

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

GERÇEK ZAMANLI STRATEJİ OYUNU İÇİN
MİKRO YÖNETİM YAPAY ZEKASI

YÜKSEK LİSANS TEZİ

Suat ÖZCAN

2000006019

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Doç. Dr. Akhan AKBULUT

HAZİRAN 2023

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

GERÇEK ZAMANLI STRATEJİ OYUNU İÇİN
MİKRO YÖNETİM YAPAY ZEKASI

YÜKSEK LİSANS TEZİ

Suat ÖZCAN

2000006019

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Doç. Dr. Akhan AKBULUT

Jüri Üyesi: Prof. Dr. Güray YILMAZ

Jüri Üyesi: Dr. Öğr. Üyesi Öznur ŞENGEL

HAZİRAN 2023

ÖNSÖZ

Tez çalışmamdaki katkıları ve desteğinden dolayı değerli tez danışmanım Doç. Dr. Akhan AKBULUT'a çok teşekkür ederim. Her zaman yanımda olan aileme çok teşekkür ederim.



Haziran 2023

Suat ÖZCAN

İÇİNDEKİLER

ÖNSÖZ.....	i
KISALTMALAR	iv
TABLO LİSTESİ	v
ŞEKİL LİSTESİ.....	vi
ÖZET.....	xi
ABSTRACT	xii
1. GİRİŞ	1
1.1. Problemin Tanımı	1
1.2. Tezin Organizasyonu	1
2. TEMEL BİLGİLER VE LİTERATÜR TARAMASI	2
2.1. Temel Bilgiler	2
2.2. Literatür Taraması	7
2.2.1. Gerçek Zamanlı Strateji Terimleri	8
2.2.2. İlgili Çalışmalar.....	9
3. YÖNTEM.....	12
3.1. Sistematik Literatür Taraması	13
3.1.1. AS-1: Hangi yapay zeka metodu kullanılmıştır?	15
3.1.2. AS-2: Hangi öğrenme metodu kullanıldı?	16
3.1.3. AS-3: Hangi yapay öğrenme sistemi kullanıldı, hangi başarı metriği uygun görüldü, derin öğrenme kullanıldı mı, hangi ödül uygun görüldü?	16
3.1.4. AS-4: Birliklerin teker teker yönetimi mi ele alınıyor, yoksa birlikler grup olarak mı kontrol edildi?	17
3.1.5. AS-5: Makale mikro yönetim veya makro yönetim üzerine mi?	18
3.1.6. AS-6: Başarı kriteri nedir?	19
3.1.7. AS-7: Hangi veriler algoritmayı eğitmek için kullanıldı?.....	20
3.1.8. AS-8: Hangi ortam kullanıldı?	20
3.1.9. Engeller	21
3.1. Veri Kümesi	24
3.2.1. Terran Kayıtlarının Hazırlanışı	24
3.2.2. Zerg Kayıtlarının Hazırlanışı	25
3.2.3. Terran Veri Kümesinin Hazırlanışı	26
3.2.4. Zerg Veri Kümesinin Hazırlanışı	27
3.3. Önerilen Yapay Öğrenme Modelleri.....	31
3.3.1. İleri Beslemeli Sinir Ağı	31
3.3.2. Uzun Kısa Vadeli Hafıza Ağılı Özyinelemeli Sinir Ağı	36
3.3.3. 1B Konvolüsyonel Model	41
4. BULGULAR.....	47
4.1. İleri Beslemeli Sinir Ağı.....	48

4.2.	Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı.....	72
4.3.	1B Konvolüsyonel Model.....	96
5.	TARTIŞMA	121
6.	GEÇERLİLİĞE TEHDİTLER.....	135
6.1.	İçsel Tehditler	135
6.2.	Dışsal Tehditler	135
7.	SONUÇ.....	136
	KAYNAKÇA	137
	EK1. LİTERATÜR TARAMASINDA KEŞFEDİLEN ENGELLER VE ÖNERİLEN ÇÖZÜMLER.....	139
	EK2. SLR ÇALIŞMASINDA SEÇİLEN YAYINLAR.....	142



KISALTMALAR

RNN:	Özyinelemeli Sinir Ağı (Recurrent Neural Network)
LSTM:	Uzun Kısa Vadeli Hafıza Ağları (Long-Short Term Memory)
CNN:	Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
ROC:	İşlem Karakteristik Eğrileri (Receiver Operating Characteristics)
AUC:	ROC Eğrisinin Altında Kalan Kısım (Area Under the Curve)
API:	Uygulama Geliştirme Arayüzü (Application Programming Interface)
BWAPI:	Broodwar Uygulama Geliştirme Arayüzü, Starcraft yapay zekası yazmak için kullanılan arayüz.

TABLO LİSTESİ

Tablo 3.1 Araştırma Soruları.....	13
Tablo 3.2 Kalite Değerlendirmesi Puanlama Tablosu	14
Tablo 3.3 Zerg Birliklerinin Menzilleri	29
Tablo 3.4 Zerg Birliklerinin Menzillerine Göre Sınıflandırması	29
Tablo 3.5 Terran Birliklerinin Menzilleri	30
Tablo 3.6 Terran Birliklerinin Menzillerine Göre Sınıflandırması	30
Tablo 5.1 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması.....	122
Tablo 5.2 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması	123
Tablo 5.3 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması.....	124
Tablo 5.4 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması	125
Tablo 5.5 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması	126
Tablo 5.6 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Temel Sınıflandırma ve Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması	127
Tablo 5.7 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması	128
Tablo 5.8 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Temel Sınıflandırma ve Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması	129
Tablo 5.9 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması..	130
Tablo 5.10 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Temel Sınıflandırma ve Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması.....	131
Tablo 5.11 1B Konvolüsyonel Modelde Terran Verilerinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması..	132
Tablo 5.12 1B Konvolüsyonel Modelde Terran Verilerinin Temel Sınıflandırma ve Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması.....	133
Tablo A.1 Literatür Taramasında Keşfedilen Engeller ve Çözümler	139

ŞEKİL LİSTESİ

Şekil 2.1 Starcraft Oyununda Zerg Üssü.....	3
Şekil 2.2 Zerg'e Karşı Terran Çatışma Görüntüsü.....	4
Şekil 3.1 Araştırma Metodolojisi	12
Şekil 3.2 Makale Puanları	14
Şekil 3.3 Makale Türleri	15
Şekil 3.4 Makro ve Mikro Yönetim Üzerine Makaleler	19
Şekil 3.5 Algoritmayı Eğitmek için Kullanılan Veriler.	20
Şekil 3.6 İleri Beslemeli Sinir Ağı Zerg Modelinin Özeti	32
Şekil 3.7 İleri Beslemeli Sinir Ağı Terran Modelinin Özeti	33
Şekil 3.8 İleri Beslemeli Sinir Ağı Menzıl Sınıflandırması Zerg Modelinin Özeti ...	34
Şekil 3.9 İleri Beslemeli Sinir Ağı Menzıl Sınıflandırması Terran Modelinin Özeti	35
Şekil 3.10 İleri Beslemeli Sinir Ağı Zerg Modeli	36
Şekil 3.11 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Zerg Modelinin Özeti	37
Şekil 3.12 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Terran Modelinin Özeti	38
Şekil 3.13 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Zerg Menzıl Sınıflandırması Modelinin Özeti	39
Şekil 3.14 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Terran Menzıl Sınıflandırması Modelinin Özeti	40
Şekil 3.15 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modeli	41
Şekil 3.16 1B Konvolüsyonel Zerg Modelinin Özeti.....	42
Şekil 3.17 1B Konvolüsyonel Terran Modelinin Özeti	43
Şekil 3.18 1B Konvolüsyonel Zerg Menzıl Sınıflandırması Modelinin Özeti.....	44
Şekil 3.20 1B Konvolüsyonel Terran Menzıl Sınıflandırması Modelinin Özeti	45
Şekil 3.21 1B Konvolüsyonel Model	46
Şekil 4.1 İleri Beslemeli Sinir Ağı Modelinde Zerg Hata Dizeyi	49
Şekil 4.2 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sınıflandırma Raporu	50
Şekil 4.3 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin ROC Eğrileri ve AUC Alanları	51
Şekil 4.4 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzıl Hata Dizeyi	52
Şekil 4.5 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzıl Sınıflandırma Raporu	53
Şekil 4.6 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin ROC Eğrileri ve AUC Alanları	53
Şekil 4.7 İleri Beslemeli Sinir Ağı Zerglerin Yakın Menzıl Hata Dizeyi	54
Şekil 4.8 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Yakın Menzıl Sınıflandırma Raporu	55
Şekil 4.9 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sadece Havadan Havaya Saldıranlar Hata Dizeyi	55
Şekil 4.10 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sadece Havadan Havaya Saldıranlar Sınıflandırma Raporu	56

Şekil 4.11 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Uzun Menzil Hata Dizeyi.....	56
Şekil 4.12 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Uzun Menzil Sınıflandırma Raporu	57
Şekil 4.13 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Büyücü Hata Dizeyi	58
Şekil 4.14 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Büyücü Sınıflandırma Raporu	58
Şekil 4.15 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Detaylı Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları	59
Şekil 4.16 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesi Hata Dizeyi ...	60
Şekil 4.17 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Sınıflandırma Raporu	61
Şekil 4.18 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin ROC Eğrileri ve AUC Alanları	62
Şekil 4.19 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Hata Dizeyi	63
Şekil 4.20 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Sınıflandırma Raporu	64
Şekil 4.21 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin ROC Eğrileri ve AUC Alanları	64
Şekil 4.22 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Yakın Menzil Hata Dizeyi	65
Şekil 4.23 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Yakın Menzil Sınıflandırma Raporu.....	66
Şekil 4.24 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Yer Birliklerinin Hata Dizeyi.....	66
Şekil 4.25 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Yer Birliklerinin Sınıflandırma Raporu	67
Şekil 4.26 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Hava Birliklerinin Hata Dizeyi	68
Şekil 4.27 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Hava Birliklerinin Sınıflandırma Raporu	69
Şekil 4.28 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Uzun Menzilli Yer Birliklerinin Hata Dizeyi	69
Şekil 4.29 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Uzun Menzilli Yer Birliklerinin Sınıflandırma Raporu.....	70
Şekil 4.30 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Büyücü Birliklerinin Hata Dizeyi.....	70
Şekil 4.31 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Büyücü Birliklerinin Sınıflandırma Raporu	71
Şekil 4.32 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Detaylı Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları	72
Şekil 4.33 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Hata Dizeyi.....	73
Şekil 4.34 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sınıflandırma Raporu	74

Şekil 4.35 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin ROC Eğrileri ve AUC Alanları	75
Şekil 4.36 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzil Hata Dizeyi.....	76
Şekil 4.37 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzil Sınıflandırma Raporu	76
Şekil 4.38 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzil ROC Eğrileri ve AUC Alanları	77
Şekil 4.39 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Yakın Menzil Hata Dizeyi.....	78
Şekil 4.40 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Yakın Menzil Sınıflandırma Raporu	78
Şekil 4.41 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sadece Havadan Havaya Saldıranlar Hata Dizeyi.....	79
Şekil 4.42 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sadece Havadan Havaya Saldıranlar Sınıflandırma Raporu	80
Şekil 4.43 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Uzun Menzil Hata Dizeyi.....	80
Şekil 4.44 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Uzun Menzil Sınıflandırma Raporu	81
Şekil 4.45 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Büyücü Hata Dizeyi	81
Şekil 4.46 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Büyücü Sınıflandırma Raporu	82
Şekil 4.47 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Detaylı Menzil Sınıflamasının ROC Eğrileri ve AUC Alanları	83
Şekil 4.48 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Hata Dizeyi.....	84
Şekil 4.49 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Sınıflandırma Raporu	85
Şekil 4.50 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin ROC Eğrileri ve AUC Alanları	86
Şekil 4.51 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Hata Dizeyi.....	87
Şekil 4.52 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Sınıflandırma Raporu	88
Şekil 4.53 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil ROC Eğrileri ve AUC Alanları	88
Şekil 4.54 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Yakın Menzil Hata Dizeyi	89
Şekil 4.55 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Yakın Menzil Sınıflandırma Raporu.....	90
Şekil 4.56 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Yer Birliklerinin Hata Dizeyi	90
Şekil 4.57 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Yer Birlikleri Sınıflandırma Raporu	91

Şekil 4.58 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Hava Birliklerinin Hata Dizeyi	92
Şekil 4.59 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Hava Birlikleri Sınıflandırma Raporu.....	93
Şekil 4.60 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Uzun Menzilli Yer Birliklerinin Hata Dizeyi	93
Şekil 4.61 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Uzun Menzilli Yer Birlikleri Sınıflandırma Raporu.....	94
Şekil 4.62 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Büyücü Birliklerinin Hata Dizeyi.....	94
Şekil 4.63 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Büyücü Birlikleri Sınıflandırma Raporu	95
Şekil 4.64 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Detaylı Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları	96
Şekil 4.65 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Hata Dizeyi.....	97
Şekil 4.66 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Zerglerin Sınıflandırma Raporu	98
Şekil 4.67 1B Konvolüsyonel Modelde Zerg Veri Kümesinin ROC Eğrileri ve AUC Alanları.....	99
Şekil 4.68 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Menzil Hata Dizeyi	100
Şekil 4.69 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Menzil Sınıflandırma Raporu	100
Şekil 4.70 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları	101
Şekil 4.71 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Yakın Menzil Hata Dizeyi	102
Şekil 4.72 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Yakın Menzil Sınıflandırma Raporu	102
Şekil 4.73 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Sadece Havadan Havaya Saldıranlar Hata Dizeyi.....	103
Şekil 4.74 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Sadece Havadan Havaya Saldıranlar Sınıflandırma Raporu	104
Şekil 4.75 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Uzun Menzil Hata Dizeyi	104
Şekil 4.76 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Uzun Menzil Sınıflandırma Raporu	105
Şekil 4.77 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Büyücü Hata Dizeyi	105
Şekil 4.78 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Büyücü Sınıflandırma Raporu	106
Şekil 4.79 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Detaylı Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları	107
Şekil 4.80 1B Konvolüsyonel Modelde Terran Verilerinin Hata Dizeyi.....	108
Şekil 4.81 1B Konvolüsyonel Modelde Terran Verilerinin Sınıflandırma Raporu .	109
Şekil 4.82 1B Konvolüsyonel Modelde Terran Verilerinin ROC Eğrileri ve AUC Alanları.....	110
Şekil 4.83 1B Konvolüsyonel Modelde Terran Verilerinin Menzil Hata Dizeyi	111

Şekil 4.84 1B Konvolüsyonel Modelde Terran Verilerinin Menzil Sınıflandırma Raporu	112
Şekil 4.85 1B Konvolüsyonel Modelde Terran Verilerinin Menzil ROC Eğrileri ve AUC Alanları	112
Şekil 4.86 1B Konvolüsyonel Modelde Terran Verilerinin Çok Yakın Menzil Hata Dizeyi	113
Şekil 4.87 1B Konvolüsyonel Modelde Terran Verilerinin Çok Yakın Menzil Sınıflandırma Raporu	114
Şekil 4.88 1B Konvolüsyonel Modelde Terran Verilerinin Orta Menzilli Yer Birliklerinin Hata Dizeyi.....	114
Şekil 4.89 1B Konvolüsyonel Modelde Terran Verilerinin Orta Menzilli Yer Birliklerinin Sınıflandırma Raporu	115
Şekil 4.90 1B Konvolüsyonel Modelde Terran Verilerinin Orta Menzilli Hava Birliklerinin Hata Dizeyi.....	116
Şekil 4.91 1B Konvolüsyonel Modelde Terran Verilerinin Orta Menzilli Hava Birliklerinin Sınıflandırma Raporu	117
Şekil 4.92 1B Konvolüsyonel Modelde Terran Verilerinin Çok Uzun Menzilli Yer Birliklerinin Hata Dizeyi.....	117
Şekil 4.93 1B Konvolüsyonel Modelde Terran Verilerinin Çok Uzun Menzilli Yer Birliklerinin Sınıflandırma Raporu	118
Şekil 4.94 1B Konvolüsyonel Modelde Terran Verilerinin Büyücü Birliklerinin Hata Dizeyi	118
Şekil 4.95 1B Konvolüsyonel Modelde Terran Verilerinin Büyücü Birliklerinin Sınıflandırma Raporu	119
Şekil 4.96 1B Konvolüsyonel Modelde Terran Verilerinin Detaylı Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları	120

Üniversite	: T.C. İstanbul Kültür Üniversitesi
Enstitü	: Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	: Bilgisayar Mühendisliği
Program	: Bilgisayar Mühendisliği
Tez Danışmanı	: Doç. Dr. Akhan AKBULUT
Tez Türü ve Tarihi	: Yüksek Lisans – Haziran 2023

ÖZET

GERÇEK ZAMANLI STRATEJİ OYUNU İÇİN MİKRO YÖNETİM YAPAY ZEKASI

Satranç ve GO oyunlarından daha fazla durum ve eylem alanına sahip gerçek zamanlı strateji oyunlarında uygulanan sabit kodlama ve senaryolu davranış bu alanın yapay zeka ihtiyacını karşılamıyorlar. Başarılı bir yapay zeka yaratmak için farklı yöntemler deneniyor. Bu yöntemlerden biri de yapay öğrenmedir. Gözetimli ve gözetimsiz metotlarla bu geniş durum ve eylem alanında başarılı sonuçlar elde edilmeye başlandı. Gerçek zamanlı strateji oyunlarını oluşturan öznitelikler değerlendirilerek öğrenme modellerine uygun öznitelikler keşfediliyor. Çalışma alanları daraltılıyor ve bu türün bir noktasına odaklanıyor. Bu çalışmada eğitim modellerini eğitecek veri kümesi için öznitelikler sistematik literatür taraması sonucu belirledik. Araştırma ortamını dengeli oyun mekanikleri ile Starcraft seçtik. Oyundaki durumu ve eylemi net ve açık şekilde kayda alan veri tabanından gerekli öznitelikler çıkardık. Bu özniteliklerin belirlediği her bir durumda Zerg ve Terran oyuncusunun hamlelerini veri kümesine işledik. Bu veri kümeleri ile 3 farklı model eğittik. Bu modeller ileri beslemeli sinir ağı modeli, uzun kısa vadeli hafıza ağılı özyinelemeli model ve 1B konvolüsyonel modelden oluşur. Ardından oyundaki birlikler menzillerine göre sınıflara ayırdık ve modelleri tekrar eğittik. Bulgular sunduk ve karşılaştırdık. Menzil sınıflandırmasının Zerg ırkı için daha başarılı sonuçlar verdiğini gördük. Zerg veri kümesi için yüksek f1 puanları ve AUC alanları sebebi ile uzun kısa vadeli hafıza ağılı özyinelemeli sinir ağı modelinin ve Terran veri kümesi için ileri beslemeli sinir ağı modelinin en iyi model olduğuna karar verdik.

Anahtar Kelimeler: Gerçek Zamanlı Strateji, Yapay Öğrenme, Derin Öğrenme, Yapay Sinir Ağları, Yapay Zeka, Mikro Yönetim

University	: T.C. Istanbul Kültür University
Institute	: Institute of Sciences
Department	: Computer Engineering
Program	: Computer Engineering
Thesis Advisor	: Assoc. Prof. Akhan AKBULUT
Degree Awarded and Date	: MA – June 2023

ABSTRACT

MICRO MANAGEMENT ARTIFICIAL INTELLIGENCE FOR A REAL-TIME STRATEGY GAME

Hard-coded artificial intelligence methods and scripts do not meet the demands of real-time strategy games, which have a larger state and action space than chess and GO games. Various methods are considered to create successful artificial intelligence. One of these methods is machine learning. By utilizing supervised and unsupervised methods, successful results are obtained in this enormous state and action space. The features that construct real-time strategy games are inspected, and the ones that are suitable for particular models are discovered. The research field is narrowed and focuses on a particular part of this genre. In this research, features of the dataset that is going to train machine learning models are decided after performing a systematic literature review. We chose Starcraft as the research environment because of its balanced game mechanics. We extracted the necessary features from the dataset, which contains clearly and precisely recorded states and actions. Each state holds the values of these features in the datasets, and in each of these states, we recorded the actions of Zerg and Terran players. We trained three different machine learning models with the datasets. These models are a feed-forward neural network, a recurrent neural network model with long-short-term memory, and a 1D convolutional model. In addition to this, we classified units in the game according to their ranges, and we trained the models again. We present the discoveries and compare them. We have seen that range classification yields better results for the Zerg race. Because of the high f1 scores and AUC areas, we decided that the recursive neural network model with long short-term memory is the best one for the Zerg dataset, and the feed-forward neural network model is the best model for the Terran dataset.

