initialweight(n)+temp;
        end
    else
        m_R(i)=0;m_OP(i)=0;m_RS(i)=0;
        for k=0:numberOfContiguousObservation
            m_R(i)=m_R(i-1)+ObtainedResponse(i-1+k)*Connection_coef^k;
            m_OP(i)=m_OP(i-1)+OrganismPreparatory(i-1+k)*Connection_coef^k;
            m_RS(i)=m_RS(i-1)+ReinforcingStimulus(i-1+k)*Connection_coef^k;
        end
        m_R(i)=m_R(i)+0.0001;
```

```

    for n=1:numberofStimulus
        temp=LearningRate*m_OP(i)*m_RS(i)*Stimulus(n,i)*m_R(i);
        WS(i,n)=tansig(StimulusExtinction_coef*WS(i-1,n)+temp);
    end
end
Basari=mse(ObtainedResponse,target);oran=5;
for i=1:numberofObservation/oran
    ortbasari(i)=mse(ObtainedResponse(oran*(i-1)+1:oran*i),target(oran*(i-1)+1:oran*i));
end

```

EK-4. Önerilen Yöntemin Akıllı Kontrol Kodu

```
function [control_response, WS_2]=behvioural_control(P1, P2, P3, P4, P5, S,  
WS_1, RS, OP)
```

```
% Başlangıç Değerleri:
```

```
StimulusExtinction_coef=P1;          % Sönme katsayısı  
LearningRate=P2;                     % Öğrenme adım katsayısı  
Connection_coef=P3;                  % Birleştirme katsayısı  
numberOfContiguousObservation=P4;    % Birleştirilecek olay sayısı  
numberOfObservation=length(target);  % Olay sayısı  
numberOfStimulus=size(datam,1);     % Uyarıcı sayısı  
numberOfResponse=1;                  % Tepki tür sayısı  
epsilon=P5;                          % Regresyon tüpü  
Stimulus=S;                          % Uyarıcı  
ReinforcingStimulus=RS;              % Tepkisel uyarıcı  
OrganismPreparatory=OP;              % Organizma uyarıcısı  
numberOfStimulus=length(Stimulus);   % Uyarıcı sayısı  
WS=0.5*ones(numberofStimulus,1);    % Başlangıç ağırlıkları
```

```
control_response=sum(WS1*Stimulus);
```

```
% Ağırlıkların Güncellenmesi
```

```
m_R=0.00001;m_OP=0.00001;m_RS=0.00001;
```

```
R(end+1)=control_response;
```

```
for k=0:numberofContiguousObservation
```

```
    m_R=m_R+R(end-k)*Connection_coef^k;
```

```
    m_OP=m_OP+OrganismPreparatory(end-k)*Connection_coef^k;
```

```
    m_RS=m_RS+ReinforcingStimulus(end-k)*Connection_coef^k;
```

```
end
```

```
for n=1:numberofStimulus temp=LearningRate*m_OP*m_RS*Stimulus(n)*m_R;
```

```
    WS_2(n)=tansig(StimulusExtinction_coef*WS_1(n)+temp);
```

```
end
```

```
end
```

EK-5. Önerilen Yöntemin Arduino Kodu

```
/* Genelleştirilmiş Davranışçı Öğrenme */
#include <SD.h> // SD kart kütüphanesi
// Sabit Tanımları
const int chipSelect = 4; // SD kart CS pini
float StimulusExtinction_coef=0.970; // Sönme katsayısı
float LearningRate=0.013; // Öğrenme adım katsayısı
float Connection_coef=0.25; // Birleştirme katsayısı
int numberOfContiguousObservation=3; // Bitiştirilecek uyarıcı sayısı
int numberOfStimulus=3; // 1. Uyarıcı (doğal) 2. Uyarıcı (nötr)
// Değişkenler ve başlangıç değerlerinin atanması
float R1=1,R2=1,R3=1;
float OP1=1,OP2=1,OP3=1;
float RS1=1,RS2=1,RS3=1;
float WS1=1,WS2=0,WS3=0;
void setup() {
    Serial.begin(9600);
}
// Çıkış pinlerinin atanması
pinMode(8, OUTPUT); // Tepki
// Dijital giriş pinlerinin atanması
pinMode(2, INPUT); // RS
pinMode(3, INPUT); // OP
pinMode(7, INPUT); // Stimulus 1: Doğal Uyarıcı
// Analog giriş pinleri: A0: 1. uyarıcı / A1: 2. uyarıcı