Keywords: Real-time Strategy, Machine Learning, Deep Learning, Artificial Neural Networks, Artificial Intelligence, Micro Management

1. GİRİŞ

Gerçek zamanlı strateji oyunları oyuncuların gerçek zamanda kaynak planlaması yapıp, binalar kurup, rakiplerine karşı ordular yöneterek oynadıkları popüler bir oyun türüdür. Bu oyunların karakteri stratejik ve taktiksel oyun elemanlarının harmanlanması ile belirlenir. Oyuncular sınırlı bilgi ile hızlı kararlar verirken, uzun dönem planlama da yaparlar. Gerçek zamanlı strateji oyunlarının bilinirliği arttıkça, bu oyunlar üzerine yapılan araştırmalar da artmıştır.

Bilgisayarların işlem kapasitelerinin gelişmesi ile birlikte yapay zeka alanında araştırmalar hız kazandı. İnsanların çağlar boyunca oynadıkları oyunlar yapay zekalara kodlanmış ve dünya şampiyonlarını yenmişlerdir. Bu alanda başarı çitası her gün yükselmektedir. Satranç ve GO şampiyonlarının bilgisayar tarafından yenilmesinin ardından yeni seviyeyi gerçek zamanlı strateji oyunları belirlemektedir. Klasik olarak uygulanan sabit kodlu yaklaşımlar bu alanın ihtiyaçlarını karşılamıyorlar (**Zhen, Wanpeng, & Hongfu, 2018**). İnsani karar vermeye yakın yapay zekaya ihtiyaç vardır.

1.1. Problemin Tanımı

Gerçek zamanlı strateji oyunları devasa durum ve eylem alanında oynandığı için sabit kod ve senaryolu yapay zeka yöntemleri ile başarılı sonuçlar alınması zordur. Bu geniş alanda uygun kararları verebilen, oyuncunun hamlelerine uyum sağlayıp doğru hamle yapabilen yapay zeka için gerçek zamanlı strateji oyunları incelenerek yapay öğrenme modelleri öneriliyor.

1.2. Tezin Organizasyonu

İlk önce gerçek zamanlı strateji oyun türü ve araştırma alanı olarak seçilen Starcraft oyunu tanıtılıyor. Ardından konu üzerine yapılan araştırmalar ve sistematik literatür taraması sunuluyor. Yöntem bölümünde sistematik literatür taramasında keşfedilen faydalı modeller ve faydası görülen veri kümesi öznitelikleri incelenerek Starcraft oyunları veri tabanından bu özellikler çıkartılarak yapay sinir ağlarında kullanılacak veri kümeleri elde ediliyor. Ardından 3 farklı yapay sinir ağı modeli sunuluyor. Bulgular bölümünde eğitim sonucunda elde edilen veriler sunuluyor. Tartışma bölümünde elde edilen bulgular değerlendiriliyor. Sonuç bölümünde tartışmada değerlendirilen kararlar özetleniyor.

2. TEMEL BİLGİLER VE LİTERATÜR TARAMASI

2.1. Temel Bilgiler

Gerçek zamanlı strateji türünde oyuncular işçilerle oyundaki kaynakları toplayarak, ardından bu kaynakları harcayarak, işçi veya askeri birlik çıkartırlar. Askeri birliklerin farklı özellikleri bulunur, menzilleri, canları, ateş güçleri farklıdır. Bu birlikleri yaratmak için oyuncular binalar kurar ve teknolojilerini geliştirirler. Rakibin bütün binaları yok eden oyunu kazanır. Oyundaki duruma uygun olan birlik kompozisyonları yaratmak önemlidir. Satrançta bir oyuncu hamle yaptıktan sonra diğer oyuncunun hamle yapmasını bekler ve oyun sıra ile ilerler, bu yüzden bu oyun türü sıra tabanlı stratejidir. Gerçek zamanlı strateji oyunlarında oyuncu hamleleri sürekli olarak, zaman devam ederken, diğer oyuncudan bağımsız gerçekleştirilir. Gerçek zamanlı strateji adını buradan alır. Makro yönetim kaynak toplamasını ve harcamasını planlamak, üretilecek birlikleri tercih etmek ve uzun vadeli stratejileri belirlemeyi kapsar. Mikro yönetim birliklerin menzil, hız, can puanları ve konumlarının kullanılmasının planlanmasıdır.

Araştırma ortamı olarak meşhur gerçek zamanlı strateji oyunu Starcraft seçildi. Oyunda oyuncular Terran, Zerg ve Protoss ırklarından birini seçerek oyunu oynarlar. Bu ırkların özellikleri birbirlerinden tamamen farklı olmasına rağmen güçleri dengelidir. Oyunda bolca bulunan kaynak mineral, daha az bulunan kaynak gazdır. Bu çalışmada Terran'a karşı Zerg oyunları incelendi. Terranlar yüksek ateş gücüne ve uzun menzile sahipken Zerglerin birlik sayısı üstünlüğü vardır. Starcraft oyun alanını anlamak için diğer strateji oyunları ile karşılaştırabiliriz. Satranç oyununun dallanma faktörü 35 ve derinlik faktörü 80, GO oyununun dallanma faktörü 30-300 arası ve derinlik faktörü 150-200 arasında tahmin edilirken, Starcraft'ta dallanma faktörü 10^{50} - 10^{200} arasında ve derinlik faktörü 36000 varsayılıyor (Santiago Ontañón, 2013).

Starcraft oyunu haritaya yukarıdan bir bakış açısı ile oynanır. Oyundan bir görüntü Şekil 2.1'de verilmiştir (Liquipedia, Liquipedia, 2008). Ekranın büyük alanını kaplayan bölge oyuncunun fare ile birlikleri seçtiği ve onlara komutlar verdiği bölümdür. Sağ alta komut kartı bulunur buradan simgelere tıklayarak oyuncu birliğe bir konuma hareket etmesi, başka bir birliğe saldırması veya durması vb. komutları verir. Şekil 2.1'de Zergling birliklerinin yeşil çember içinde bulunması, şu anda

oyuncunun bu birlikleri seçtiğini gösterir. Bu sebeple Zerglingler komut kartından verilen emri uygulamaktadırlar. Komut kartında sola doğru ok beyaz olduğu için, bu birliklere hareket etme komutu verilmiştir ve Şekil 2.1’de hareket emri verilen konuma hareket etmektedirler. Oyuncu fareyi ekranın sol, sağ, alt ve üst bölgesine götürerek haritanın diğer alanlarını görebilir. Ekranda gördüğümüz sadece tam haritanın bir kesimidir. Sol altta mini harita bulunur, burada bütün haritanın küçük bir versiyonu gözükür. Mini haritada beyaz kare içindeki alan ekranın büyük kısmını kaplayan bölümün haritadaki konumudur. Mini haritadaki yeşil noktalar oyuncunun birlikleridir. Ekranın orta alt kesiminde hangi birliklerin seçildiği gözükür. Şekil 2.1’de 6 tane Zerg Zergling birliğinin seçildiği gözükür. Bu birlikler oyun alanında yeşil çember içindedirler.



Şekil 2.1 Starcraft Oyununda Zerg Üssü

Oyuncular oyuna bir üs ve 4 işçi ile başlar. İşçiler kaynakları toplarlar. Kaynaklar mineral ve gazdır. Şekil 2.1’in orta sol tarafında işçiler mineral toplarken gözükmektedirler. Mineral bolca bulunurken gaz kaynakları ender bulunur. Her birlik farklı bir fiyatı vardır. Bir birlik üretildiğinde birliğin fiyatı toplanan kaynaklardan düşülür. Şekil 2.1’de sağ üstte sırası ile kaynaklar gözükür. Şekil 2.1’de gösterilen

anda oyuncuda 50 mineral ve 0 gaz vardır. Sağ üstte en sağda tedarik sınırı gözüktür. Şu anda oyuncunun 11 tedarik puanı vardır ve 17 tedarik puanına kadar çıkabilir. Her birliğin farklı bir tedarik puanı vardır. Herhangi bir birlik üretildiğinde üretilen birliğin tedarik puanı toplam tedarik puanına eklenir. Tedarik sınırını arttırmak için Zerg ırkı Overlord birliğini, Terran ırkı Supply Depot birliğini üretir. Tedarik puanı sınırı 200 değerindedir.



Şekil 2.2 Zerg'e Karşı Terran Çatışma Görüntüsü

Şekil 2.2'de Starcraft'ta bir çatışma sahnesi gözüktür (Liquipedia, Liquipedia, 2016). Zerg'e karşı Terran oyunudur. Ekranın üst kısmında bulunan sarı renkli birlikler Zerg birlikleri, alttaki mor renkli birlikler Terran birlikleridir. Ekranın orta altında seçili Zerg Hydralisk birliğinin can puanı gözüktür. Şu an can puanı 80 üzerinden 80 değerindedir, henüz hasar almamıştır. Seçili Zerg Hydralisk oyun alanında yeşil çember içinde gözükmemektedir. Her birliğin can puanı 0 değerine ulaştığında yok olur ve oyundan çıkar. Rakibin bütün binalarını yok eden oyunu kazanır.

Zerg Zergling 50 mineral ve 1 tedarik puanı fiyatına ikişer tane üretilir, 35 can puanına sahip hızlı bir birliktir. 35 can puanına sahiptir. Sadece karadan temas

ettiği birliklere saldırabilir. Verdiği hasar 5 değerindedir. Saniye başına verdiği hasar 14,88 değerindedir. Zerg Hydralisk 75 mineral, 25 gaz ve 1 tedarik puanı fiyatına sahiptir. 80 can puanı vardır. Hem havaya hem karaya saldırabilir. Menzili 4 değerindedir. Hasarı 10 değerindedir. Saniye başına verdiği hasar 15,87 değerindedir. Zerg Ultralisk 200 mineral, 200 gaz ve 4 tedarik puanı fiyatına sahip bir birliktir. 400 can puanına sahiptir. Sadece karadan temas ettiği birliklere saldırabilir. Temas ettiğinde yay şeklinde bir alan hasar verir. Verdiği hasar 20 değerindedir. Saniye başına verdiği hasar 31,75 değerindedir. Hızlı bir saldırgandır. Zerg Mutalisk 100 mineral, 100 gaz, 2 tedarik puanı fiyatına sahiptir. Hızlı bir birliktir. 120 can puanına sahiptir. Menzili 3 değerindedir. Verdiği hasar 9 değerindedir. Saniye başına verdiği hasar 7,14 değerindedir. Uçan birliktir. Kara birliklerinin geçemediği yükseltilerin üzerinden uçabilir. Bu sayede, yükselti alanlara kara yolundan gitmeden daha çabuk erişebilir. Zerg Scourge 25 mineral, 75 gaz ve 1 tedarik puanı fiyatına ikişer tane üretilir. 25 can puanına sahiptir. Sadece uçan birliklere saldırabilir. Uçan birliktir. Saldırdığında yok olur. Verdiği hasar 100 değerindedir. Zerg Devourer, Zerg Mutalisk'in dönüşebileceği birliklerden biridir. 150 mineral, 50 gaz fiyatına sahiptir. 250 can puanına sahiptir. Uçan birliktir. Sadece uçan birliklere saldırabilir. 6 menzile değerine ve 25 hasar değerine sahiptir. Saniye başına verdiği hasar 5,95 değerindedir. Yavaş bir saldırgandır. Zerg Guardian, Zerg Mutalisk'in dönüşebileceği birliklerden biridir. 50 mineral, 100 gaz fiyatına sahiptir. Uçan birliktir. 150 can puanı vardır. Sadece kara birliklerine saldırabilir. 8 menzil değerine sahiptir. Verdiği hasar 20 değerindedir. Saniye başına verdiği hasar 15,87 değerindedir. Zerg Lurker, Zerg Hydra'nın dönüşebileceği birliktir. 50 mineral, 100 gaz ve 1 tedarik puanı fiyatına sahiptir. 125 can puanı vardır. Menzili 6 değerindedir. Verdiği hasar 20 değerindedir. Saniye başına verdiği hasar 12,87 değerindedir. Zerg Queen 100 mineral, 100 gaz ve 2 tedarik puanı fiyatına sahiptir. Büyücü birliğidir, diğer birliklere direk olarak saldırmaz. Büyücü birlikleri büyülerini yapabilmek için enerjiye ihtiyaç duyar. Enerjileri zamanla dolar. Infest Command Center büyüü ile Terran Command Center'ı enfekte edebilir. Parasite büyüü ile rakibin bir birliğinin görüş alanını görebilir. Spawn Broodling büyüü ile rakibin bir birliğinin yok edip ondan iki tane Broodling birlikleri çıkartabilir. Broodlingler 30 can puanına sahiptir ve verdikleri hasar 4 değerindedir. Saniye başına verdiği hasar 6,35 değerindedir. Ensnare büyüü ile rakibin hareket hızlarını ve ateş hızlarını 22,5 saniye boyunca yavaşlatabilir. Zerg Defiler 50 mineral, 150 gaz ve 2 tedarik puanı puanına sahiptir. Can puanı 80

değerindedir. Büyücü birliğidir. Consume büyüü ile oyuncunun başka bir birliğini yok ederek kendisine enerji katabilir. Plague büyüü ile rakibin biyolojik birliklerine 25,2 saniye boyunca saniyede 11,74 hasar puanı verir. Dark Swarm büyüü ile birlikleri menzilli ateş hasarından korur.

Terran Marine 50 mineral ve 1 tedarik puanı fiyatına sahiptir. 40 cana sahiptir. Menzili 4 değerindedir. Verdiği hasar 6 değerindedir. Saniye başına verdiği hasar 9,52 değerindedir. Hem karaya hem havaya saldırabilir. Genel amaçlı kullanılır. Terran Ghost 25 mineral, 75 gaz ve 1 tedarik puanı fiyatına sahiptir. Hem büyücü hem de saldıran birliktir. 45 can puanı vardır. Menzili 7 değerindedir. Verdiği hasar 10 değerindedir. Saniye başına verdiği hasar 10,82 değerindedir. Personal Cloaking büyüü ile görünmez olabilir. Lockdown büyüü ile rakibin mekanik birliklerini 44,1 saniye boyunca hareketsiz ve ateş edemez hale getirebilir. Nuclear Strike ile geniş bir alanda 500 hasar puanı verebilir. Terran Vulture 75 mineral ve 2 tedarik puanı fiyatına sahiptir. Hızlı bir birliktir. Sadece kara birliklerine saldırabilir. Can puanı 80 değerindedir. Menzili 5 değerindedir. Verdiği hasar 20 değerindedir. Saniye başına verdiği hasar 15,87 değerindedir. Her bir Terran Vulture 3 Spider Mine yerleştirebilir. Terran Spider Mine birlikleri temasta 125 alan etkili hasar verirler. Terran Goliath 100 mineral, 50 gaz ve 2 tedarik puanı fiyatına sahiptir. Can puanı 125 değerindedir. Hem kara birliklerine hem hava birliklerine saldırabilir. Kara menzili 6 değerinde ve hava menzili 5 değerindedir. Verdiği kara hasarı 12 ve verdiği hava hasarı 20 değerindedir. Saniye başına kara birliklerine verdiği hasar 12,99 ve hava birliklerine verdiği hasar 21,64 değerindedir. Terran Siege Tank 150 mineral, 100 gaz ve 2 tedarik puanı fiyatına sahiptir. Can puanı 150 değerindedir. Menzili 7 değerindedir. Verdiği hasar 30 değerindedir. Saniye başına verdiği hasar 19,31 değerindedir. Kuşatma moduna geçip menzilini 12 değerine çıkartabilir. Kuşatma modunda alan etkili hasar verir. Kuşatma modunda 70 hasar değerine sahiptir. Saniye başına 22,22 değerinde hasar verir. Aynı zamanda kuşatma modunda en düşük menzili 2 değerine iner. Bu yüzden temas ile kendisine hasar veren birliklere hasar veremez. Terran Wraith 150 mineral, 100 gaz ve 2 tedarik puanı değerine sahiptir. 120 can puanı vardır. Menzili 5 değerindedir. Uçan birliktir. Hava birliklerine verdiği hasar 20 ve yer birliklerine verdiği hasar 8 değerindedir. Saniye başına kara birliklerine verdiği hasar 6,35 ve hava birliklerine verdiği hasar 21,65 değerindedir. Hızlı bir birliktir. Terran Science Vessel 100 mineral, 225 gaz ve 2 tedarik puanı fiyatına sahiptir. Can puanı 200 değerindedir. Büyücü

birliktir. Defensive Matrix büyüğü ile herhangi bir birliğe fazladan 250 can puanı verebilir. Irradiate büyüğü ile hedef biyolojik birliğe ve onun etrafındaki biyolojik birliklere 25,2 saniyede 249 hasar puanı verebilir. EMP Shockwave büyüğü ile birliklerin kalkanlarını ve enerji puanlarını tüketebilir. Terran Dropship 100 mineral, 100 gaz ve 2 tedarik puanı fiyatına sahiptir. Diğer Terran birliklerini içine alıp taşır. Uçan birliktir. Can puanı 150 değerindedir. Terran Battlecruiser 400 mineral, 300 gaz ve 6 tedarik puanına sahiptir. Can puanı 500 değerindedir. Uçan birliktir. Menzili 6 değerindedir. Hava birliklerine ve kara birliklerine verdiği hasar 25 değerindedir. Saniye başına hem kara hem hava birliklerine verdiği hasar 19,84 değerindedir. Terran Nuclear Missile Terran Ghost tarafından ateşlenir. Geniş bir alanda 500 hasar puanı verir. Terran Firebat 50 mineral, 25 gaz ve 1 tedarik puanı fiyatına sahiptir. Can puanı 50 değerindedir. Sadece yer birliklerine saldırabilir. Menzili 2 değerindedir. Hasar puanı 24 değerindedir. Saniye başına verdiği hasar 17,32 değerindedir. Bir çizgi boyunca hasar verir. Terran Medic 50 mineral, 25 gaz ve 1 tedarik puanı fiyatına sahiptir. Hasarlı biyolojik birliklerin can puanlarını normal değerlerine kadar artırır. Can puanı 60 değerindedir. Terran Valkyrie 250 mineral, 125 gaz ve 3 tedarik puanı fiyata sahiptir. Uçan birliktir. Sadece hava birliklerine saldırabilir. Can puanı 200 değerindedir. Menzili 6 değerindedir. Verdiği hasar 48 değerindedir. Saniye başına verdiği hasar 17,86 değerindedir.

2.2. Literatür Taraması

Gerçek zamanlı strateji oyunları mükemmel olmayan bilgiye dayalı olarak oynandığı için, bu oyunları oynayabilen yapay zekalar gerçek hayat uygulamalarında kullanılmak için uygundur. Gerçek zamanlı strateji oyunları yapay zeka teknikleri için ideal bir sınamaya merkezidir. Satranç ve ardından GO oyununda yapay zekaların dünya şampiyonlarını yenmesinin ardından, şimdi sıradaki hedef daha büyük bir alan ve duruma sahip gerçek zamanlı strateji oyunlarında görülüyor.

Çalışmanın daha iyi anlaşılabilmesi için gerçek zamanlı strateji terimlerini öğrenmemiz faydalı olacaktır. Gerçek zamanlı strateji oyunlarında, oyun başında, bir ana bina ve bir miktar işçi ile oyuna başlanır. İşçiler kaynakları mineral, gaz ve altın gibi farklı kaynakları toplar. Bu kaynaklar birlikleri üretmek için gereklidir. Kaynaklar işçiler ve askerler üretilebilirler. Her bir birliğin farklı özellikleri vardır: Menzilli, yakın dövüşçü, farklı can puanları ve farklı hasar puanları. Oyunda amaç rakibin ordusunu yenecek bir orduyu, dikkatli kaynak ve strateji planlaması yapıp,

oluşturmaktır. Bir oyuncu rakibin bütün binalarını yok ederse oyunu kazanmış olur. Oyun haritasında sadece kendi birliklerimizin menzilineki alanı görebiliriz. Bu yüzden oyunda rakibin durumunu, ilerleyişini, birliğini sadece bir birliğin menziline girdiğinde anlayabiliriz. Bu yüzden oyun bilgisi satranç ve GO'daki gibi her bir oyuncunun her şeyi gördüğü gibi mükemmel değildir. Mükemmel olmayan bilgiye dayanır. Rakibi tahmin etmek önemlidir.

Gerçek zamanlı strateji oyununda birliklerin özellikleri birbirlerinden çok farklıdır. Bu birlikler az sayıda kombinasyonlanabilir veya büyük sayılara çıkabilirler. Birlik sayıları arttıkça, kombinasyonlar ve olası saldırı stratejileri de artar. Oyunun başında sadece küçük bir miktar birlik ile gerçekleşen eylemler, oyunun geri kalanına etki eder ve ardından gelen stratejileri belirler. Belli bir açılıştan sonra, bazı stratejiler daha ön plana çıkar, kimileri de dezavantajlı olurlar, ama oyun açıldıkça, oyuncu hataları ile dezavantajlar avantajlara dönüşebilir. Dezavantajlı oyuncu doğru birlikleri, doğru sayıda, doğru zamanda zekice üreterek oyunu kazanabilir. Mümkün olan birlik oluşumları ve konumları devasadır. Bu sebepten, bütün bu olası kombinasyonlar için çalışan bir yapay zeka sistemi yazmak, geliştiriciler için zordur. Bu yüzden, gerçek zamanlı strateji oyunları gerçek insanlarla oynandığında zevklidir. Oyunun durumunu kavrayabilen, gelecek durumları öngörebilen ve buna göre planlar yapan bir yapay zeka yaratmak için araştırmalar devam etmektedir.

2.2.1. Gerçek Zamanlı Strateji Terimleri

RTS: Real time strategy (Gerçek Zamanlı Strateji) kısaltmasıdır.

Birlik: Oyunda kullanabildiğimiz her bir işçiye, savaşçıya ve binaya birlik adı verilir. Her birliğin kendine has bir can puanı, hasar puanı ve bazılarının büyü güçleri vardır.

Can Puanı: Bir birlik üretildiğinde kendine has tam can puanı ile oyuna girer. Birlik hasar aldığı anda can puanından düşülür. Birliğin can puanı 0 değerine indiğinde yok olur ve oyundan çıkar.

Soğuma: Birliklerin saldırı ve büyü özellikleri bir kez kullanıldığında, tekrar kullanılabilmesi için geçmesi gereken süre.

Kaynak: Birlikleri üretmek için gerekli olan, işçiler tarafından toplanan altın, odun, mineral ve gaz gibi kaynaklara denir. Bazı kaynaklar bolca bulunurken, bazıları daha enderdir.

Menzil: Bir birliğin diğerk bir birliğe saldırıp, hasar verebilmesi için gereken minimum mesafedir.

Bina: Oyun bir bina ile başlar. Diğerk binalar işçiler tarafında yeterli kaynak toplandıktan sonra üretilirler.

Yükseltme: Birliklerin özelliklerini güçlendiren, elde edilmesi bir süre alan araştırmadır.

Makro: Oyunda esas olarak takip edilen strateji, kaynak planlaması, hangi birliklerin ne zaman üretileceğine karar verilmesi konularıdır.

Mikro: Birliklerin birbirleri ile hangi açıyla, hangi sıra ve düzen ile savaşacaklarının, menzile, konum ve hız özelliklerinin ayarlanmasıdır.

Üretim: Bir birliği üretmek için komut verildikten sonra bu birliğin oyunda yer alması için bir üretim süresi geçer.

Üretim sıralaması: Oyunun başından itibaren üretilen birlik, yükseltme ve binaların sırasıdır.

İrk: Oyuna başlamadan önce seçilen her birinin farklı özellikte birliklere, binalar ve teknoloji ağacına sahip olan seçenektir.

Teknoloji Ağacı: Kaynakları kullanarak sırası ile yeni teknolojilerin açılmasıdır. Yeni teknolojiler daha iyi özelliklere sahip birliklerin üretimini sağlarlar.

Replay: Oynanan oyunun bilgisayardaki kayıdır. Buradaki verilerle bütün oyun, en baştan bilgisayar tarafından oynatılır.

Savaş Sisi: Oyuncular sadece kendi birliklerinin görüş alanındaki haritayı görebilirler, geri kalan her yer, önceden bir birlik tarafından görülmüş olsa bile, savaş sisi denen karanlık ile kaplıdır.

2.2.2. İlgili Çalışmalar

Oyunların çoğunluğunda oyuncuya adapte olamayan, bir zaaf keşfedildiği zaman bu zaafi suistimal ederek yapay zekayı etkisiz hale getiren oyuncularla karşılaşılır (Marcel van der Heijden, 2008). Bu zaafi telafi etmek için çalışmalar yapıldı. Gerçek zamanlı strateji oyunlarında yapay zeka olarak ilk başlarda kural tabanlı sabit kodlu yapılar kullanıldı. Bu yapılar için oyunu çok iyi bilen her türlü

durum yazabilecek programcılar gerekliydi. Alan çok geniş olduğu için çok başarılı olmadı. Durum makineleri kullanıldı (**Jagdale, 2021**). Ama bu kadar büyük bir alanda başarılı olmadı. Ardından farklı yöntemler denendi. Monte-Carlo kara verme ağaçları bir ölçüde başarılı oldu (**Guillaume Chaslot, 2008**). Ardından durum tabanlı yöntemler denendi. Bunlar belli senaryolar için işe yarar oldular.

Bakkes v.d. (**Sander Bakkes P. S., 2007**) oyundaki domain bilgisini, değerlendirme fonksiyonuna dönüştürme üzerinde çalışmalar yaptı. Tavlada başarılı bir yapay zeka oluşturdu. (**Tesauro, 1992**) TD değerlendirmesi ile Spring RTS oyunundaki her bir birliğe ve konumlara bir değerlendirme fonksiyonu vererek, oyun sonu tahminini nispeten başarı ile gerçekleştirdiler ve birliklere konumlara değerlendirme fonksiyonu vererek uygun konumlama sağladılar fakat ikisinin kombinasyonunun başarılı olmadığını keşfettiler. Chen v.d. (**Yu Chen, 2019**) masaüstü oyunlarda kullanılan pekiştirme öğrenmesi ajanını, gerçek zamanlı strateji oyunları gibi büyük bir alanda oynanan bilardo oyununu Q öğrenmesi, derin sinir ağları ve arama ağaçlarıyla eğitti. Chaslot v.d. (**Guillaume Chaslot, 2008**) arama alanı içinde rasgele aramalar yaparak ardından geri yayılım ile ağaç nodelarını güncelleştirerek, araştırma ve suistimal arasında bir denge kurdu. Bilgisayar oyunlarında faydalı bir yapay zeka ürettirler. Saffidine v.d. (**David Churchill, 2016**) satranç ve GO gibi soyut oyun alanlarındaki sezgisel aramayı Alpha-Beta aramaya genişletip, gerçek zamanlı stratejiyi tur tabanlı hale getirdiler. Turlarda raslantısal avantajı eşitleme çalışmaları yaptılar. Gerçek zamanlı strateji oyun türünün mikro çarpışmalarında performanslı çalıştırdılar. Schadd v.d. (**Frederik Schadd, 2014**) hiyerarşik yapıda rakip modellemesi sistemi oluşturdu. Hiyerarşinin üst seviyesi rakibin genel oyun tarzını sınıflandırırken, alt seviye hiyerarşide rakibin özel stratejilerini tanımladı. Bakkes v.d. (**Sander Bakkes P. S., 2008**) her bir oyunun durum bilgisini alan bilgisi içeren bir durum tabanından aldılar. Karakterin durumunu ve bu durumun sonuçlarını kaydederek, rakip modellemesi gerçekleştirdiler. Hızlıca uyum sağlayan bir yapay zeka geliştirdiler.


Heijdewn v.d. (**Marcel van der Heijden, 2008**) rakip modellemesi kullanarak, sabit formasyondaki birlikleri dinamik hale getirerek oyuncuya daha fazla rekabet sağladılar. Hagelback v.d. (**Johansson, A Multiagent Potential Field-Based Bot for Real-Time Strategy Games, 2008**) (**Johansson, Dealing with Fog of War in a Real Time Strategy Game, 2008**) robotik alanında kullanılan potansiyel alanları gerçek

zamanlı strateji oyunlarına uyarladılar. Savaş sisi olduğu halde iyi çalışan, kendi görevlerini yerine getirirken etrafını araştırabilen yapay zeka tasarladılar. Özellikle kaynak toplama alanında başarılar elde ettiler. Robertson v.d. **(Watson, 2014)** önce replayleri çözümleyerek ve ardından replayleri BWAPI aracılığıyla çalıştırıp durumları çıkararak araştırmalar için kullanışlı bir veri tabanı oluşturdular. Starcraft'ta 1 saniyeye denk gelen 24 karede bir veri olarak, kullanılması kolay, büyüklüğü düşük bir veri tabanı oluşturdular.

Oyunu tam anlamıyla kapsayan yöntemler daha geliştirilmedi. Son araştırmalarda yapay sinir ağları ve evrimsel algoritmalarla daha iyi sonuçlar alındığı görüldü. Önceden Atari oyunlarını oynamak için pekiştirmeli öğrenme başarı ile kullanıldı **(Volodymyr Mnih, 2013)**. Fakat pekiştirmeli öğrenmeyi büyük durum ve eylem alanlarında kullanmak hala daha çok araştırma gerektiriyor **(Piotr Mirowski, 2017)**. Bunun sebebi hangi algoritmaların uygunluğunun bulunması ve hangi ödüllerin uygunluğunun belirlenmesinde yatıyor. Başarılı öğrenmeyi gerçekleştirmek için Q-öğrenme, Sarsa algoritması, modellemeler, sezgisel algoritmalar, derin öğrenme ve farklı algoritmalar deneniyor. Elde edilen verilerden yapay sinir ağlarına girdi olarak verilerek oyunu başarıya ulaştıracak algoritmalar aranıyor.

3. YÖNTEM

Bu bölümde belirlenen araştırma soruları ve sistematik literatür taramasından elde edilen yanıtlar verilecektir. Araştırmacıların karşılaştıkları engeller ve çözüm yolları anlatılacaktır. Araştırma için Kitchenham (**Barbara Kitchenham and Stuart Charters, 2007**) yöntemi kullanıldı. Araştırma soruları belirlendi. Araştırma sorularını yanıtlayabilecek anahtar kelimeler belirlendi ve arama yapıldı. Bulunan makaleler kalite kontrolünden geçirildi. 5 puanın altında kalan makaleler çıkartıldı. Elde edilen makalelerden araştırma soruları yanıtladı ve sonuçlar raporlandı.



Şekil 3.1 Araştırma Metodolojisi

Belirlenen araştırma soruları Tablo 3.1’de verilmiştir. Bu soruları cevaplamak için sistematik literatür taraması yapılarak, literatürde bulunan yayınlar incelendi.

Tablo 3.1 Araştırma Soruları

Araştırma Soruları	
S1	Hangi yapay zeka metodu kullanılmıştır?
S2	Hangi öğrenme metodu kullanılıyor?
S3	Hangi yapay öğrenme sistemi kullanılıyor, hangi başarı metriği uygun görülüyor, derin öğrenme kullanılıyor mu, hangi ödül uygun görülüyor?
S4	Birliklerin teker teker yönetimi mi ele alınıyor, yoksa birlikler grup olarak mı kontrol edildi?
S5	Makale mikro yönetim veya makro yönetim üzerine mi?
S6	Başarı kriterleri nedir? Rakibin bütün birliklerini yok etmek mi, yoksa iyi bir üretim sıralaması oluşturulması mı, yoksa birlikleri uygun bir şekilde bir yerden bir yere götürmek mi, kaynakları verimli toplamak mı?
S7	Hangi veriler algoritmayı eğitmek için kullanıldı?
S8	Hangi ortam kullanıldı?

Bu sorular araştırmanın doğasını, hangi yapay öğrenme modellerinin başarıya ulaştığını, onların avantajlarını ve hangi hiper parametrelerin işe yarar olduğunu gösterdi. Sistematik literatür taraması sonucu elde edilen yanıtlar aşağıda anlatılmıştır. Ardından, veri kümelerinin nasıl oluşturulduğu anlatılarak, son olarak da seçilen yapay öğrenme modelleri detaylı olarak sunulacaktır.

3.1. Sistematik Literatür Taraması

Sistematik literatür taraması ile gerçek zamanlı strateji oyunlarında yapay öğrenme için belirlenen sorulara yanıtlar bulundu. “Artificial Intelligence in Real-Time Strategy Games”, “Machine learning in Real-Time Strategy Games”, “Artificial Intelligence in Games” dizileri ile IEEE, ACM, ResearchGate ve ScienceDirect veri tabanlarından arama yapıldı. Elde edilen makalelerin referansları da takip edildi ve 114 makale elde edildi.


Elde edilen makaleler tam metinli, İngilizce ve yapay zeka üzerinedir. Strateji oyunları yapay zekası ile direk ilgili olmayanlar çıkartıldı. Böylece 67 tane elde edildi. Eldeki makaleler kalite değerlendirmesinden Tablo 3.2’deki kriterlere göre geçirildi.

Tablo 3.2 Kalite Değerlendirmesi Puanlama Tablosu

Evet: 1 puan Hayır: 0 puan


ID	Kalite Değerlendirmesi Soruları
S1	Çalışmanın amacı açıkça belirtildi mi?
S2	Çalışmanın arka planı ve genişliği açıkça belirtildi mi?
S3	Önerilen çözüm açıkça açıklandı mı ve gözlemsel bir çalışma ile onaylandı mı?
S4	Araştırmada kullanılan değişkenler geçerli ve güvenilir mi?
S5	Araştırma süreci uygun şekilde belgelendi mi?
S6	Bütün çalışma soruları cevaplandı mı?
S7	Negatif sonuçlar sunulmuş mu?
S8	Ana bulgular güvenilirlik, geçerlilik ve onaylanma açısından açıkça anlatıldı mı?

Kalite değerlendirmesi sonunda 4 puanın altında kalan 8 tane makale çıkartıldı. 21 male 8 puan 14 makale 7 puan, 14 makale 6 puan, 10 makale 5 puan ve 8 makale 4 puan aldı. Elde edilen 59 makalelerin puanlandırması Şekil 3.2’de gösterilmiştir.



Şekil 3.2 Makale Puanları

Elde edilen makalelerden 1 tane ScienceDirect'ten, 2 adet ACM'den, 3 adet ResearchGate'ten ve 53 adet IEEE'den bulunmaktadır. Makalelerin 31 tanesi konferanslardan, 20 tanesi dergilerden ve 8 tanesi rapor türündendir. Makalelerin türlere göre sayısı Şekil 3.3'te gösterilmiştir.



Şekil 3.3 Makale Türleri

Seçilen makalelerden araştırma soruları yanıtlandı.

3.1.1. AS-1: Hangi yapay zeka metodu kullanılmıştır?

Makalelerin çoğunda yapay öğrenmede yapay sinir ağları kullanıldı. 9 makalede evrimsel algoritma [S1] [S2] [S3] [S4] [S5] [S6] [S7] [S8] [S9] tercih edildi. [S10] 5 makalede karar verme ağaçları, davranış ağaçları, sezgisel metotlar, Markov Raslantısal Alanlar, görev dağıtma yapay zeka sistemleri kullanıldı [S11] [S12] [S13] [S14] [S15]. Yapay sinir ağlarında en çok pekiştirmeli öğrenme ve evrimsel algoritmalarda genetik algoritmalar kullanılmıştır. Öğrenme metodu içinde farklı modüllerin kullanılması genellikle bütün çalışmalarda uygulanmıştır. Durumlar okunarak saldırı, savunma, erken saldırı, tank saldırısı, büyük ekonomiye yönelme ve benzeri modüller arasında sistem bir tercih yapılmıştır ve bu tercih bota iletilerek uygulanmasına bırakılmıştır [S13]. Bu yöntem oyun kazanma oranını arttırmıştır. Girdiler arttıkça ve öğrenme derinleştikçe yapay zeka stratejinin uygulanması için modüllerden daha çok birliklerinin birer birer kontrolüne doğru genişlemiştir.

3.1.2. AS-2: Hangi öğrenme metodu kullanıldı?

Yapay öğrenen sistemlerinde pekiştirmeli öğrenme ilk sırada yer alıyor [S16] [S17] [S18] [S19] [S20] [S21] [S22] [S23] [S24] [S25] [S26] [S27] [S28] [S29] [S30]. Evrimsel algoritmalarda genetik algoritma en çok kullanılandır. Bunun yanında sürü zekası [S1] ve SOMA [S3] yöntemleri de genetik algoritma içinde kullanıldı. Bunların yanında hızlı raslantısal öğrenme [S31], yokuş yukarı araştırma [S14], ağaçlara uygulanan yukarı güven hatları [S30], Bayesian modeller [S32], Markov Ağı [S12], iki terimli sınıflandırma [S33], konvansiyonel model sınıflandırma [S25], bulanık mantık[S34] de birer tane makalede kullanıldı. Arayüz ile oyunun durumlarına erişilmiş ve bu durumlardan yapay öğrenmeye uygun o anda oyunda bulunan birlikler, birliklerin konumları, kaynaklar, yükseltmeler ve kaynak miktarları ve benzerleri öznitelikler çıkartılmıştır [S23] [S29] . Öğrenme her zaman tek bir ırk üzerinde yapıldı. Öğrenme hızını arttırmak için küçük haritalar kullanıldı. Öğrenmenin girdileri arttıkça, daha çok katmanlı ve çok nöronlu sinir ağları kullanıldıkça, modüller seçimlerden daha ziyade, strateji birlikler özeline kadar indi ve gittikçe daha başarılı gerçekleştirildi.

3.1.3. AS-3: Hangi yapay öğrenme sistemi kullanıldı, hangi başarı metriği uygun görüldü, derin öğrenme kullanıldı mı, hangi ödül uygun görüldü?

Gözetimli, gözetimsiz, pekiştirmeli öğrenme, durum tabanlı çıkarım [S10], içerik transferli pekiştirmeli öğrenme [S27], derin pekiştirmeli öğrenme [S20], rakip modelleme [S10], geri yayılımlı sinir ağı [S35], iki terimli sınıflandırma [S33], genetik algoritma [S36] [S5] [S1] [S4] [S34] [S3] [S37], uygunluk fonksiyonu, değerlendirme fonksiyonu [S21], derin Q öğrenmesi ile pekiştirmeli öğrenme [S18], derin Q network [S20], Sinir ağına uyumlu Q öğrenme ve geleneksel derin sinir ağlarına uyumlu Q- öğrenme [S26], içerik eğitimi [S19], Monte-Carlo ağaç araması, derin pekiştirmeli öğrenme, bulanık integral [S34], parametre paylaşan çok etmenli gradyan iniş Sarsa Bayesian modelleri [S27], Markov rastlantısal alanlar [S12] kullanıldı. Genetik algoritma çıkışları, bir makalede, yapay sinir ağlarına girdi olarak kullanıldı [S37]. Bulanık ölçüm genetik algoritma çıkışları ile iyileştirildi [S34]. Sıra tabanlı bulanık integralin daha performanslı sonuçlar verdiği görüldü. Her bir çalışmada ayrı bir yöntem ve algoritma kullanıldı. Ödül olarak genellikle kazanmaya +1 kaybetmeye -1 veya -10 kullanıldı. Mikro çalışmalarda öğrenmedeki gecikme hangi eylemin ödülün ne kadarından sorumlu olduğunu keşfetmesini zorlaştırdığı için, birliğin ne kadar hasar verip ne kadar hasar aldığı gibi ara ödüller de kullanıldı [S27] [S16]. Ödüller verilen

hasar, alınan hasar ve yok edilen birliklerin toplamından hesaplandı. Birlikleri mineral veya gaz kaynaklarına yönlendirmek için farklı derecede ödüller verildi. Bunun ardından birliklerin can puanlarını kaybetmelerine negatif ödüller verildi ve hasar almayan birliklere pozitif ödüller verildi [S28].