void loop() {
    // Değişken Tanımları
    String dataString = ""; // SD karta yazılacak bilgi
    float WS11, WS22, WS33; // Ağırlıklar
    float S1, S2, S3; // Uyarıcılar
    int i, n, temp; // Program değişkenleri
    float mR, mOP, mRS; // Program değişkenleri
    // Uyarıcıların okunması
    S1=digitalRead(7); // Doğal uyarıcı
    temp=analogRead(A0); // Analog giriş (dokunma algılayıcısı)
    if (temp>500){S2=1;} // Analog girişin dijitalize edilmesi
    else {S2=0;} // Analog girişin dijitalize edilmesi
    temp=analogRead(A1); // Analog giriş (hareket algılayıcısı)
    if (temp>300){S3=1;} // Analog girişin dijitalize edilmesi
    else {S3=0;} // Analog girişin dijitalize edilmesi

    R3=WS1*S1+WS2*S2+WS3*S3; // Tepkinin hesaplanması
    // Tepkinin dijital olarak yansıtılması (8. Port)
    if (R3>0.5){
        digitalWrite(8,HIGH);}
}
```

```

else {
    digitalWrite(8,LOW);}

RS3=digitalRead(2);           // Tepkisel uyarıcısının okunması
OP3=digitalRead(3);           // Organizma uyarıcısının okunması

// Geriye dağılmış parametrelerin hesaplanması
mR=R3+R2*pow(Connection_coef,1)+R1*pow(Connection_coef,2);
mRS=RS3+RS2*pow(Connection_coef,1)+RS1*pow(Connection_coef,2);
mOP=OP3+OP2*pow(Connection_coef,1)+OP1*pow(Connection_coef,2);
// Ağırlıkların güncellenmesi
WS11=StimulusExtinction_coef*WS1+LearningRate*mOP*mRS*S1*mR;
WS22=StimulusExtinction_coef*WS2+LearningRate*mOP*mRS*S2*mR;
WS33=StimulusExtinction_coef*WS3+LearningRate*mOP*mRS*S3*mR;

// Verilerin SD karta kaydedilmesi
dataString += String(S1);dataString += ",";
dataString += String(S2);dataString += ",";
dataString += String(S3);dataString += ",";
dataString += String(OP3);dataString += ",";
dataString += String(RS3);dataString += ",";
dataString += String(R3);dataString += ",";
dataString += String(WS11);dataString += ",";
dataString += String(WS22);dataString += ",";
dataString += String(WS33);dataString += ",";
File dataFile = SD.open("deney.txt", FILE_WRITE);
dataFile.println(dataString);
dataFile.close();