Aktivasyon fonksiyonu gizli katmanlarda ReLu ve çıkışta SoftMax tercih edildi [S25] [S23]. Öğrenme hızı makrolarda 0.01, mikrolarda 0.001 araştırmanın artırılması için düşük tutuldu [S16] [S25] [S27] [S33]. Modüler çalışmalarda da sinir ağından çıkan tercih büyük oranda uygulansa da düşük bir yüzdeyle rasgele bir strateji seçimine izin verip araştırmaya yer bırakıldı. Ağgözlü algoritmaların da beraber denendiği makalelerde ağgözlü algoritmanın, araştırmaya yer veren algoritmalar karşısında daha az başarı sağladığı, uzun oyunlara yönelmediği ve yükseltme tercihinde bulunmadığı görüldü. Mikro çalışmalarda epsilon ağgözlü algoritması kullanımlarında epsilon 0,9 olarak başlatıldı. Epoch'un sonlarına doğru sabit oranla 0'a düşürüldü.

Sinir ağlarına girdi olarak oyunda o sıra bulunan birlikler ve bunların sayısı, o sırada araştırılan yükseltmeler, bu yükseltmelerin ilerleme durumu, rakipteki birlikler ve tedarik puanı verildi. Bazı makalelerde zaman da bir girdi olarak verildi. Çıkışta üretilcek birlikler ve yükseltmeler verildi. Modüler çalışmalarda alınan çıkışlarla bir modül tercih edildi ve kullanılan botun yapay zekasına bu modülü kullanması komut edildi. Mikro çalışmalarda girişler birliklerin can puanları, silahlarının soğuma süreleri, rakip birlikler arasındaki mesafe olarak alındı ve çıkışlar da 8 farklı yöne hareket etme ve saldırı olarak alındı.

Çalışmaların çoğunda pekiştirme türlerinin farklı algoritmalar ile denenmesi ve ağırlıklandırılması yer aldı. Evrimsel algoritmalarından genetik algoritma, mutasyon ve kromozomlama kullanıldı. Hem ödül hem kromozomlamalar, hem mikro düzeyde çatışmalar için hem de makro inşa sıraları oluşturmak için kullanıldı.


3.1.4. AS-4: Birliklerin teker teker yönetimi mi ele alınıyor, yoksa birlikler grup olarak mı kontrol edildi?

50 adet makalede birlikleri birer birer kontrol etme, 23 adette toplu halde yönlendirme, 6 adette ikisi birden konu alındı. Bir çalışmada birliklerin teker teker kontrol edilmesi sürekli değişen bir lider belirlendi [S3]. Bir çalışmada A-star yol bulma, tehlike farkında yol bulmaya dönüştürüldü. Hazır yol bulmadan daha iyi sonuç

verse de sistemin geri kalanından çok daha yavaş çalıştığı gözlemlendi [S38]. Teker teker kontrol etme yönteminde potansiyel alanlar ve alan değerlendirmeleri kullanıldı [S39]. Birliklerin grup olarak kontrol edildiği alanlarda Q öğrenme ve pekiştirmeli öğrenmelerin daha başarılı olduğu görülürken [S25], birliklerin teker teker kontrol edilmesinde genetik algoritmaların, potansiyel alanların ve pekiştirmeli öğrenmenin verimli olduğu görüldü [S37]. Önceki algoritmalar binaları, yükseltmeleri, birliklerin yaşam puanlarını ve özelliklerini öznitelik olarak alıp oyunda nihai amaç olan rakibi yenmeyi gerçekleştirdiği için [S23], sonraki algoritmalar konum odaklı çalışıp kaynak planlamasına ihtiyaç duymadıklarından çatışma düzeyinde daha başarılı sonuçlar verdiler [S27].

3.1.5. AS-5: Makale mikro yönetim veya makro yönetim üzerine mi?

Sadece mikro yönetim üzerine olan çalışmalar Şekil 3.4'te görüldüğü gibi daha fazladır. Hem mikro hem de makro üzerine olan çalışmalar da makroya eklenirse sayıları birbirine yakındır. Geniş durum eylem alanı mikro alanda sınırlandığında algoritmalar denemek daha kolay sonuç alınmasını sağladılar [S33]. Algoritma verimliliği kolay sınıandı. Ödüllendirme rahat ayarlanabildi [S27]. Öğrenme hızı çok düşük tutularak araştırmaya geniş alan bıraktı. Makro üzerine çalışmalar daha fazla bilgisayar kaynağı gerektirir, ancak oyun gerçek zamanlı oynandığı için hesaplamaların hızlı yapılması gerekir [S18] [S13]. Makro için başlıca bir sorun oluşturur. Geliştirilen algoritmaların rafine edilmesi, optimize edilmesi ve anlık tepkileri verebilmesi istenir.



Şekil 3.4 Makro ve Mikro Yönetim Üzerine Makaleler


3.1.6. AS-6: Başarı kriteri nedir?

Çalışmaların çoğunun amacı oyunu kazanmaktı [S35] [S23] [S38]. Aynı zamanda oyunu kazanırken algoritmaların hızlı çalışması da göz önünde bulunduruldu [S1] [S33]. Rakip modelleme üzerine çalışmalar da yapıldı [S12] [S40] [S41]. Mikro düzeyde olan çalışmalarda rakibin bütün birliklerinin yok edilmesi idi [S30] [S36] [S6]. Mikro düzeyde yapay zeka birliklerin özellikleri bakımından avantajlı taraf, dengeli ve dezavantajlı taraf olarak farklı birliklere karşı savaştırıldı [S27]. Dezavantajlı olduğu durumlarda daha geç sürede kaybetmek, rakibe ilk durumundan daha fazla hasar vermek ve daha az birlik kaybetmesini sağlamak da başarı kriteri olarak seçildi [S28]. Birliklerin menzilinın rakip birlikleri aştığı durumlarda, daha uzun menzilli birlikler ateş ettikten sonra rakipten uzaklaşıp, silahların soğuma süresi bitince tekrar ateş edip ve ardından tekrar uzaklaşarak hiç hasar almadan rakiplerini yok edebilirler. Bu vur kaç taktiği gerçek zamanlı strateji oyuncuları arasında sıklıkla uygulanır. Yapay öğrenmede bu davranışı geliştirmek mikro yönetim çalışmalarında başarı kriteri seçildi [S27] [S28]. Birliklerin vur kaç taktiği uygulaması dezavantajlı durumda daha çabuk öğrenildi. Dezavantajlı durumda model eğitilerek, birliklerin avantajlı bir durumda olduğu karşılaşmaya bu model uyarlanırsa daha başarılı, daha az kayıplı, daha kısa sürede çarpışmayı kazanan sistemler geliştirildiği görüldü. Bunun ardından yüksek skor almayı amaçlayan çalışmalar gelir. Ardından az sayıda makalede

üretim sıralaması oluşturma [S13] ve birliklerin düzgün bir yol planlama [S37] [S42] ile bir noktadan başka bir noktaya hareket etmesi başarı kriteri olarak alındı.

3.1.7. AS-7: Hangi veriler algoritmayı eğitmek için kullanıldı?

Birçok çalışma kendi algoritmasını kurup oyunu çalıştırarak bu algoritmayı eğitti. Önceden oynanmış oyunların replaylerinden eğitilen sistemler aktif oyun ile eğitilen sistemlerin 3'te 1'i kadardır. Makalelerde üretilen algoritmaların oynanışı ilk andan itibaren geliştirmeleri ve standardı geçmeleri gösterildi. Kullanılan replayler profesyonel oyuncuların ve yüksek seviyede oynayan oyuncuların oyunlarıdır [S23] [S32] [S34]. Makro algoritmalarında en çok seçilen ırk Protoss'tur [S23] [S2] Daha az birlik sayısı sebebi ile eğitimi daha kolaydır. Mikro eğitimlerinde konumsal avantajı daha yüksek olan, mikro yönetimi iyi uygulanırsa kaybeden birlik kompozisyonunu kazanan birlik kompozisyonuna dönüştürecek olan Terran ırkı daha çok tercih edilir[S28] [S30] [S42] [S6]. Algoritmayı eğitmek için kullanılan veriler Şekil 3.5'te gösterilmiştir.



Şekil 3.5 Algoritmayı Eğitmek için Kullanılan Veriler.

3.1.8. AS-8: Hangi ortam kullanıldı?

Makalelerin %50'sine yakınında Starcraft kullanıldı. BWAPI [S10] [S1] [S17] [S27] sayesinde oyun durumlarına erişilebilmesi ve botların yapılarının değiştirilebilmesi sayesinde Starcraft üzerinde birçok çalışma yapılmasına imkan tanır. BWAPI aracılığıyla bütün oynanan oyunların replaylerine de aynı şekilde erişilerek

veriler çıkartılabilir. Dengeli, ırkların özellikleri çok farklı olmasına rağmen eşit güçte olmaları, sebebi ile araştırma için ideal bir ortam oluşturur. Sadece yapay zeka eğitmek için tasarlanan Deep RTS [S18], ELF [S19], Mikro RTS [S43] ve Spring [S13] [S40] oyunları üzerine de çalışmalar yapıldı. Bu motorlar RTS oyunlarını simüle ederek yapay zeka araştırmaları yapmak için kullanılırlar. Gerçek zamanlı stratejilerin soyut hallerini uyguladıkları için işlemcinin üzerinden yükü alıp, kapasitesini algoritmaları verimli çalıştırmakta kullanırlar. 2 makalede Starcraft 2 [S6] [S26] ve bir makalede Warcraft 3 [S7] kullanıldı. Bunların dışında ticari oyunlardan Starcraft klonu Watercraft [S14], Civilization klonu Call To Power 2 [S46] ve Warcraft 3 klonu Wargus [S47] da kullanıldı. Gerçek zamanlı strateji oyunlarının mikro düzeyinde oynan MOBA oyunlarından [S11] Mobile Legend: Bang Bang [S35] ve League of Legends [S50] kullanıldı. Bellus Belum Gratia[S8], Glest [S47], The Bos Wars [S4], Mario [S9], Flappy Bird [S20], Snakeotron ,Rogue Trooper [S57],Darkmok 2, BattleCity [S3][S51], Tic-Tac-Toe, Triangular Tic-Tac-Toe[S52] üzerinde yapay öğrenme araştırmaları yapıldı. Satranç [S44], GO [S45] ve dama [S5] üzerine araştırmalar dahil edildi.

3.1.9. Engeller

Çalışmaların bütününde ortak engeller geniş durum ve eylem alanını dar bir alan dönüştürmektir. Başka bir genel engel ise evrimsel algoritmaların sağlamlık fonksiyonları için doğru değerleri bulmak ve pekiştirmeli öğrenme algoritmalarında uygun ödüllerin atanmasıdır. Karşılaşılan engeller Ek 1 bölümünde Tablo A.1’de verilmiştir.

Bundan sonra araştırma sorularından elde ettiğimiz veriler değerlendirildi. Gerçek zamanlı strateji oyunlarındaki çok büyük alan ve eylem sebebi ile çok farklı yöntemler denenmiştir. Kullanılan yöntemler, öğrenim sistemleri birbirlerinden çok farklı bakış açıları altında yazılmıştır. Sabit kodlu yapılardan, derin öğrenme, karar verme ağaçlarından pekiştirmeli öğrenmeye kadar bir çok detaylı araştırma yapılmıştır.

Bu yöntemlerden herbiri oyunun geniş alanını sınırlandırarak bu alanda başarıyı amaçlamıştır. Bu dar alanda başarılı olmuşlardır fakat genel uygulanabilirlikleri büyük ölçüde gözlemlenmemiştir. Özellikle hard-coded yapılar ve karar ağaçları bütün oyunu oynamakta yeterince başarı gösteremekteler. Karar

verme ağaçları, eğer makine öğrenimi ile eğitilmiş bir modelden girdi alırsa başarılı sonuçlar alınacağı gözlemlenmiştir.

Alan ve eylem büyüklüğü sebebi ile birçok çalışma alanını mikro üzerine geliştirmiştir. Oyun alanını mikro düzeyde, küçük bir harita alanında, belli adet ve türde birliklerin belli adet ve türde birliklerle savaştığı durumlarda başarı oranı oldukça yüksektir. Hızlı eğitilebilirler. Değerlendirme fonksiyonları ve ödüller daha kolay ayarlanabilir görünmektedir. Oyunu değil çatışmayı kazandırır, bir makro eğitim yöntemine eklenirse oldukça verimli olabilirler.

Yapay sinir ağlarında ağırlıkların hesaplanmasında gradyan azalma metodu kullanır. Yapay sinir ağlarının çıkışında softmax tercih ediliyor, sınıflandırma yaparak mikrolarda hareket yönü ve saldırıya, makrolarda botlarda hangi stratejilerin tercih edileceğine, üretim sıralaması oluşturmada hangi birliğin üretileceğine karar veriyor. Ödüller çoğunlukla gelecek ödüllere önem vererek değerlendiriliyor, anlık ödüllerin değeri artırılarak da denemeler yapılıyor. Açık poliçe SARSA, kapalı poliçe Q öğrenmesinden daha başarılı sonuçlar veriyor.

Makro düzeyde de alan daraltılmaları kullanılmıştır. Sadece üretim sırası veya kullanılacak birlik türleri düşürülerek araştırmalar yapılmıştır. Bu eğitim modelleri halihazırda olan botların üretim kodlarına eklenerek başarılı performanslar göstermişlerdir. Özellikle genetik algoritma bu alanda çok işe yarar olduğu anlaşılmıştır.

Çalışmaların hepsinde tek bir ırk seçilip araştırmalar bu ırk için yapılmıştır. Bir ırk için eğitilen modeller, birliklerin bambaşka özellikleri nedeni ile, diğer ırklarda hiçbir işe yaramayacakları gözlemlenmiştir.

Tam makro düzeyde, hiçbir sınırlama yapılmadan, olan araştırmalarda pekiştirmeli öğrenme en başarılı sonuçları vermektedir. Özellikle derin pekiştirmeli öğrenme birçok oyunu kazanabilmektedir. Bunun sebebi oyunun da insanlar tarafından mükemmel anlaşılmadığı için gözetimli ve yarı gözetimli öğrenmelerde iyi bir başarı metreği girilememesidir. Bu sebepten, çalışmalar pekiştirmeli öğrenmede ödüllerin iyi belirlenmesini araştırarak ve başka yöntemlerden elde edilen veriler pekiştirmeli eğitime girdi olarak verilerek yapılmıştır.

Birçok çalışma sıradan oyunda kendi kendisini eğitmiştir fakat profesyonel oyuncularının replayleri ile daha verimli sonuçlar alınabilir. Bu veriler ile eğitildikten sonra yapay öğrenmenin kendi kendi eğitimi başlayabilir.

Birçok araştırmada Starcraft oyunun kullanılması şaşırtıcı değildir. En dengeli gerçek zamanlı strateji oyunu olması ihtimali yüksektir. Uygun türde ve sayıda birlik, uygulanabilir ve iyi zamanlanabilir teknoloji ağaçları bulundurur. Mikro düzeyde çalışmalarda Warcraft klonları kullanılabilir, çünkü Warcraft'ta mikronun etkisi Starcraft'ta göre oldukça fazladır.

Çalışmalar oyunun orijinal yapay zekasını %68'in üzerinde oranla, bazı algoritmalar %100 oranla [S27] [S28] yeniyor. Yapay öğrenmenin sabit kod yapılardan daha başarılı olduğunu gösteriyor.

Çalışmalar öğrenmenin genişliği ve dolayısıyla başarısı ile oyun gerçek zamanlı oynandığı için hızlı çalışabilmesi arasında denge kurmak üzerine yapıyor. Öğrenme üstün başarılı olduğunda sistemin performansı azalıyor, çalışmalar hem performanslı hem de geniş bir alanda öğrenen algoritmaları keşfetmeyi amaçlıyor.

Bu sistematik literatür taramasında 59 adet makale incelendi ve 8 araştırma sorusu yanıtlandı. Bu çalışmadan şu sonuçlar çıkartılabilir. Gerçek zamanlı strateji oyunları yapay zeka tekniklerini denemek için ideal bir ortamdır. Geniş bir alanda yapay zeka denemeleri bu ortamda gerçekleştirilebilir ve geliştirilebilir. Yapay öğrenme gerçek zamanlı strateji oyunlarında yapay zekanın gelişmesine katkılar sağlamaktadır. Özellikle pekiştirmeli öğrenme, genetik algoritmalar ve derin pekiştirmeli öğrenme çok başarılı sonuçlar getirmektedir.

Geniş bir alanda arama ve öğrenme yaparken, çabuk cevap veren, performanslı algoritmaları keşfetmek gerçek zamanlı strateji oyunlarında yapay öğrenmenin amacıdır. BWAPI aracılığıyla Starcraft ve Spring ve microRTS benzeri gerçek zamanlı strateji oyunlarını soyutlayan motorlar algoritmaların geliştirilmesi için uygun ortamı sağlamaktadır. Satranç ve Go'nun ardından yeni başarı, gerçek zamanlı strateji oyunlarını iyi oynayan yapay zekalarda bulunacaktır. Mükemmel olmayan bilgiye dayanarak eğitilen sistem karar verdiği için bir çok gerçek hayat uygulamasında yeni imkanları beraberinde getirecektir.

3.1. Veri Kümesi

Çalışmada Auckland Üniversitesi'nde Profesör Ian Watson ve yazım tarihinde doktora öğrencisi ve öğretim görevlisi olan Glen Robertson tarafından hazırlanan veri tabanı kullanıldı (**Watson, 2014**). Veri tabanı 812 adet Terran'a karşı Zerg oyunundan oluşur. 287 oyunda Zergler, 362 oyunda Terranlar kazanır. 163 oyun berabere biter. Bu veri tabanında her bir birliğe kendine has bir birlik numarası UnitID verildiği için, birliklere verilen bütün komutlar ve birliğin özellikleri takip edilebilir durumdadır. Profesyonel oyuncuların Starcraft replay dosyaları replayfile parserdan geçirilerek ReplayID ve oyuncuların PlayerReplayID'si ile oyuncu eylemleri action tablosuna, oyun Game, oyuncular Player, birlik grupları unitgroup tablosuna işlenmiştir. Aynı replay dosyalarından Starcraft oyununda oynatılmış ve BWAPI'den stateler okunarak terrain, event, unitattributes, unitvisibility ve playerresources tabloları oluşturulmuştur. Elde edilen tablolarla SQL veri tabanı gerçekleştirilmiştir.

Yapay öğrenmede kullanılacak olan veri kümesini oluşturmada amaç oyunda bulunan hem oyuncunun hem de rakibinin, tüm birliklerinin tek bir satırda bulunması ve bu durumda oyuncunun üretim emri verdiği birliğin çıkış sütununda işlenmesidir. Bu veriye veri tabanından doğrudan erişilemediği için veri tabanında bulunan tablolar işlemiden geçirilerek arzulanan veri kümesi elde edildi.

3.2.1. Terran Kayıtlarının Hazırlanışı

Starcraft oyununda zaman oynatılan kareler ile ölçülür. 1 saniyede 24 kare vardır. Bütün tablolar kare numarasına göre sıralanmıştır. Terran kayıtlarından yaratım tablosunun hazırlanması için Event tablosu EventTypeID üzerinden eventtype tablosu ile, UnitID üzerinden unit tablosu ile, unit tablosu UnitTypeID üzerinden unittype tablosu ile birleştirildi. UnitTypeName "terran" içeren ve EventTypeID = 12 olan satırlar alındı ve Terran Üretim Tablosu oluşturuldu. Event tablosu EventTypeID üzerinden eventtype tablosu ile, UnitID üzerinden unit tablosu ile, unit tablosu UnitTypeID üzerinden unittype tablosu ile birleştirildi. UnitTypeName "terran" içeren ve EventTypeID = 13 olan satırlar alındı ve Terran YokEdilme Tablosu oluşturuldu. Refinery binası oyundaki diğer binalardan farklı olarak yaratılmıyor, gaz kaynakları fayansları Refinery binası ile değiştiriliyor. Bu sebepten SCV'lere verilen "Refinery kur" komutları takip edilerek Refinery sayıları elde edildi. Action tablosu UnitGroupID üzerinden unitgroup tablosu ile, unitgroup tablosu UnitID üzerinden unit

tablosu ile, unit tablosu UnitTypeID üzerinden unittype tablosu ile birleştirildi. UnitTypeName "Terran" içeren ve UnitCommandType = 2 ve TargetID = 110 olan satırlar alındı.

“Build Refinery” komutu oyuncu tarafından verildiğinde Refinery kurulamaz bölgelere de verilebileceği için veya kaynak yetersizliğinden kurulamadığında, Refinery 2x2 fayans alan kapladığından, x ve y fayans koordinatlarında, binanın konumlandırılması komutunu verilen fayans koordinatlarının +1, -1 konumuna önceki satırlarda kurulum komutu verilmiş ise bu satırlar filtrelendi. Elde edilen satırlarla Terran Refinery Kurulum Tablosu oluşturuldu.

3.2.2. Zerg Kayıtlarının Hazırlanışı

Zerglerde, diğer ırkların üretim sisteminden farklı bir yöntemi var. Zerg birlikleri sadece Hatchery’lerin ürettikleri larvalardan evrimleşerek başka birliklere dönüşüyor. Üretim komutu sadece larvalar için kaydediliyor. Bu yüzden larvalara verilen dönüşme komutları takip edilerek oyuna giren birlikler tablolara eklendi. Action tablosu UnitGroupID üzerinden unitgroup ile, TargetID üzerinden unittype, unit tablosu UnitID üzerinden unitgroup tablosu ile birleştirildi. UnitCommandTypeID = 5 olan satırlar alındı ve Çoklu Dönüşüm tablosu oluşturuldu.

Tablo dönüşme eyleminden oluşturulduğu için oyuncu üretme komutu verse de kaynak yetersizse birlik üretilmez. Aynı zamanda, Starcraft oyuncularında aynı komutu arka arkaya vermek yaygın bir alışkanlıktır. Bu sebepten Çoklu Dönüşüm tablosunda satırlar ReplayID, UnitID ve karelere göre sıralandı. Satırlarda arka arkaya aynı UnitID ve aynı UnitTypeName'e dönüşme komutu verilmişse önceki satırlar elendi ve sadece son satır alındı. Bu satırlar Zerg Tek Dönüşüm tablosunu oluşturdu. Action tablosu PlayerReplayID üzerinden playerreplay tablosu ile birleştirildi. UnitCommandTypeID = 2 ve RaceID = 0 olan satırlar alındı. Bu satırlarla Zerg Build tablosu oluşturuldu. Kazanan Zergler için UnitCommandTypeID = 5, RaceID = 0 ve Winner= 1 olan satırlar, kaybeden Zergler için UnitCommandTypeID = 5, RaceID = 0 ve Winner= 0 olan satırlar alındı. Kaynak yetersizliği veya bina kurulamayacak bölgelere kurma komutu verilebileceği için, satırlar PlayerReplayID ve kare ile sıralandı. Binalar 2x2 fayans alan kapladığı için x,y fayans koordinatlarında, binanın konumlandırılması komutunu verilen fayans koordinatlarının +1, -1 konumuna önceki satırlarda aynı bina türünün kurulma komutunun verilmiş ise bu satırlar filtrelendi.

Kalan satırlarla Zerg Tek Fayans Filtreli Kurulum Tablosu elde edildi. Event tablosu EventTypeID üzerinden eventtype tablosu ile, UnitID üzerinden unit tablosu ile, unit tablosu UnitTypeID üzerinden unittype tablosu ile birleştirildi. UnitTypeName "Zerg" içeren ve EventTypeID = 13 olan satırlar alınarak Zerg UnitID Destroy tablosu elde edildi. Zerg UnitID Destroy tablosu UnitID üzerinden Zerg Tek Dönüşüm tablosu ile eşleştirilerek UnitTypeName sütununa birlik adı yazıldı ve Zerg YokEdilme tablosu oluşturuldu.

3.2.3. Terran Veri Kümesinin Hazırlanışı

Zerg Tek Dönüşüm Eylemi, Zerg Üretim, Zerg Tek Fayans Filtreli Kurulum Eylemi, Zerg YokEdilme, Terran Üretim, Terran Refinery Filtreli Kurulum Eylemi, Terran YokEdilme veri çerçevesi arka arkaya eklendi. Ardından ReplayID ve kare ile sıralandı. Böylelikle oyun esnasında gerçekleşen olaylar zaman sırasına göre hizalandı. Oyundaki her bir birliğin oyundaki sayısını belli eden Toplam_Sayı sütunları ve oyuncunun üretim emri verdiği birliğin işleneceği "Çıkış" sütunu veri çerçevesine eklendi. Her bir birlik için bir sayaç oluşturuldu ve sıfırdan başlatıldı. Örneğin, Toplam_Terran_Medic_Sayısı = 0.

Bir Starcraft oyununun başında Terranlar 4 SCV ve Bir Command Center ile ve Zergler 4 Drone, 1 Hatchery ve 1 Overlord ile başladığı için bu birliklerin sayaçları 4, 1 ve 1 olarak başlatıldı. Veri kümesinde her bir satırda EventTypeID sütunu = 12 ise UnitTypeID'de bulunan birlik, Çıkış sütununa işlendi ve bu birliğin sayacı 1 arttırıldı. Eğer Zerg birliği ise sadece bu birliğin sayacı 1 arttırıldı. Üretim komutu alan Zerg birlikleri sadece Zerg Zergling ve Zerg Scourge'tür. Bu birliklerden aynı larvadan iki tane çıktığı için, ikincisi oluştuğunda veri tabanında üretim kaydedilmiştir.

Satırda TargetID sütunu dolu ise, buradaki birliğin sayacı 1 arttırıldı. TargetID'de Refinery varsa Çıkış sütununa Refinery işlendi. TargetID'de Terran Refinery hariç hepsi Zerg birliğidir. EventID ve TargetID aynı satırda ikisi birden dolu değildir. Bu yüzden aynı satırda ya EventID ya da TargetID işlenir. Yok edilen birliklerin eksiltilmesi için satırda EventTypeID sütunu = 13 ise Terran birlikleri için UnitTypeID sütundaki birliğin sayacından 1 çıkarıldı, Zerg birlikleri için UnitTypeName sütunundaki birliğin sayacından 1 eksiltildi.

Her bir döngü adımının başında her bir birliğin sayacında bulunun rakam, o birliğin toplam sayısının bulunduğu sütundaki satır numarasına atandı. Kare sütununda

0 okunduğunda sayaçlar baştaki duruma döndürüldü. Döngü bittikten sonra Çıkış sütununda boş olan satırlar çıkartıldı. Sayaçların atandığı ve oyundaki birlik sayısını gösteren Toplam_Sayı sütunları ve Çıkış sütunu yeni bir veri çerçevesine atandı ve veri kümesi elde edildi.

3.2.4. Zerg Veri Kümesinin Hazırlanışı

Zerg Tek Dönüşüm Eylemi, Zerg Üretim, Zerg Tek Fayans Filtreli Kurulum Eylemi, Zerg YokEdilme, Terran Üretim, Terran Refinery Filtreli Kurulum Eylemi, Terran YokEdilme veri çerçevesi arka arkaya eklendi. Ardından ReplayID ve kare ile sıralandı. Böylelikle oyun esnasında gerçekleşen olaylar zaman sırasına göre hizalandı. Oyundaki her bir birliğin oyundaki sayısını belli eden Toplam_Sayı sütunları ve oyuncunun üretim emri verdiği birliğin işleneceği "Çıkış" sütunu veri çerçevesine eklendi.

Her bir birlik için bir sayaç oluşturuldu ve sıfırdan başlatıldı. Bir Starcraft oyununun başında Terranlar 4 SCV ve Bir Command Center ile ve Zergler 4 Drone ve 1 Hatchery ve 1 Overlord ile başladığı için bu birliklerin sayaçları 4, 1 ve 1 olarak başlatıldı. Veri kümesinde her bir satırda TargetID'de bulunan birlik Çıkış sütununa işlendi ve bu birliğin sayacı 1 arttırıldı. TargetID'de bulunan birlikler, bir tanesi hariç, Zerg birliğidir. TargetID'de bulunan tek Terran birliği Refinery'dir. Bu durumda sadece Refinery sayacı arttırıldı ve Çıkış'a işlenmedi.

Zerg Larva'lar Zerg Hydraliskler'e ve Zerg Mutaliskler'e evrildikten sonra, Zerg Hydralisk'ler Zerg Lurker'lara ve Zerg Mutaliskler de Zerg Devourer veya Zerg Guardian'a evrilebiliyor. Bu Zerg Lurker'a dönüşüm komutu verilmişse Zerg Hydralisk sayacından 1 eksiltildi ve Zerg Devourer veya Zerg Guardian'a dönüşüm komutu verilmişse Zerg Mutaliskler'in sayacından 1 eksiltildi. Aynı şekilde, Zerg Dronelar da binalara evrimleşiyorlar. Bu sebepten bir binaya dönüşüm komutu verildiğinde Zerg Drone sayacı da bir eksiltildi.

EventTypeID sütunu = 12 ise UnitTypeID'de bulunan birliğin sayacı 1 arttırıldı. EventType'larda Terran birlikleri bulunur. Zerg Zerglingler ve Zerg Scourgeler aynı larvadan 2 tane çıktığı için, ikinci birlik event tablosunda oluşturulur. EventID ve TargetID aynı satırda ikisi birden dolu değildir. Bu yüzden aynı satırda ya EventID ya da TargetID işlenir. Satırda EventTypeID sütunu = 13 ise Terran birlikleri

için UnitTypeID sütundaki birliğin sayacından 1 çıkarıldı, Zerg birlikleri için UnitTypeName sütunundaki birliğin sayacından 1 eksiltildi.

Her bir döngü adımının başında her bir birliğin sayacında bulunun rakam, o birliğin toplam sayısının bulunduğu sütundaki satır numarasına atandı. Kare sütununda 0 okunduğunda sayaçlar baştaki duruma döndürüldü. Döngü bittikten sonra Çıkış sütununda boş olan satırlar çıkartıldı. Sayaçların atandığı ve oyundaki birlik sayısını gösteren Toplam_Sayı sütunları ve Çıkış sütunu yeni bir veri çerçevesine atandı ve veri kümesi elde edildi.

61 sütunda her biri birlik türünden, oyuncu üretim komutu verdiği zaman kaçır adet bulunduğu ve Çıkış sütununda oyuncunun üretim emri verdiği birlik bulunur. Her bir satır oyundaki her bir birliğin hem oyuncunun hem de rakibin, toplam sayısını ve oyuncunun bu durumda hangi birliği üretmeyi seçtiğini gösterir. Örneğin, Toplam_Terran_Medic_Sayısı sütununda o karede oyundaki toplam Terran Medic sayısı, Toplam_Zerg_Hydralisk_Sayısı sütununda aynı karede oyundaki toplam Zerg Hydralisk sayısı, Toplam_Zerg_Mutalisk_Sayısı sütununda aynı karede oyundaki toplam Zerg Mutalisk sayısı ve Çıkış sütununda üretme emri verilen birlik bulunur. Satırlar ReplayID ve karelere göre sıralandı, böylelikle oyunların verilerle gerçek temsili oluştu.

Terran ve Zerg ırklarının birlikleri birbirlerinden tamamen farklıdır. Bir ırktaki birlik diğerinde bulunmamaktadır. Her bir oyuncu her bir oyunda sadece tek bir ırk oynar. Terran birliklerinin tamamı Terran oyuncusuna ve Zerg birliklerinin tamamı Zerg oyuncusuna aittir ve sadece onların kontrolündedir. Terran ırkında Marine ve SCV'ler, Zerg ırkında Zergling ve Dronelar sadece bol kaynak olan mineraller ile üretildiği için çok fazla sayıda oyunda bulunur. Yapay öğrenme modelleri her bir çıkışı Terranlar'da Marine, Zergler'de Zergling olarak çıkardı. Bu sebepten çıkış sütununda Marine, SCV, Zergling ve Drone üretim emri verilen satırlar veri kümesinden çıkarıldı. Oyundaki toplam sayılarını gösteren sütunları korundu. Bina üretme komutu verilen satırlarda Çıkış sütunundan çıkarıldı ve oyundaki toplam sayılarını veren sütunlar korundu.

Terran veri kümesi 70141 satırdan ve Zerg veri kümesi 147794 satırdan ve her biri 62 sütundan oluşmaktadır.

Birliklerin menzillerine göre eğitilmesini sağlamak için Zergler'de Hydralisk, Ultralisk ve Mutalisk yakın menzilli birlikler; Scourge ve Devourer sadece havadan havaya saldıranlar birlikler; Guardian ve Lurker uzun menzilli birlikler; Queen ve Defiler da büyücü birlikleri olarak belirlendi. Zerg Veri Kümesi'ne bir "Range" sütunu oluşturuldu ve her bir satırda üretilen birliğin kendi gruplandırmasına karşılık gelen değer yazıldı. "Çıkış" kolonu düşürüldü ve Zerg Menzil Veri Kümesi elde edildi. Zerg birliklerinin menzilleri ve menzil sınıflamaları sırası ile Tablo 3.6 ve Tablo 3.7'de gösterilmiştir.

Tablo 3.3 Zerg Birliklerinin Menzilleri

Zerg Birlikleri	Menzil
Zerg Ultralisk	Temas
Zerg Mutalisk	3
Zerg Hydralisk	4
Zerg Scourge	Temas
Zerg Devourer	6
Zerg Lurker	6
Zerg Guardian	8
Zerg Queen	Büyücü
Zerg Defiler	Büyücü

Tablo 3.4 Zerg Birliklerinin Menzillerine Göre Sınıflandırması

Zerg Menzil Sınıflaması	Birlikler
Yakın Menzilli Birlikler	Zerg Ultralisk, Zerg Hydralisk, Zerg Mutalisk
Sadece Havadan Havaya Saldıran Birlikler	Zerg Scourge, Zerg Devourer
Uzun Menzilli Birlikler	Zerg Guardian Zerg Lurker
Büyücü Birlikleri	Zerg Queen, Zerg Defiler

Birliklerin menzillerine göre eğitilmesini sağlamak için Terranlar'da Firebat ve Medic çok yakın menzilli yer birlikleri; Vulture ve Goliath orta menzilli yer birlikleri; Wraith, Battlecruiser ve Valkyrie orta menzilli hava birlikleri; Siege Tank ve Nuclear

Missile uzun menzilli yer birlikleri; Ghost ve Science Vessel da büyücü birlikleri olarak belirlendi. Terran Veri Kümesi'ne bir "Range" sütunu oluşturulduğu ve her bir satırda üretilen birliğin kendi gruplandırmasına karşılık gelen değer yazıldı. "Çıkış" kolonu düşürüldü ve Terran Menzil Veri Kümesi elde edildi. Terran birliklerinin menzilleri ve sınıflandırmaları sırası ile Tablo 3.4 ve Tablo 3.5'te gösterilmiştir.

Tablo 3.5 Terran Birliklerinin Menzilleri

Terran Birlikleri	Menzil
Terran Medic	Temas
Terran Firebat	2
Terran Vulture	5
Terran Goliath	5
Terran Wraith	5
Terran Battlecruiser	6
Terran Valkyrie	6
Terran Nuclear Missile	10
Terran Siege Tank	12
Terran Ghost	Büyücü
Terran Science Vessel	Büyücü

Tablo 3.6 Terran Birliklerinin Menzillerine Göre Sınıflandırması

Terran Menzil Sınıflaması	Birlikler
Çok Yakın Menzilli Yer birlikleri	Terran Firebat, Terran Medic
Orta Menzilli Yer Birlikleri	Terran Vulture, Terran Goliath
Orta Menzilli Hava Birlikleri	Terran Wraith, Terran Battlecruiser, Terran Valkyrie
Çok Uzun Menzilli Yer Birlikleri	Terran Siege Tank, Terran Nuclear Missile
Büyücü Birlikleri	Terran Ghost, Terran Science Vessel

Zerg Yakın Menzilli Birlikler Veri Kümesi için Zerg veri kümesinin Çıkış sütununda Zerg Hydralisk, Zerg Ultralisk ve Zerg Mutalisk yer almayan bütün satırlar çıkartıldı ve kalan satırlarla veri kümesi oluşturuldu. Zerg Havadan havaya saldıranlar Birlikler Veri Kümesi için Zerg veri kümesinin Çıkış sütununda Scourge ve Devourer

yer almayan bütün satırlar çıkartıldı ve kalan satırlarla veri kümesi oluşturuldu. Zerg Uzun Menzilli Birlikler Veri Kümesi için Zerg veri kümesinin Çıkış sütununda Zerg Guardian ve Zerg Lurker yer almayan bütün satırlar çıkartıldı ve kalan satırlarla veri kümesi oluşturuldu. Zerg Büyücü Birlikler Veri Kümesi için Zerg veri kümesinin Çıkış sütununda Zerg Queen ve Zerg Defiler yer almayan bütün satırlar çıkartıldı ve kalan satırlarla veri kümesi oluşturuldu.

Terran Yakın Menzilli Yer Birlikleri Veri Kümesi için Terran veri kümesinin Çıkış sütununda Terran Medic ve Terran Firebat yer almayan bütün satırlar çıkartıldı ve kalan satırlarla veri kümesi oluşturuldu. Terran Orta Menzilli Yer Birlikleri Veri Kümesi için Terran veri kümesinin Çıkış sütununda Vulture ve Goliath yer almayan bütün satırlar çıkartıldı ve veri kümesi oluşturuldu. Terran Orta Menzilli Hava birlikleri için Terran veri kümesinin Çıkış sütununda Terran Wraith, Terran Battlecruiser ve Terran Valkyrie yer almayan bütün satırlar çıkartıldı ve veri kümesi oluşturuldu. Terran Uzun Menzilli Yer Birlikleri Veri Kümesi için Terran veri kümesinin Çıkış sütununda Terran Wraith, Terran Battlecruiser ve Terran Valkyrie yer almayan bütün satırlar çıkartıldı ve veri kümesi oluşturuldu. Terran Büyücü Birlikleri Veri Kümesi için Terran veri kümesinin Çıkış sütununda Terran Ghost ve Terran Science Vessel yer almayan bütün satırlar çıkartıldı ve veri kümesi oluşturuldu.

3.3. Önerilen Yapay Öğrenme Modelleri

Terran Veri Kümesi, Zerg Veri Kümesi ve her bir menzile dayalı veri kümesi ayrı ayrı aynı yapay öğrenme modeline verildi. Bu her model için yapıldı. Uzun kısa vadeli hafıza ağılı özyinelemeli sinir ağı modeli hariç bütün modeller için değerler normalize edildi. Verilerin %80'i eğitim kümesi, %20'si test kümesi olarak seçildi. Yapay öğrenme modelleri Tensorflow'da gerçekleştirildi. İleri Beslemeli Sinir Ağı, Uzun Kısa Vadeli Hafıza Ağılı Özyinelemeli Sinir Ağı ve 1B Konvolüsyonel Sinir Ağı modelleri kullanıldı.