// Verilerin zamansal olarak kaydırılması
R1=R2;R2=R3;RS1=RS2;RS2=RS3;OP1=OP2;OP2=OP3;
WS1=WS11;WS2=WS22;WS3=WS33;
delay(1000);
}

```

ÖZGEÇMİŞ

Ad Soyad : Ömer Faruk Ertuğrul

Doğum Yeri ve Tarihi : Batman, 18.03.1978

Adres : Batman Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Batıraman, Batman

E-Posta : omerfarukertugrul@gmail.com

Lisans : Elektrik ve Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Hacettepe Üniversitesi

Yüksek Lisans (1) : Matematik Bölümü, Fen Bilimleri Enstitüsü, Dicle Üniversitesi

Yüksek Lisans (2) : Elektrik ve Elektronik Mühendisliği Bölümü, Fen Bilimleri Enstitüsü, Dicle Üniversitesi

Mesleki Deneyim ve Ödüller :

- Türk Telekom A.Ş., Telekom Uzman Yardımcısı (2003-2006)
- TEİAŞ, Mühendis & Grup Müdür Yardımcısı (2006-2011)
- Batman Valiliği, Enerji Çalışma Grubu, Mühendis (2009 - 2011)
- Batman Üniversitesi, Araştırma Görevlisi (2011-)

Yayın Listesi :

SSCI, SCI, SCI-E kapsamındaki Uluslararası hakemli dergilerde yayımlanan makaleler :

1. Tağluk M.E, Ertuğrul Ö.F., (2015). A Joint Generalized Exemplar Method for Classification of Massive Datasets. *Applied Soft Computing*. 36, 487-498, doi: 10.1016/j.asoc.2015.07.044
2. Kaya Y., Ertuğrul Ö.F., Tekin, R. (2015). Two novel local binary pattern descriptors for texture analysis. *Applied Soft Computing*. 34, 728–735, doi:10.1016/j.asoc.2015.06.009
3. Kaya Y., Kayci L., Tekin R., Ertuğrul Ö.F. (2013). Evaluation of texture features for automatic detecting butterfly species using extreme learning machine. *Journal of Experimental & Theoretical Artificial Intelligence*. 26(2), 267-281, doi: 10.1080/0952813X.2013.861875

SSCI, SCI, SCI-E kapsamı dışındaki Uluslararası hakemli dergilerde yayımlanan makaleler :

1. Tagluk, M.E., Ertugrul, O.F. (2015). A Review of Computational Classical Conditioning Models. *American Journal of Psychology and Behavioral Sciences (AJPBS)*. 2(2), 36-44.
2. Ertuğrul Ö.F., Kaya Y., Kaycı L., Tekin R. (2015). Identification of Butterfly Species by Similarity Indexes Based on Prototypes.

- International Journal of Computer Vision, Machine Learning and Data Mining*. 1, 11-19.
3. Kaya Y., Kaycı L., Ertuğrul Ö.F., Tekin R. (2015). Identification of Butterfly Species with Rough Set Approach Based on Textural Features. *International Journal of Computer Vision, Machine Learning and Data Mining*. 1, 1-10.
 4. Ertuğrul Ö.F., Kaya Y., Kaycı L., Tekin R. (2015). A Vision System for Classifying Butterfly Species by using Law's Texture Energy Measures. *International Journal of Computer Vision, Machine Learning and Data Mining*. 1, 16-24.
 5. Ertuğrul Ö.F., Kaya Y. (2014). A Detailed Analysis on Extreme Learning Machine and Novel Approaches Based on ELM. *American Journal of Computer Science and Engineering*. 1(5), 4350
 6. Kaya Y., Ertuğrul Ö.F., Tekin R. (2014). A Rough Set Approach for Modeling E-Mail Usage Habits. *Computer Science and Applications*. 1(4), 259-264.
 7. Ertuğrul Ö.F., Kurt M.B. (2014). A Fast and Accurate Fault Detection Approach in Power Transmission Lines by Modular Neural Network and Discrete Wavelet Transform. *Computer Science and Applications*. 1(3), 152-157.