3.3.1. İleri Beslemeli Sinir Ağı

İleri beslemeli sinir ağları birbirlerine sık bağlı nöron katmanlarından oluşur (Géron, 2019). Zerg modeli 128 adet yoğun bağlı 4 gizli katman ve bir çıkış katmanından oluşur. Çıkış katmanı 12 nörondan oluşur. Yoğun katmanlar relu aktivasyon fonksiyonu ve çıkış katmanı softmax aktivasyon fonksiyonu ile çalışır. İlk katmanda 7936 parametre, diğer gizli katmanlarda 16512 ve çıkış katmanında 1290

parametre vardır. Toplamda 58,762 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritmasını seçildi. Temel sınıflandırma ve detaylı menzil sınıflandırmasında bu model kullanıldı. İleri beslemeli sinir ağı menzil sınıflandırması Zerg modelinin özeti Şekil 3.6’da verilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış Şekli	Param #
yoğun (Yoğun)	(None, 128)	7936
yoğun_1 (Yoğun)	(None, 128)	16512
yoğun_2 (Yoğun)	(None, 128)	16512
yoğun_3 (Yoğun)	(None, 128)	16512
yoğun_4 (Yoğun)	(None, 10)	1290
Toplam parametre: 58,762		
Eğitilebilir parametre: 58,762		
Eğitilemez parametre: 0		

Şekil 3.6 İleri Beslemeli Sinir Ağı Zerg Modelinin Özeti

Terran modeli 128 adet yoğun bağlı 4 gizli katman ve bir çıkış katmanından oluşur. Çıkış katmanı 12 nörondan oluşur. Yoğun katmanlar relu aktivasyon fonksiyonu ve çıkış katmanı softmax aktivasyon fonksiyonu ile çalışır. İlk katmanda 7936 parametre, diğer gizli katmanlarda 16512 ve çıkış katmanında 1548 parametre vardır. Toplamda 59,020 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. Temel sınıflandırma ve detaylı menzil sınıflandırmasında bu model kullanıldı. İleri beslemeli sinir ağı Terran modelinin özeti Şekil 3.7’de verilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış Shape	Param #
yoğun (Yoğun)	(None, 128)	7936
yoğun_1 (Yoğun)	(None, 128)	16512
yoğun_2 (Yoğun)	(None, 128)	16512
yoğun_3 (Yoğun)	(None, 128)	16512
yoğun_4 (Yoğun)	(None, 12)	1548
Toplam parametre: 59,020		
Eğitilebilir parametre: 59,020		
Eğitilemez parametre: 0		

Şekil 3.7 İleri Beslemeli Sinir Ağı Terran Modelinin Özeti

Menzil sınıflandırması Zerg modelinde 128 adet yoğun bağlı 4 gizli katman ve bir çıkış katmanından oluşur. Çıkış katmanı 10 nörondan meydana gelir. Yoğun katmanlar relu aktivasyon fonksiyonu ve çıkış katmanı softmax aktivasyon fonksiyonu ile çalışır. İlk katmanda 7936 parametre, diğer gizli katmanlarda 16512 ve çıkış katmanında 516 parametre vardır. Toplamda 57,988parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. İleri beslemeli sinir ağı menzil sınıflandırması Zerg modelinin özeti Şekil 3.8’de verilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış şekli	Param #
yoğun (Yoğun)	(None, 128)	7936
yoğun_1 (Yoğun)	(None, 128)	16512
yoğun_2 (Yoğun)	(None, 128)	16512
yoğun_3 (Yoğun)	(None, 128)	16512
yoğun_4 (Yoğun)	(None, 4)	516
Toplam parametre: 57,988 Eğitilebilir parametre: 57,988 Eğitilemez parametre: 0		


Şekil 3.8 İleri Beslemeli Sinir Ağı Menzil Sınıflandırması Zerg Modelinin Özeti

Menzil sınıflandırması Terran modelinde 128 adet yoğun bağlı 4 gizli katman ve bir çıkış katmanından oluşur. Çıkış katmanı 10 nörondan meydana gelir. Yoğun katmanlar relu aktivasyon fonksiyonu ve çıkış katmanı softmax aktivasyon fonksiyonu ile çalışır. İlk katmanda 7936 parametre, diğer gizli katmanlarda 16512 ve çıkış katmanında 645 parametre vardır. Toplamda 58,117 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. İleri beslemeli sinir ağı menzil sınıflandırması Terran modelinin özeti Şekil 3.9’da verilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış şekli	Param #
yoğun (Yoğun)	(None, 128)	7936
yoğun_1 (Yoğun)	(None, 128)	16512
yoğun_2 (Yoğun)	(None, 128)	16512
yoğun_3 (Yoğun)	(None, 128)	16512
yoğun_4 (Yoğun)	(None, 5)	645
Toplam parametre: 58,117 Eğitilebilir parametre: 58,117 Eğitilemez parametre: 0		

Şekil 3.9 İleri Beslemeli Sinir Ağı Menzil Sınıflandırması Terran Modelinin Özeti

Zerg modeli çizimi Şekil 3.10’da gösterilmiştir. Her bir katman birbirine yoğun bağlı, giriş katmanı 61 nöron, gizli katmanlar 128’er nöron ve çıkış katmanı 10 nöron oluşur.



Şekil 3.10 İleri Beslemeli Sinir Ağı Zerg Modeli

3.3.2. Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı

Özyinelemeli sinir ağlarının her bir birliği kendi içinde bir sinir ağıdır. (Géron, 2019) Zerg modelinde Bir lambda boyut yükseltme katmanı geriye doğru 128 birimli uzun kısa vadeli hafıza ağı iki katmana, onlar da bir yoğun çıkış katmanına bağlıdır. Çıkış katmanı 10 nörondan oluşur ve softmax aktivasyon fonksiyonuyla çalışır. İlk uzun kısa vadeli hafıza ağı katmanında 97280 parametre, ikinci uzun kısa vadeli hafıza ağı katmanında 131584 parametre ve çıkış katmanında 1290 parametre vardır. Toplamda 230,154 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. Temel sınıflandırma ve detaylı menzil sınıflandırmasında bu modeli kullanıldı. Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı Zerg modelinin özeti Şekil 3.11’de gösterilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış Shape	Param #
lambda (Lambda)	(None, 1, 61)	0
geriye_doğru_katman (LSTM)	(None, 1, 128)	97280
geriye_doğru_katman_2 (LSTM)	(None, 128)	131584
yoğun (Yoğun)	(None, 10)	1290
=====		
Toplam parametre: 230,154		
Eğitilebilir parametre: 230,154		
Eğitilemez parametre: 0		

Şekil 3.11 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Zerg Modelinin Özeti

Terran modelinde bir lambda boyut yükseltme katmanı geriye doğru 128 birimli uzun kısa vadeli hafıza ağı iki katmana, onlar da bir yoğun çıkış katmanına bağlıdır. Çıkış katmanı 12 nörondan oluşur ve softmax aktivasyon fonksiyonuyla çalışır. İlk uzun kısa vadeli hafıza ağı katmanında 97280 parametre, ikinci uzun kısa vadeli hafıza ağı katmanında 131584 parametre ve çıkış katmanında 1548 parametre vardır. Toplamda 230,154 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. Temel sınıflandırma ve detaylı menzil sınıflandırmasında bu modeli kullanıldı. Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı Terran menzil modelinin özeti Şekil 3.12’de gösterilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış Shape	Param #
lambda (Lambda)	(None, 1, 61)	0
geriye_doğru_katman (LSTM)	(None, 1, 128)	97280
geriye_doğru_katman_2 (LSTM)	(None, 128)	131584
yoğun (Yoğun)	(None, 12)	1548
=====		
Toplam parametre: 230,412		
Eğitilebilir parametre: 230,412		
Eğitilemez parametre: 0		

Şekil 3.12 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Terran Modelinin Özeti

Zerg menzil sınıflaması modelinde bir lambda boyut yükseltme katmanı geriye doğru 128 birimli uzun kısa vadeli hafıza ağı iki katmana, onlar da bir yoğun çıkış katmanına bağlıdır. Çıkış katmanı 10 nörondan oluşur ve softmax aktivasyon fonksiyonuyla çalışır. İlk uzun kısa vadeli hafıza ağı katmanında 97280 parametre, ikinci uzun kısa vadeli hafıza ağı katmanında 131584 parametre ve çıkış katmanında 516 parametre vardır. Toplamda 229,380 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı Zerg menzil modelinin özeti Şekil 3.13'te gösterilmiştir.


Model: "sırayla"		
Katman (tür)	Çıkış şekli	Param #
lambda (Lambda)	(None, 1, 61)	0
geriye_doğru_katman (LSTM)	(None, 1, 128)	97280
geriye_doğru_katman_2 (LSTM)	(None, 128)	131584
yoğun (Yoğun)	(None, 4)	516
Toplam parametre: 229,380 Eğitilebilir parametre: 229,380 Eğitilemez parametre: 0		

Şekil 3.13 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Zerg Menzil Sınıflandırması Modelinin Özeti

Terran menzil sınıflaması modelinde bir lambda boyut yükseltme katmanı geriye doğru 128 birimli uzun kısa vadeli hafıza ağı iki katmana, onlar da bir yoğun çıkış katmanına bağlıdır. Çıkış katmanı 10 nörondan oluşur ve softmax aktivasyon fonksiyonuyla çalışır. İlk uzun kısa vadeli hafıza ağı katmanında 97280 parametre, ikinci uzun kısa vadeli hafıza ağı katmanında 131584 parametre ve çıkış katmanında 645 parametre vardır. Toplamda 229,509 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı Terrain menzil modelinin özeti Şekil 3.14’te gösterilmiştir. Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı modeli Şekil 3.15’te gösterilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış şekli	Param #
=====		
lambda (Lambda)	(None, 1, 61)	0
geriye_doğru_katman (LSTM)	(None, 1, 128)	97280
geriye_doğru_katman_2 (LSTM)	(None, 128)	131584
yoğun (Yoğun)	(None, 5)	645
=====		
Toplam parametre: 229,509		
Eğitilebilir parametre: 229,509		
Eğitilemez parametre: 0		

Şekil 3.14 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Terran Menzil Sınıflandırması Modelinin Özeti



Şekil 3.15 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modeli

3.3.3. 1B Konvolüsyonel Model

1 boyutlu konvolüsyonel modelde girişler filtrelenerek bir sonraki katmana iletilir (Géron, 2019). Zerg 1B konvölüsyonel model bir lambda boyut yükseltme katmanı, 256 filtreli ve 1 çekirdek alanlı katman ardından bir büyütme örnekleme katmanı, ardından bir tane daha 256 filtreli 1 çekirdek alanlı katman, ardından mutlak büyütme örnekleme katmanı ve çıkış katmanından oluşur. Çıkış katmanı 10 nörondan oluşur ve softmax aktivasyon fonksiyonu ile çalışır. İlk konvolüsyonel katmanda 15872 parametre, ikinci konvolüsyonel katmanında 65792 parametre ve çıkış katmanında 2570 parametre vardır. Toplamda 84,234 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve

iyileştirici 0.001 öğrenme oranı ile Adam algoritmasını seçtik. Temel sınıflandırma ve detaylı menzil sınıflandırmasında bu modeli kullandık. 1B konvolüsyonel Zerg modelinin özeti şekil 3.16’da verilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış Shape	Param #
lambda (Lambda)	(None, 1, 61)	0
konv1b (Conv1D)	(None, 1, 256)	15872
büyütme_örnekleme1b (BüyükÖrnekleme1B)	(None, 1, 256)	0
konv1b (Conv1D)	(None, 1, 256)	65792
mutlak_büyütme_örnekleme1b (MutlakBüyükÖrnekleme1B)	(None, 256)	0
yoğun_4 (Yoğun)	(None, 10)	2570
Toplam parametre: 84,234 Eğitilebilir parametre: 84,234 Eğitilemez parametre: 0		

Şekil 3.16 1B Konvolüsyonel Zerg Modelinin Özeti

Terran 1B konvölüsyonel model bir lambda boyut yükseltme katmanı, 256 filtreli ve 1 çekirdek alanlı katman ardından bir büyütme örnekleme katmanı, ardından bir tane daha 256 filtreli 1 çekirdek alanlı katman, ardından mutlak büyütme örnekleme katmanı ve çıkış katmanından oluşur. Çıkış katmanı 10 nörondan oluşur ve softmax aktivasyon fonksiyonu ile çalışır. İlk konvolüsyonel katmanda 15872

parametre, ikinci konvolüsyonel katmanında 65792 parametre ve çıkış katmanında 3084 parametre vardır. Toplamda 84,748 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. Temel sınıflandırma ve detaylı menzil sınıflandırmasında bu modeli kullandık. 1B konvolüsyonel Terran modelinin özeti Şekil 3.17’de verilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış Shape	Param #
lambda (Lambda)	(None, 1, 61)	0
konv1b (Conv1D)	(None, 1, 256)	15872
büyütme_örnekleme1b (BüyükÖrnekleme1B)	(None, 1, 256)	0
konv1b_1 (Conv1D)	(None, 1, 256)	65792
mutlak_büyütme_örnekleme1b (MutlakBüyükÖrnekleme1B)	(None, 256)	0
yoğun (Yoğun)	(None, 12)	3084
Toplam parametre: 84,748 Eğitilebilir parametre: 84,748 Eğitilemez parametre: 0		

Şekil 3.17 1B Konvolüsyonel Terran Modelinin Özeti

Zerg menzil sınıflaması 1B konvölüsyonel model bir lambda boyut yükseltme katmanı, 256 filtrelili ve 1 çekirdek alanlı katman ardından bir büyütme örnekleme katmanı, ardından bir tane daha 256 filtrelili 1 çekirdek alanlı katman, ardından mutlak

büyütme örnekleme katmanı ve çıkış katmanından oluşur. Çıkış katmanı 10 nöron dan oluşur ve softmax aktivasyon fonksiyonu ile çalışır. İlk konvolüsyonel katmanda 15872 parametre, ikinci konvolüsyonel katmanında 65792 parametre ve çıkış katmanında 1028 parametre vardır. Toplamda 82,692 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. 1B konvolüsyonel zerg menz il sınıflandırması modelinin özeti Şekil 3.18’de verilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış şekli	Param #
lambda (Lambda)	(None, 1, 61)	0
konv1b (Conv1D)	(None, 1, 256)	15872
büyütme_örnekleme1b (BüyükÖrnekleme1B)	(None, 1, 256)	0
konv1b_1 (Conv1D)	(None, 1, 256)	65792
mutlak_büyütme_örnekleme1b (MutlakBüyükÖrnekleme1B)	(None, 256)	0
yoğun (Yoğun)	(None, 4)	1028
Toplam parametre: 82,692		
Eğitilebilir parametre: 82,692		
Eğitilemez parametre: 0		


Şekil 3.18 1B Konvolüsyonel Zerg Menz il Sınıflandırması Modelinin Özeti

Terran menz il sınıflaması 1B konvölüsyonel model bir lambda boyut yükseltme katmanı, 256 filtreli ve 1 çekirdek alanlı katman ardından bir büyütme

örnekleme katmanı, ardından bir tane daha 256 filtrelili 1 çekirdek alanlı katman, ardından mutlak büyütme örnekleme katmanı ve çıkış katmanından oluşur. Çıkış katmanı 10 nöronlardan oluşur ve softmax aktivasyon fonksiyonu ile çalışır. İlk konvolüsyonel katmanda 15872 parametre, ikinci konvolüsyonel katmanında 65792 parametre ve çıkış katmanında 1285 parametre vardır. Toplamda 82,949 parametre bulunur ve hepsi eğitilebilirdir. Metrik doğruluk, kayıp kategorik çapraz entropi ile belirlendi ve iyileştirici 0.001 öğrenme oranı ile Adam algoritması seçildi. 1B konvolüsyonel Zerg modelinin özeti Şekil 3.19’da gösterilmiştir. 1B konvolüsyonel model şekil 3.20’de gösterilmiştir.

Model: "sırayla"		
Katman (tür)	Çıkış şekli	Param #
lambda (Lambda)	(None, 1, 61)	0
konv1b (Conv1D)	(None, 1, 256)	15872
büyütme_örnekleme1b (BüyükÖrnekleme1B)	(None, 1, 256)	0
konv1b_1 (Conv1D)	(None, 1, 256)	65792
mutlak_büyütme_örnekleme1b (MutlakBüyükÖrnekleme1B)	(None, 256)	0
yoğun (Yoğun)	(None, 5)	1285
Toplam parametre: 82,949		
Eğitilebilir parametre: 82,949		
Eğitilemez parametre: 0		

Şekil 3.19 1B Konvolüsyonel Terran Menzil Sınıflandırması Modelinin Özeti



Şekil 3.20 1B Konvolüsyonel Model

4. BULGULAR

Bu bölümde yapay öğrenme modellerinden ileri beslemeli sinir ağı, uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı ve 1B konvolüsyonel modelden elde edilen bulgular sunulacaktır. Veri kümesi %80 oranında eğitime, %20 oranında sınamaya ayrıldı. İleri beslemeli sinir ağı ve 1B konvolüsyonel model için değerler normalleştirildi. Modeller 100 epoch eğitildi. Hata düzeyi, sınıflandırma raporu, işlem karakteristik eğrisi ve bu eğrinin altında kalan kısım kullanılarak sonuçlar anlatıldı.

Hata düzeyi gerçek değerler ve tahmini değerleri gösteren dört farklı kombinasyonu içeren bir tablodur. Hata düzeyi tablosundan sınıflandırılan etiketlerin yüzde kaçının doğru sınıflandırıldığını gösteren doğruluk, pozitif tahmin edilmesi gereken etiketlerin ne kadarının pozitif tahmin edildiğini gösteren duyarlılık ve pozitif olarak tahmin edilen değerlerin gerçekte kaç tanesinin pozitif olduğunu gösteren kesinlik anlaşılır.

Doğruluk sınıflandırılan etiketlerin yüzde kaçının doğru sınıflandırıldığını gösterir. Doğruluk, denklem 4.1’de gösterildiği gibi, gerçek pozitif ve gerçek negatif tahminlerin toplamının gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif tahminlerin toplamına oranıdır.

$$\text{Doğruluk} = \frac{GP + GN}{GP + GN + YP + YN} \quad (4.1)$$

Duyarlılık pozitif tahmin edilmesi gereken etiketlerin yüzde kaçının pozitif tahmin edildiğini gösterir. Duyarlılık, denklem 4.2’de gösterildiği gibi, gerçek pozitif tahminlerin gerçek pozitif ve yanlış negatif tahminlerin toplamına oranıdır.

$$\text{Duyarlılık} = \frac{GP}{GP + YN} \quad (4.2)$$

Kesinlik pozitif tahmin edilen değerlerin gerçekte yüzde kaçının pozitif olduğunu gösterir. Kesinlik, denklem 4.3'te gösterildiği gibi, gerçek pozitif değerinin gerçek pozitif ve yanlış pozitif sayılarının toplamına oranıdır.

$$\text{Kesinlik} = \frac{GP}{GP + YP} \quad (4.3)$$

F1 puanı duyarlık ve kesinliğin harmonik ortalamasıdır. Simetrik olarak hem duyarlılık hem de kesinliği tek bir ölçüde gösterir. F1 puanı, denklem 4.4'te gösterildiği gibi, kesinlik ve duyarlılığın iki ile çarpımının kesinlik ve duyarlılığın toplamına oranıdır.

$$\text{F1 puanı} = 2 \cdot \frac{\text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4.4)$$

Sınıflandırma raporunda doğruluk, duyarlık ve kesinlik gösterildi. ROC eğrisi farklı eşikler için modelin doğruluğunu gösterir. Bu eğrinin altında kalan alan modelin performansının bir ölçüsüdür. Zerg veri kümelerinde 10, Terran veri kümelerinde 12, menzil sınıflamasında Zerglerde 4, Terranlarda 5 tane ROC eğrisi bulunuyor. Model değerlendirmesinde eğrilerin altındaki alanların ortalaması alındı.

4.1. İleri Beslemeli Sinir Ağı

Zerg veri kümesi ile eğittiğimiz ileri beslemeli sinir ağının hata düzeyinde her bir sınıfı tahmin etmedeki başarısı görülmektedir. Modele ait hata düzeyi Şekil 4.1'de verilmektedir. Hata düzeyinde Zerg Mutalisk sınıfına ait tahminlerin 3203 adet tahmin ve %85.8 duyarlılık ile en iyisi olduğu görülür. Zerg Defiler sınıfının 436 adet doğru tahmin ve %27.2 duyarlılık ile en düşük doğrulukla sınıflandırılan birlik olduğu görülür. Zerg Hydralisk %79,9, Zerg Ultralisk %78,4, Zerg Overlord %57,5, Zerg Guardian %78,1, Zerg Queen %59,2, Zerg Scourge %42,2, Zerg Devourer %80,8, Zerg Lurker %58,9 duyarlılığa sahiptir. Doğru tahmin oranı %68'dir.




Şekil 4.1 İleri Beslemeli Sinir Ağı Modelinde Zerg Hata Dizeyi

Kesinlik sıralamasında Zerg Guardian %88 ile ilk sırada yer alırken, Zerg Defiler %41 ile son sıradadır. Duyarlılık ölçütünde Zerg Hydralisk %80 ile ilk sırada yer alırken, Zerg Defiler %27 ile son sırada yer alıyor. En iyi f1 puanını %83 ile Zerg Mutalisk ve Zerg Guardian paylaşıırken, en düşük %0,33 puanını Zerg Defiler birliği alır. Ortalama f1 puanı 0,65'tir. Model doğruluğu Şekil 4.2'de %68 olarak görülmektedir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Hydralisk	0.73	0.80	0.76	9907
Zerg Ultralisk	0.64	0.78	0.70	2745
Zerg Overlord	0.68	0.58	0.62	3999
Zerg Mutalisk	0.81	0.86	0.83	3733
Zerg Guardian	0.88	0.78	0.83	342
Zerg Queen	0.49	0.59	0.54	76
Zerg Defiler	0.41	0.27	0.33	1603
Zerg Scourge	0.50	0.42	0.46	2607
Zerg Devourer	0.75	0.81	0.78	26
Zerg Lurker	0.62	0.59	0.60	4521
doğruluk			0.68	29559
makro ort	0.65	0.65	0.65	29559
ağırlıklı ort	0.67	0.68	0.67	29559


Şekil 4.2 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sınıflandırma Raporu

En yüksek ROC-AUC değeri 1 alan ile Zerg Guardian ve Zerg Devourer birliklerine aittir. En düşük alan 0,88 ile Zerg Scourge birliğine aittir. ROC eğrilerine ve AUC değerlerine baktığımızda modelin genel olarak ayırt ediciliğinin iyi olduğu ve iyi tahmin yaptığı görülmektedir. ROC eğrileri ve AUC değerleri Şekil 4.3'te gösterilmiştir.



Şekil 4.3 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin ROC Eğrileri ve AUC Alanları

Zerglerin menzil sınıflandırmasında 14375 adet doğru tahmin ve %88 duyarlılıkla yakın menzil sınıfını en iyi sonucu verir. En düşük doğruluk 548 adet doğru tahmin ve %33,8 duyarlılıkla büyücüler sınıfında yer alır. Sadece havadan havaya saldıranlar sınıfı %51,2 ve uzun menzil birlikler sınıfı %58,1 duyarlılığa sahiptir. Ortalama doğruluk %75 değerindedir. Hata düzeyi Şekil 4.4'de verilmiştir.




Şekil 4.4 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzil Hata Dizeyi

Yakın menzil %82 ile en yüksek kesinliğe sahipken, büyücü sınıfı %43 ile en düşük kesinliğe sahiptir. Duyarlılıkta yakın menzil %88 ile ilk sıradayken, büyücü %34 ile son sırada yer alır. En yüksek f1-puanı 0,85 ile yakın menzil sınıfında ve en düşük f1 puanı 0.38 ile büyücü sınıfında bulunuyor. Ortalama f1 puanı 0.60'tır. Doğruluk %75 değerindedir. Zerglerin menzil sınıflandırma raporu Şekil 4.5'te verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Yakın menzil	0.81	0.88	0.85	16341
Havadan havaya	0.54	0.51	0.53	2645
Uzun menzil	0.69	0.58	0.63	4950
Büyücü	0.43	0.34	0.38	1619
doğruluk			0.75	25555
makro ort	0.62	0.58	0.60	25555
ağırlıklı ort	0.74	0.75	0.74	25555

Şekil 4.5 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzil Sınıflandırma Raporu


En yüksek ROC-AUC değeri 0,92 alanla uzun menzilli birlikler sınıfında ve en düşük alan 0,88 alan ile yakın menzilli ve büyücü birlikleri sınıfındadır. ROC eğrileri ve AUC değerleri Şekil 4.6'da gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.6 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin ROC Eğrileri ve AUC Alanları

Zerglerin detaylı menzil sınıflandırmasında yakın menzilde 9626 doğru tahmin ve %97,9 duyarlılık ile Zerg Hydralisk en iyi sonucu alır. En düşük doğru tahmini

3511 tane tahmin ve %92 duyarlılık oranı ile Zerg Mutaliskler alır. Zerg Ultralisk sınıfı 2559 adet doğru tahmin ve %93,3 duyarlılık oranına sahiptir. Detaylı yakın menzil hata dizeyi Şekil 4.7’de verilmiştir. Doğruluk oranı %96 değerindedir.




Şekil 4.7 İleri Beslemeli Sinir Ağı Zerglerin Yakın Menzil Hata Dizeyi

Yakın menzil detaylı sınıflandırmada Zerg Hydralisk 9626 tane doğru tahmin ve %96 kesinlik ile birinci, Zerg Ultralisk %95 ile son sırada yer alır. Zerg Ultralisk 0,95 kesinliğe sahiptir. Duyarlılıkta Zerg Hydralisk %98 ile ilk sırada yer alırken, Zerg Mutalisk %93 ile son sırada yer almaktadır. Zerg Ultralisk 0,93 duyarlılığa sahiptir. Zerg Hydralisk %97 ile en yüksek f1 puanına sahipken, Zerg Mutalisk ve Zerg Ultralisk %94 f1 puanına sahiptir. Ortalama f1 puanı 0,95’tir. Doğruluk %96 değerindedir. Detaylı yakın menzil sınıflandırma raporu Şekil 4.8’ de gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Hydralisk	0.96	0.98	0.97	9831
Zerg Ultralisk	0.95	0.93	0.94	2743
Zerg Mutalisk	0.96	0.92	0.94	3818
doğruluk			0.96	16392
makro ort	0.96	0.94	0.95	16392
ağırlıklı ort	0.96	0.96	0.96	16392

Şekil 4.8 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Yakın Menzil Sınıflandırma Raporu

Zerg sadece havadan havaya saldırılar detaylı menzil sınıflandırmasında Zerg Scourge 2627 adet doğru tahmin ve %100 duyarlılık alır ve Zerg Devourer 35 adet doğru tahmin ve %94,6 duyarlılık alır. Zerg sadece havadan havaya saldırılar detaylı menzil hata dizeyi Şekil 4.9'de gösterilmiştir.



Şekil 4.9 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sadece Havadan Havaya Saldırıların Hata Dizeyi


Zerg Scourge 1 kesinlik ve Zerg Devourer 0,97 kesinliğe sahiptir. Zerg Scourge 1 duyarlılık değerine ve Zerg Devourer 0.95 duyarlılık değerine sahiptir. Zerg Scourge

1 f1-puanı alırken Zerg Devourer 0,96 puan alır. Ortalama f1 puanı 0,98'dir. Doğruluk %100'dür. Zerg sadece havadan havaya saldırımlar menzile sınıflandırması Şekil 4.10'da verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Scourge	1.00	1.00	1.00	2628
Zerg Devourer	0.97	0.95	0.96	37
doğruluk			1.00	2665
makro ort	0.99	0.97	0.98	2665
ağırlıklı ort	1.00	1.00	1.00	2665

Şekil 4.10 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sadece Havadan Havaya Saldırımlar Sınıflandırma Raporu

Zerg uzun menzile detaylı sınıflamasında Zerg Guardian 345 adet doğru tahmin ve %98,3 duyarlılık oranı alırken, Zerg Lurker 4491 adet doğru tahmin ve %99,7 duyarlılık elde eder. Zerglerin uzun menzile detaylı sınıflamasının hata düzeyi Şekil 4.11' de gösterilmiştir.




Şekil 4.11 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Uzun Menzile Hata Düzeyi

Zerg Guardian birliđi %97, Zerg Lurker birliđi %100 kesinlik elde eder. Zerg Guardian sınıfı %98 duyarlılık ve Zerg Lurker sınıfı %100 duyarlılıđa sahiptir. Zerg Guardian sınıfının f1 puanı %97 ve Zerg Lurker sınıfının f1 puanı %100'dür. Ortalama f1 puanı 0.99'dur. Doğruluk oranı %100'dür. Zerg detaylı uzun menzil sınıflamasının sınıflandırma raporu Şekil 4.12'de gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Guardian	0.97	0.98	0.97	351
Zerg Lurker	1.00	1.00	1.00	4503
doğruluk			1.00	4854
makro ort	0.98	0.99	0.99	4854
ağırlıklı ort	1.00	1.00	1.00	4854

Şekil 4.12 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Uzun Menzil Sınıflandırma Raporu

Zerg büyücüler detaylı sınıflamasında Zerg Queen 65 adet doğru tahmin ve %90,3 duyarlılıđa sahiptir. Zerg Defiler 1555 adet doğru tahmin ve %98,8 duyarlılıđa sahiptir. Zerg büyücüler detaylı menzil sınıflandırması hata dizeyi Şekil 4.13'de gösterilmiştir.



Şekil 4.13 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Büyücü Hata Dizeyi

Zerg büyücüler detaylı menzil sınıflandırmasında Zerg Queen 0.7 kesinlik ve Zerg Defiler 1 kesinlik alır. Zerg Queen 0.9 duyarlılık ve Zerg Defiler 0.99 duyarlılık değeri alır. Zerg Queen 0.83 f1 puanı alırken, Zerg Defiler 0.99 f1 puanı alır. Ortalama f1 puanı 0.91'dir. Doğruluk oranı %98'dir. Zerg büyücü sınıflamasının sınıflandırma raporu Şekil 4.14'te verilmiştir.


	kesinlik	duyarlılık	f1-puanı	destek
Zerg Queen	0.77	0.90	0.83	72
Zerg Defiler	1.00	0.99	0.99	1574
doğruluk			0.98	1646
makro ort	0.88	0.95	0.91	1646
ağırlıklı ort	0.99	0.98	0.98	1646

Şekil 4.14 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Büyücü Sınıflandırma Raporu

Yakın menzil detaylı sınıflandırmada %100 duyarlılık ile Zerg Lurker, Zerg Scourge ve Zerg Defiler en iyi değerlere sahiptir. %77 ile Zerg Queen sınıfı en düşük

kesinlik değerine sahiptir. Duyarlılıkta Zerg Lurker ve Zerg Scourge %100 değeri ile en iyi değere sahipken, Zerg Mutalisk %92 ile en düşük değere sahiptir. En yüksek f1-puanı 1 ile Zerg Lurker ve Zerg Scourge sınıflarındadır.


ROC-AUC değerlerinde 1 alan ile en yüksek değer alan Zerg Ultralisk, Zerg Scourge, Zerg Devourer, Zerg Guardian ve Zerg Lurker sınıflarıdır. En düşük değer 0,98 ile Zerg Defiler sınıfındadır. ROC eğrilerinin dik ve sol üst köşeye yakın olmalarından modelimizin ayırt ediciliğinin ve performansının çok iyi olduğunu anlayabiliriz. Zerg detaylı menzil sınıflamasının ROC eğrileri ve AUC değerleri Şekil 4.15'te verilmiştir.



Şekil 4.15 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Detaylı Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları

Terran veri kümesi ile eğittimiz ileri beslemeli sinir ağının hata düzeyinde her bir sınıfı tahmin etmedeki başarısı görünmekteydi. Modele ait hata düzeyi Şekil 4.16'da verilmektedir. Hata düzeyinde Terran Goliath sınıfına ait tahminlerin 1581 adet tahmin ve %81,6 duyarlılık ile en iyisi olduğu görülür. Terran Nuclear Missile sınıfının 0 adet doğru tahmin ile en düşük doğrulukta olduğu görülür. Terran Ghost %80, Terran Vulture %58,9, Terran Siege Tank %33,8, Terran Wraith %72,7, Terran Science Vessel %19,5, Terran Dropship %9,6, Terran Battlecruiser %39,8, Terran Firebat

%56,1, Terran Medic %67,2, Terran Valkyrie %21,8 duyarlılık yüzdesine sahiptir. Ortalama doğru tahmin oranı %53'tür.




Şekil 4.16 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesi Hata Dizeyi

Kesinlik sıralamasında Terran Goliath %62 ile ilk sırada yer alırken, Terran Nuclear Missile %0 ile son sıradadır. Duyarlılık ölçütünde Terran Goliath %82 ile ilk sırada yer alırken, Terran Nuclear Missile %0 ile son sırada yer alır. En iyi f1 puanını %76 ile Terran Goliath alırken, en düşük %0 puanını Terran Nuclear Missile birliği alır. Ortalama f1 puanı 0.44'tür. Model doğruluğu Şekil 4.17'de %53 olarak görülmektedir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Ghost	0.62	0.80	0.70	10
Terran Vulture	0.54	0.59	0.57	2097
Terran Goliath	0.71	0.82	0.76	1937
Terran Siege Tank	0.43	0.34	0.38	2685
Terran Wraith	0.64	0.73	0.68	187
Terran Science Vessel	0.33	0.19	0.24	1863
Terran Dropship	0.15	0.10	0.12	240
Terran Battlecruiser	0.52	0.40	0.45	83
Terran Nuclear Missile	0.00	0.00	0.00	3
Terran Firebat	0.56	0.56	0.56	1441
Terran Medic	0.53	0.67	0.59	3428
Terran Valkyrie	0.32	0.22	0.26	55
doğruluk			0.53	14029
makro ort	0.45	0.45	0.44	14029
ağırlıklı ort	0.51	0.53	0.51	14029


Şekil 4.17 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Sınıflandırma Raporu

En yüksek ROC-AUC değeri 0,99 alan ile Terran Ghost ve Terran Nuclear Missile birliklerine aittir. En düşük alan 0,75 ile Terran Science Vessel birliğine aittir. ROC eğrileri ve AUC değerleri Şekil 4.18’de gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.18 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin ROC Eğrileri ve AUC Alanları

Terranların menzil sınıflandırmasında 3385 adet doğru tahmin ve %82 duyarlılıkla orta menzilli yer birlikleri sınıfının en iyi sonucu verir. En düşük doğruluk 462 adet doğru tahmin ve %25,3 duyarlılıkla büyücüler sınıfında yer alır. Ortalama doğruluk %62'dir. Hata dizeyi Şekil 4.19'da vermiştir.




Şekil 4.19 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Hata Dizeyi

Orta menzilli yer birlikleri %72 ile en yüksek kesinliğe sahipken, büyücü sınıfı %34 ile en düşük kesinliğe sahiptir. Duyarlılıkta orta menzilli yer birlikleri %82 ile ilk sıradayken, büyücü %25 ile son sırada yer alır. En yüksek f1-puanı 0,77 ile orta menzilli yer birlikleri sınıfında ve en düşük f1 puanı 0,29 ile büyücü sınıfında bulunuyor. Ortalama f1 puanı 0,54'tür. Doğruluk %62'dir. Terranların menzil sınıflandırma raporu Şekil 4.20'de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Çok yakın menzilli yer	0.67	0.76	0.71	4951
Orta menzilli yer	0.72	0.82	0.77	4130
Orta menzilli hava	0.63	0.52	0.57	307
Çok Uzun menzilli yer	0.44	0.32	0.37	2576
Büyücü	0.34	0.25	0.29	1824
doğruluk			0.62	13788
makro ort	0.56	0.53	0.54	13788
ağırlıklı ort	0.60	0.62	0.61	13788


Şekil 4.20 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Sınıflandırma Raporu

En yüksek ROC-AUC değeri 0.96 alanla orta menzilli yer birlikleri sınıfında ve en düşük alan 0,76 alan ile büyücü birlikleri sınıfındadır. ROC eğrileri ve AUC değerleri Şekil 4.21’de gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.21 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin ROC Eğrileri ve AUC Alanları

Terranların detaylı menzil sınıflandırmasında çok yakın menzilde 3092 doğru tahmin ve %88,5 duyarlılık ile Terran Medic en iyi sonucu alır. Terran Firebat 1003 tane tahmin ve %70,1 duyarlılık oranı elde eder. Detaylı çok yakın menzil hata dizeyi Şekil 4.22’de verilmiştir. Doğruluk oranı %79’dur.




Şekil 4.22 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Yakın Menzil Hata Dizeyi

Terran Firebat 0,71 kesinlik ve Terran Medic 0,88 kesinliğe sahiptir. Terran Firebat 0,0 duyarlılık değerine ve Terran Medic 0,89 duyarlılık değerine sahiptir. Terran Firebat 0,71 f1-puanı alırken Terran Medic 0.88 puan alır. Ortalama f1 puanı 0,79’dır. Doğruluk %83’tür. Terran çok yakın menzil sınıflandırması Şekil 4.23’te verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Firebat	0.71	0.70	0.71	1431
Terran Medic	0.88	0.89	0.88	3492
doğruluk			0.83	4923
makro ort	0.80	0.79	0.79	4923
ağırlıklı ort	0.83	0.83	0.83	4923

Şekil 4.23 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin ÇokYakın Menzil Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında orta menzilli yer birlikleri sınıflamasında 1842 doğru tahmin ve %91,8 duyarlılık ile Terran Goliath en iyi sonucu alır. Terran Vulture 1856 tane tahmin ve %89,7 duyarlılık oranı elde eder. Detaylı orta menzilli yer birlikleri hata dizeyi Şekil 4.24’te verilmiştir. Doğruluk oranı %91’dir.



Şekil 4.24 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Yer Birliklerinin Hata Dizeyi


Terran Vulture 0,92 kesinlik ve Terran Goliath 0.90 kesinliğe sahiptir. Terran Vulture 0,90 duyarlılık değerine ve Terran Goliath 0.92 duyarlılık değerine sahiptir.

Terran Vulture 0,91 f1-puanı alırken Terran Goliath 0.91 puan alır. Ortalama f1 puanı 0,91’dir. Doğruluk %91’tür. Terran orta menzilli yer birlikleri sınıflaması Şekil 4.25’te verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Vulture	0.92	0.90	0.91	2070
Terran Goliath	0.90	0.92	0.91	2006
doğruluk			0.91	4076
makro ort	0.91	0.91	0.91	4076
ağırlıklı ort	0.91	0.91	0.91	4076

Şekil 4.25 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Yer Birliklerinin Sınıflandırma Raporu

Terranların orta menzilli hava birlikleri detaylı sınıflandırmasında Terran Wraith 10505 adet tahmin ve %99,6 duyarlılık ile en iyi sonucu alır. En düşük doğru tahmini 14 tahmin ve %26,9 ile Terran Valkyrie alır. Terran Battlecruiser sınıfı 54 adet doğru tahmin ve %67,5 duyarlılık oranına sahiptir. Detaylı orta menzilli hava birlikleri hata dizeyi Şekil 4.26’da verilmiştir.




Şekil 4.26 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Hava Birliklerinin Hata Dizeyi

Orta menzilli hava birlikleri sınıflandırmasında Terran Wraith %99 kesinlik ile birinci, Terran Valkyrie %54 ile son sırada yer alır. Terran Battlecruiser 0.61 değerinde kesinliğe sahiptir. Duyarlılıkta Terran Wraith %100 ile ilk sırada yer alırken, Terran Valkyrie %27 ile son sırada yer almaktadır. Terran Battlecruiser %68 duyarlılık değeri almaktadır. Terran Wraith %99 ile en yüksek f1 puanına sahipken, Terran Battlecruiser %64 ve Terran Valkyrie %36 f1 puanına sahiptir. Ortalama f1 puanı 0,66'dır. Doğruluk %99'dur. Detaylı orta menzilli hava birlikleri sınıflandırma raporu Şekil 4.27'de gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Wraith	0.99	1.00	0.99	10551
Terran Battlecruiser	0.61	0.68	0.64	80
Terran Valkyrie	0.54	0.27	0.36	52
doğruluk			0.99	10683
makro ort	0.71	0.65	0.66	10683
ağırlıklı ort	0.99	0.99	0.99	10683

Şekil 4.27 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Hava Birliklerinin Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında çok uzun menzilli yer birlikleri sınıflamasında 2603 doğru tahmin ve %100 duyarlılık ile Terran Siege Tank en iyi sonucu alır. Terran Nuclear Missile 2 tane doğru tahmin ve %40 duyarlılık oranı elde eder. Detaylı çok uzun menzil hata düzeyi Şekil 4.28’de verilmiştir.



Şekil 4.28 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Uzun Menzilli Yer Birliklerinin Hata Dizeyi


Terran Siege Tank ve Terran Nuclear Missile 1 kesinliğe sahiptir. Terran Siege Tank 1 duyarlılık değerine ve Terran Nuclear Missile 0,40 duyarlılık değerine sahiptir.

Terran Siege Tank 1 f1-puanı alırken Terran Nuclear Missile 0,57 puan alır. Ortalama f1 puanı 0.79'dur. Doğruluk %100'dür. Terran çok uzun menzil sınıflandırması Şekil 4.29'da verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Siege Tank	1.00	1.00	1.00	2603
Terran Nuclear Missile	1.00	0.40	0.57	5
doğruluk			1.00	2608
makro ort	1.00	0.70	0.79	2608
ağırlıklı ort	1.00	1.00	1.00	2608

Şekil 4.29 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Uzun Menzilli Yer Birliklerinin Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında büyücü birlikleri sınıflamasında 1873 doğru tahmin ve %99,8 duyarlılık ile Terran Science Vessel en iyi sonucu alır. Terran Ghost 6 tane doğru tahmin ve %75 duyarlılık elde eder. Detaylı büyücü birlikleri hata dizeyi Şekil 4.30'da verilmiştir.