 8. Kaya Y., Ertuğrul Ö.F., Tekin R. (2014). An Expert Spam Detection System Based on Extreme Learning Machine. *Computer Science and Applications*. 1(2), 133-138.
 9. Ertugrul Ö.F. (2014). Adaptive Texture Energy Measure Method. *International Journal of Intelligent Information Systems*. 3(2), 13-18.
 10. Ertuğrul Ö.F., Kurt M.B. (2011). Enerji İletim Hatlarında Modüler YSA ve ADD ile Hızlı Arıza Tespiti. *e-Jurnal of New World Sciences Academy (NWSA)*. 6(1), 79-88.

Ulusal Hakemli Yayınlar _____ :

1. Tekin R., Sezgin N., Ertuğrul Ö.F. (2013). Matlab İle Hodgkin-Huxley Nöron Modeli Temelli Nöron Dinamiği Benzetimi. *Yaşam Bilimleri Dergisi*. 1(2), 317-327.
2. Ertuğrul Ö.F., Kaya Y., Acar E. (2013). Enerji İletim Hattı Arızalarında Elman Ysa Kullanılarak Çok Hızlı Arıza Tetikleme Algoritması. *Yaşam Bilimleri Dergisi*. 1(2), 299-306.
3. Kaya Y., Ertuğrul Ö.F., Tekin R. (2013). Epileptik EEG İşaretlerinin Sınıflandırılmasında Karar Kuralları ve Karar Ağaçlarının Kullanılması. *Yaşam Bilimleri Dergisi*. 1(2), 403-413.

Ulusal bilimsel toplantılarda sunulan ve bildiri kitabında basılan bildiriler _____ :

1. Tağluk M.E., Mamiş M.S., Arkan M., Ertuğrul Ö.F., (2015). Aşırı Öğrenme Makineleri ile Enerji İletim Hatları Arıza Tipi ve Yerinin Tespiti. *IEEE, 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, pp. 992-995
2. Çalışkan A., Ertuğrul Ö.F., (2015). Dalgacık Dönüşümü Tabanlı Parmak İzi Tanıma. *IEEE, 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, pp. 1383-1386
3. Kaya Y., Ertuğrul Ö.F., Tekin R. (2015). Doküman Dili Tanıma İçin İkili Örüntüler Tabanlı Yeni Bir Yaklaşım. *Akademik Bilişim*.
4. Ertuğrul Ö.F., Tağluk M.E., Sümer E. (2014). Davranışçı Öğrenme Kuramlarının Genelleştirilmesi". *23. Ulusal Eğitim Bilimleri Kurultayı*, Kocaeli. pp. 162.
5. Ertugrul O. F., Tagluk M. E. (2014). Klasik Koşullanma ile Öğrenme. *IEEE, 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*. pp. 927-930.

6. Ertugrul Ö.F., Tağluk M.E., Tekin R. (2013). Yapay Sinir Ağları ile Dayanıklı Kararlılık Analizi. *2013 Otomatik Kontrol Ulusal Toplantısı ve Sergisi (TOK2013)*. pp. 1268-1271
7. Ertugrul Ö.F., Tağluk M.E., Kaya Y. (2013). Enerji İletim Hatlarında Oluşan Arızaların Aşırı Öğrenme Makinesi ile Tespiti. *21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, (SIU2013)*.
8. Ertugrul Ö.F., Tağluk M.E., Kaya Y., Tekin R. (2013). EMG Sinyallerinin Aşırı Öğrenme Makinesi ile Sınıflandırılması. *21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2013)*.
9. Sezgin N., Tağluk M.E., Ertuğrul Ö.F., Kaya Y., (2013). Epileptik EEG İşaretlerinin İkiz-spektrum Analizi. *21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2013)*.
10. Tekin R., Tağluk M.E., Ertuğrul Ö.F., Sezgin N. (2013). Kortikal Bir Ağ Modelinin Çıkış Verisindeki Karmaşıklık ve Uyumluluk Analizi. *21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2013)*.
11. Ertuğrul Ö.F., Tağluk M.E., Kaya Y. (2012). Enerji İletim Hatlarında Wigner Ville Dağılımı, Gri Düzey Eş Oluşum Matrisi ve Örüntü Tanıma Yöntemleri ile Arıza Analizi. *20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2012)*.
12. Tekin R., Tağluk M.E., Ertuğrul Ö.F. (2012). Harici Uyarı Akımı Ve İyonik Konsantrasyonların Hodgkin-huxley Sinir Modeli Üzerindeki Etkileri. *20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU2012)*.
13. Ertuğrul Ö.F., Korkmaz G. (2012). Güneş Hibrit Jeotermal Enerji ve Batman – Taşlıdere’de Güneş Hibrit Jeotermal Enerji ile Elektrik Üretim Örneği. *Ulusal Enerji Verimliliği Forumu (UEVF2012)*. pp.103-109.
14. Ertuğrul Ö.F. (2011). Enerji Verimliliği Çalışmaları ve Yenilenebilir Enerji Kaynaklarının Bölgede Kullanılabilirliği ve Yatırım Olanakları. *Batman, Siirt, Şırnak İlleri Enerji Forumu*. (Davetli Konuşmacı)
15. Ertuğrul Ö.F. (2009). Batman Yenilenebilir Enerji Kaynakları Potansiyeli. *1. Batman Kent Sempozyumu*.
16. Ertuğrul Ö.F., Kurt M.B. (2009). Yenilenebilir Enerji Kaynakları Maliyet Analizi ve Sürdürülebilir YEK Uygulamaları. *V. Yenilenebilir Enerji Kaynakları Sempozyumu (YEKSEM'09)*. pp. 37-40.
17. Ertuğrul Ö.F., Kurt M.B. (2009). Güneydoğu Anadolu Bölgesinin Yenilenebilir Enerji Kaynakları Yönünden Değerlendirilmesi. *V. Yenilenebilir Enerji Kaynakları Sempozyumu (YEKSEM'09)*. pp. 232-235.

Proje :

1. Dika destekli “Güneş Enerjisi ile İçme Suyu Temini” (DİKA-14-DFD/0007) projesi, Bütçe 200.600 TL, Proje Yürütücüsü (12.02.2015-01.06.2015) – İl Özel İdare ve Batman Üniversitesi ortak projesi

Tezden Türetilen Yayınlar/Sunumlar:

1. Tağluk M.E, Ertuğrul Ö.F., (2015). A Joint Generalized Exemplar Method for Classification of Massive Datasets. *Applied Soft Computing*. In press, doi: 10.1016/j.asoc.2015.07.044
2. Tağluk, M.E., Ertugrul, O.F. (2015). A Review of Computational Classical Conditioning Models. *American Journal of Psychology and Behavioral Sciences (AJPBS)*. 2(2), 36-44.
3. Ertuğrul Ö.F., Tağluk M.E., Sümer E. (2014). Davranışçı Öğrenme Kuramlarının Genelleştirilmesi”. *23. Ulusal Eğitim Bilimleri Kurultayı, Kocaeli*. pp. 162.

4. Tađluk M.E., Mamiř M.S., Arkan M., Ertuđrul .F., (2015). Ařırı đrenme Makineleri ile Enerji İletim Hatları Arıza Tipi ve Yerinin Tespiti. *IEEE, 23. Sinyal İřleme ve İletiřim Uygulamaları Kurultayı*, pp. 992-995
5. Ertuđrul, .F., Tađluk, M.E. (2014). Klasik Kořullanma İle đrenme. 22. *Sinyal İřleme ve İletiřim Uygulamaları Konferansı (SIU-2014)*, Trabzon.
6. Ertuđrul, .F., Tađluk, M.E., Tekin, R. (2013). Yapay Sinir Ađları ile Dayanıklılı Kararlılık Analizi. *2013 Otomatik Kontrol Ulusal Toplantısı ve Sergisi (TOK2013)*. Syf: 1268-1271.
7. Ertuđrul, .F., Tađluk, M.E., Kaya, Y. (2013). Enerji İletim Hatlarında Oluřan Arızaların Ařırı đrenme Makinesi ile Tespiti. *21. Sinyal İřleme ve İletiřim Uygulamaları Kurultayı (SIU2013)*.
8. Ertuđrul, .F., Tađluk, M.E., Kaya, Y., Tekin, R. (2013). EMG Sinyallerinin Ařırı đrenme Makinesi ile Sınıflandırılması. *21. Sinyal İřleme ve İletiřim Uygulamaları Kurultayı (SIU2013)*.
9. Ertuđrul, .F., Tađluk, M.E., Kaya, Y. (2012). Enerji İletim Hatlarında Wigner Ville Dađılımı, Gri Düzey Eř Oluřum Matrisi Ve rüntü Tanıma Yöntemleri İle Arıza Analizi. *20. Sinyal İřleme ve İletiřim Uygulamaları Kurultayı (SIU2012)*.

Tezin Diđer Çıktıları :

1. 2015/00743 nolu, “İnsan gibi đrenebilen Akıllı Kontrol Sistemi” patent başvurusu (Arařtırma Ařamasında)