Şekil 4.30 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Büyücü Birliklerinin Hata Dizeyi

Terran Science Vessel 1 kesinliğe ve Terran Ghost 0,67 kesinliğe sahiptir. Terran Science Vessel 1 duyarlılık değerine ve Terran Ghost 0,75 duyarlılık değerine sahiptir. Terran Science Vessel 1 f1-puanı alırken Terran Ghost 0,71 puan alır. Ortalama f1 puanı 0.85'tir. Doğruluk %100'dür. Terran büyücü birlikleri sınıflaması Şekil 4.31'de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Ghost	0.67	0.75	0.71	8
Terran Science Vessel	1.00	1.00	1.00	1876
doğruluk			1.00	1884
makro ort	0.83	0.87	0.85	1884
ağırlıklı ort	1.00	1.00	1.00	1884

Şekil 4.31 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Büyücü Birliklerinin Sınıflandırma Raporu


ROC-AUC değerlerinde 1 alan ile en yüksek değer alan Terran Battlecruiser, Terran Nuclear Missile, Terran Ghost ve Terran Science Vessel sınıflarıdır. En düşük değer 0,80 ile Terran Siege Tank sınıfındadır. ROC eğrilerinin diyagonalin üstünde bulunmasından ve eğrilerin çoğunluğunun sol üst köşeye yakın olmasından modelimizin ayırt ediciliğinin ve performansının iyi olduğunu anlayabiliriz. Terran detaylı menzil sınıflamasının ROC eğrileri ve AUC değerleri Şekil 4.32'de verilmiştir.



Şekil 4.32 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Detaylı Menzili Sınıflamasının ROC Eğrileri ve AUC Alanları

4.2. Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı

Zerg veri kümesi ile uzun kısa vadeli hafıza ağı özyinelemeli sinir ağının hata düzeyinde her bir sınıfı tahmin etmedeki başarısı görünmektedir. Modele ait hata düzeyi Şekil 4.33'de verilmektedir. Hata düzeyinde Zerg Mutalisk sınıfına ait tahminlerin 3146 adet tahmin ve %84,3 duyarlılık ile en iyisi olduğu görülür. Zerg Defiler sınıfının 429 adet tahmin ve %26,8 duyarlılık ile en düşük doğrulukla sınıflandırılan birlik olduğu görülür. Zerg Hydralisk %77,3, Zerg Ultralisk %77,4, Zerg Overlord %60,9, Zerg Guardian %81, Zerg Queen %50, Zerg Scourge %45,1, Zerg Devourer %69,2, Zerg Lurker %61,6 duyarlılığa sahiptir. Ortalama doğru tahmin oranı %68'dir.




Şekil 4.33 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sınır Ağı Modelinde Zerg Veri Kümesinin Hata Dizeyi

Kesinlik sıralamasında Zerg Guardian %87 ile ilk sırada yer alırken, Zerg Defiler %42 ile son sıradadır. Duyarlılık ölçütünde Zerg Mutalisk %84 ile ilk sırada yer alırken, Zerg Defiler %27 ile son sırada yer alır. En iyi f1 puanını %84 ile Zerg Guardian alırken, en düşük %33 puanını Zerg Defiler birliği alır. Ortalama f1 puanı 0,65’dir. Model doğruluğu Şekil 4.34’te %68 olarak görünmektedir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Hydralisk	0.74	0.77	0.75	9907
Zerg Ultralisk	0.65	0.77	0.71	2745
Zerg Overlord	0.65	0.61	0.63	3999
Zerg Mutalisk	0.82	0.84	0.83	3733
Zerg Guardian	0.87	0.81	0.84	342
Zerg Queen	0.69	0.50	0.58	76
Zerg Defiler	0.42	0.27	0.33	1603
Zerg Scourge	0.54	0.45	0.49	2607
Zerg Devourer	0.78	0.69	0.73	26
Zerg Lurker	0.59	0.62	0.60	4521
doğruluk			0.68	29559
makro ort	0.67	0.63	0.65	29559
ağırlıklı ort	0.67	0.68	0.67	29559


Şekil 4.34 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sınıflandırma Raporu

En yüksek ROC-AUC değeri 1 alanla Zerg Devourer sınıfında ve en düşük alan 0,89 ile Zerg Defiler ve Zerg Scourge sınıfındadır. ROC eğrileri ve AUC değerleri Şekil 4.35'te gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.35 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin ROC Eğrileri ve AUC Alanları

Zerglerin menzil sınıflandırmasında 14443 adet tahmin ve %88,4 duyarlılıkla yakın menzil sınıfını en iyi sonucu verir. En düşük doğruluk 472 doğru tahmin ve %29,2 duyarlılıkla büyücüler sınıfında yer alır. Sadece havadan havaya saldırırlar sınıfında %42 ve uzun menzilli birlikler sınıfında %59,5 duyarlılığa sahiptir. Ortalama doğruluk %75. Hata dizeyi Şekil 4.36'da verilmiştir.




Şekil 4.36 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzil Hata Dizeyi

Yakın menzil %80 ile en yüksek kesinliğe sahipken, büyücü sınıfı %48 ile en düşük kesinliğe sahiptir. Duyarlılıkta yakın menzil %88 ile ilk sıradayken, büyücü %29 ile son sırada yer alır. En yüksek f1-puanı 0.84 ile yakın menzil sınıfında ve en düşük f1 puanı 0.36 ile büyücü sınıfında bulunuyor. Ortalama f1 puanı 0.58'dir. Doğruluk %74'tür. Zerglerin menzil sınıflandırma raporu Şekil 4.37'de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Yakın menzil	0.80	0.88	0.84	16341
Havadan havaya	0.58	0.42	0.49	2645
Uzun menzil	0.64	0.60	0.62	4950
Büyücü	0.48	0.29	0.36	1619
doğruluk			0.74	25555
makro ort	0.62	0.55	0.58	25555
ağırlıklı ort	0.73	0.74	0.73	25555


Şekil 4.37 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzil Sınıflandırma Raporu

En yüksek ROC-AUC değeri 0.91 alanla uzun menzilli birlikler sınıfında ve en düşük alan 0.87 alan ile sadece havadan havaya saldırılar sınıfındadır. ROC-AUC değerleri Şekil 4.38’de gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.38 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Menzil ROC Eğrileri ve AUC Alanları

Zerglerin detaylı menzil sınıflandırmasında yakın menzilde 9535 tahmin ve %97 duyarlılık ile Zerg Hydralisk en iyi sonucu alır. En düşük doğru tahmini 3530 tane tahmin ve %92,5 duyarlılık oranı ile Zerg Mutaliskler alır. Detaylı yakın menzil hata düzeyi Şekil 4.39’da verilmiştir. Doğruluk oranı %96’dır.




Şekil 4.39 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Yakın Menzil Hata Dizeyi

Yakın menzil detaylı sınıflandırmada Zerg Hydralisk %97 duyarlılık ile birinci, Zerg Ultralisk %94 ile son sırada yer alır. Duyarlılıkta Zerg Hydralisk %97 ile ilk sırada yer alırken, Zerg Mutalisk %92 ile son sırada yer almaktadır. Zerg Hydralisk %97 ile en yüksek f1 puanına sahipken, Zerg Mutalisk %94 ile en düşük f1 puana sahiptir. Ortalama f1 puanı 0,95'tir. Doğruluk %96'dır. Detaylı yakın menzil sınıflandırma raporu Şekil 4.40'ta gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Hydralisk	0.97	0.97	0.97	9831
Zerg Ultralisk	0.94	0.96	0.95	2743
Zerg Mutalisk	0.95	0.92	0.94	3818
doğruluk			0.96	16392
makro ort	0.95	0.95	0.95	16392
ağırlıklı ort	0.96	0.96	0.96	16392

Şekil 4.40 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Yakın Menzil Sınıflandırma Raporu

Zerg sadece havadan havaya saldırılar detaylı menzil sınıflandırmasında Zerg Scourge ve Zerg Devourer %100 doğruluğa sahiptir. Zerg Scourge 2627 adet doğru tahmin ve Zerg Devourer 37 adet doğru tahmin yapıyor. Zerg sadece havadan havaya saldırılar detaylı menzil hata düzeyi Şekil 4.41’de gösterilmiştir.




Şekil 4.41 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sadece Havadan Havaya Saldırıların Hata Düzeyi

Zerg Scourge 1 kesinlik ve Zerg Devourer 0.97 kesinliğe sahiptir. Zerg Scourge ve Zerg Devourer 1 duyarlılık değerine sahiptir. Zerg Scourge 1 f1 puanı alırken Zerg Devourer 0,99 puan alır. Ortalama f1 puanı 0,99’dur. Doğruluk %100’dür. Zerg sadece havadan havaya saldırılar menzil sınıflandırması Şekil 4.42’de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Scourge	1.00	1.00	1.00	2628
Zerg Devourer	0.97	1.00	0.99	37
doğruluk			1.00	2665
makro ort	0.99	1.00	0.99	2665
ağırlıklı ort	1.00	1.00	1.00	2665

Şekil 4.42 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Sadece Havadan Havaya Saldıranlar Sınıflandırma Raporu

Zerg uzun menzil detaylı sınıflamasında Zerg Guardian 347 adet doğru tahmin ve %98,9 duyarlılık oranı alırken, Zerg Lurker 4493 adet doğru tahmin ve %99,8 duyarlılık elde eder. Zerglerin uzun menzil detaylı sınıflamasının hata dizeyi Şekil 4.43'te gösterilmiştir.



Şekil 4.43 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Uzun Menzil Hata Dizeyi


Zerg Guardian birliği %97, Zerg Lurker birliği %100 kesinlik elde eder. Zerg Guardian sınıfı %99 duyarlılık ve Zerg Lurker sınıfı %100 duyarlılığa sahiptir. Zerg

Guardian sınıfının f1 puanı %98 ve Zerg Lurker sınıfının f1 puanı %100'dür. Ortalama f1 puanı 0,99'dur. Doğruluk oranı %100'dür. Zerg detaylı uzun menzil sınıflamasının sınıflandırma raporu Şekil 4.44'te gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Guardian	0.97	0.99	0.98	351
Zerg Lurker	1.00	1.00	1.00	4503
doğruluk			1.00	4854
makro ort	0.99	0.99	0.99	4854
ağırlıklı ort	1.00	1.00	1.00	4854

Şekil 4.44 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Uzun Menzil Sınıflandırma Raporu

Zerg büyücüler detaylı sınıflamasında Zerg Queen 56 adet doğru tahmin ve %77,8 duyarlılığa sahiptir. Zerg Defiler 1563 adet doğru tahmin ve %99,3 duyarlılığa sahiptir. Zerg büyücüler detaylı menzil sınıflandırması hata düzeyi Şekil 4.45'te gösterilmiştir.




Şekil 4.45 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Büyücü Hata Düzeyi

Zerg büyücüler detaylı menzil sınıflandırmasında Zerg Queen 0,84 kesinlik ve Zerg Defiler 0,99 kesinlik alır. Zerg Queen 0,78 duyarlılık ve Zerg Defiler 0,99 duyarlılık değeri alır. Zerg Queen 0,83 f1 puanı alırken, Zerg Defiler 0,99 f1 puanı alır. Ortalama f1 puanı 0.90'dır. Doğruluk oranı %98'dir. Zerg büyücü sınıflamasının sınıflandırma raporu Şekil 4.46'da verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Queen	0.84	0.78	0.81	72
Zerg Defiler	0.99	0.99	0.99	1574
doğruluk			0.98	1646
makro ort	0.91	0.89	0.90	1646
ağırlıklı ort	0.98	0.98	0.98	1646


Şekil 4.46 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Büyücü Sınıflandırma Raporu

ROC-AUC değerlerinde 1 alan ile en yüksek değer alan Zerg Ultralisk, Zerg Scourge, Zerg Devourer, Zerg Guardian ve Zerg Lurker sınıflarıdır. En düşük değer 0,98 ile Zerg Queen ve Zerg Defiler sınıflarındadır. ROC eğrilerinin dik ve sol üst köşeye yakın olmalarından modelimizin ayırt ediciliğinin ve performansının çok iyi olduğunu anlayabiliriz. Zerg detaylı menzil sınıflamasının ROC eğrileri ve AUC değerleri Şekil 4.47'de verilmiştir.



Şekil 4.47 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Detaylı Menzil Sınıflamasının ROC Eğrileri ve AUC Alanları

Terran veri kümesi ile eğittiğimiz ileri beslemeli sinir ağının hata düzeyinde her bir sınıfı tahmin etmedeki başarısı görünmektedir. Modele ait hata düzeyi Şekil 4.48’de verilmektedir. Hata düzeyinde Terran Goliath sınıfına ait tahminlerin 1395 adet tahmin ve %72 duyarlılık ile en iyisi olduğu görülür. Terran Nuclear Missile sınıfının 0 adet doğru tahmin ile en düşük doğrulukla sınıflandırılan birlik olduğu görülür. Terran Ghost %80, Terran Vulture %53,5, Terran Siege Tank %42,1, Terran Wraith %62,6, Terran Science Vessel %27,7, Terran Dropship %10, Terran Battlecruiser %49,4, Terran Firebat %54,8, Terran Medic %59,9, Terran Valkyrie %18,2 duyarlılık yüzdesine sahiptir. Ortalama doğru tahmin oranı %51’dir.




Şekil 4.48 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Hata Dizeyi

Kesinlik sıralamasında Terran Goliath ve Terran wraith %75 ile ilk sırada yer alırken, Terran Nuclear Missile %0 ile son sıradadır. Duyarlılık ölçütünde Terran Ghost %80 ile ilk sırada yer alırken, Terran Nuclear Missile %0 ile son sırada yer alır. En iyi f1 puanını %74 ile Terran Goliath alırken, en düşük %0 puanını Terran Nuclear Missile birliği alır. Ortalama f1 puanı 0.45'tir. Model doğruluğu Şekil 4.49'da %51 olarak görülmektedir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Ghost	0.57	0.80	0.67	10
Terran Vulture	0.55	0.54	0.54	2097
Terran Goliath	0.75	0.72	0.74	1937
Terran Siege Tank	0.40	0.42	0.41	2685
Terran Wraith	0.75	0.63	0.68	187
Terran Science Vessel	0.30	0.28	0.29	1863
Terran Dropship	0.26	0.10	0.14	240
Terran Battlecruiser	0.64	0.49	0.56	83
Terran Nuclear Missile	0.00	0.00	0.00	3
Terran Firebat	0.58	0.55	0.56	1441
Terran Medic	0.53	0.60	0.56	3428
Terran Valkyrie	0.30	0.18	0.23	55
doğruluk			0.51	14029
makro ort	0.47	0.44	0.45	14029
ağırlıklı ort	0.51	0.51	0.51	14029


Şekil 4.49 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Sınıflandırma Raporu

En yüksek ROC-AUC değeri 1 alan ile Terran Ghost birliğine aittir. En düşük alan 0,75 ile Terran Science Vessel birliğine aittir. ROC eğrisi ve AUC değerleri Şekil 4.50’de gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.50 Uzun Kısa Vadeli Hafıza Ağılı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin ROC Eğrileri ve AUC Alanları

Terranların menzil sınıflandırmasında 3346 adet doğru tahmin ve %81 duyarlılıkla orta menzilli yer birlikleri sınıfının en iyi sonucu verir. En düşük doğruluk 343 adet doğru tahmin ve %18,8 duyarlılıkla büyücüler sınıfında yer alır. Ortalama doğruluk %63'tür. Hata dizeyi Şekil 4.51'de verilmiştir.




Şekil 4.51 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Hata Dizeyi

Orta menzilli yer birlikleri %74 ile en yüksek kesinliğe sahipken, büyücü sınıfı %35 ile en düşük kesinliğe sahiptir. Duyarlılıkta orta menzilli yer birlikleri %81 ile ilk sıradayken, büyücü %19 ile son sırada yer alır. En yüksek f1-puanı 0,77 ile orta menzilli yer birlikleri sınıfında ve en düşük f1 puanı 0,24 ile büyücü sınıfında bulunuyor. Ortalama f1 puanı 0,54'tür. Doğruluk %63'tür. Terranların menzil sınıflandırma raporu Şekil 4.52'de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Çok yakın menzilli yer	0.66	0.79	0.71	4951
Orta menzilli yer	0.74	0.81	0.77	4130
Orta menzilli hava	0.62	0.55	0.59	307
Çok Uzun menzilli yer	0.43	0.35	0.38	2576
Büyücü	0.35	0.19	0.24	1824
doğruluk			0.63	13788
makro ort	0.56	0.54	0.54	13788
ağırlıklı ort	0.60	0.63	0.61	13788


Şekil 4.52 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil Sınıflandırma Raporu

En yüksek ROC-AUC değeri 0,97 alanla orta menzilli yer birlikleri sınıfında ve en düşük alan 0,76 alan ile büyücü birlikleri sınıfındadır. ROC eğrileri ve AUC değerleri Şekil 4.53’de gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.53 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Menzil ROC Eğrileri ve AUC Alanları

Terranların detaylı menzil sınıflandırmasında çok yakın menzilde 1422 doğru tahmin ve %99,4 duyarlılık ile Terran Firebat en iyi sonucu alır. Terran Medic 81 tane tahmin ve %2,3 duyarlılık oranı elde eder. Detaylı çok yakın menzil hata dizeyi Şekil 4.54’te verilmiştir. Doğruluk oranı %31’dir.




Şekil 4.54 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Yakın Menzil Hata Dizeyi

Terran Firebat 0,29 kesinlik ve Terran Medic 0,90 kesinliğe sahiptir. Terran Firebat 0,99 duyarlılık değerine ve Terran Medic 0,02 duyarlılık değerine sahiptir. Terran Firebat 0,45 f1-puanı alırken Terran Medic 0,05 puan alır. Ortalama f1 puanı 0.25’tir. Doğruluk %31’tür. Terran çok yakın menzil sınıflandırması Şekil 4.55’te verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Firebat	0.29	0.99	0.45	1431
Terran Medic	0.90	0.02	0.05	3492
doğruluk			0.31	4923
makro ort	0.60	0.51	0.25	4923
ağırlıklı ort	0.72	0.31	0.16	4923

Şekil 4.55 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Yakın Menzil Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında orta menzilli yer birlikleri sınıflamasında 1853 doğru tahmin ve %89,5 duyarlılık ile TerranVulture en iyi sonucu alır. Terran Goliath 1746 tane tahmin ve %87,9 duyarlılık oranı elde eder. Detaylı orta menzilli yer birlikleri hata dizeyi Şekil 4.56’da verilmiştir. Doğruluk oranı %91’dir.



Şekil 4.56 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Yer Birliklerinin Hata Dizeyi


Terran Vulture 0,88 kesinlik ve Terran Goliath 0.89 kesinliğe sahiptir. Terran Vulture 0,90 duyarlılık değerine ve Terran Goliath 0.88 duyarlılık değerine sahiptir.

Terran Vulture 0,89 f1-puanı alırken Terran Goliath 0,88 puan alır. Ortalama f1 puanı 0,89'dur. Doğruluk %89'dur. Terran orta menzilli yer birlikleri sınıflandırması Şekil 4.57'de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Vulture	0.88	0.90	0.89	2070
Terran Goliath	0.89	0.88	0.88	2006
doğruluk			0.89	4076
makro ort	0.89	0.89	0.89	4076
ağırlıklı ort	0.89	0.89	0.89	4076

Şekil 4.57 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Yer Birlikleri Sınıflandırma Raporu

Terranların orta menzilli hava birlikleri detaylı sınıflandırmasında Terran Wraith 10551 adet tahmin ve %100 duyarlılık ile en iyi sonucu alır. Terran Valkyrie ve Terran Battlecruiser sınıfı 0 adet doğru tahmine sahiptir. Detaylı orta menzilli hava birlikleri hata düzeyi Şekil 4.58'de verilmiştir.




Şekil 4.58 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Hava Birliklerinin Hata Dizeyi

Orta menzilli hava birlikleri sınıflandırmasında Terran Wraith %99 kesinlik ile birinci, Terran Valkyrie ve Terran Battlecruiser %0 ile son sırada yer alır. Duyarlılıkta Terran Wraith %100 ile ilk sırada yer alırken, Terran Battlecruiser ve Terran Valkyrie %0 ile son sırada yer almaktadır. Terran Wraith %99 ile en yüksek f1 puanına sahipken, Terran Battlecruiser ve Terran Valkyrie %0 f1 puanına sahiptir. Ortalama f1 puanı 0.33'tür. Doğruluk %99'dur. Detaylı orta menzilli hava birlikleri sınıflandırma raporu Şekil 4.59' da gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Wraith	0.99	1.00	0.99	10551
Terran Battlecruiser	0.00	0.00	0.00	80
Terran Valkyrie	0.00	0.00	0.00	52
doğruluk			0.99	10683
makro ort	0.33	0.33	0.33	10683
ağırlıklı ort	0.98	0.99	0.98	10683

Şekil 4.59 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Orta Menzilli Hava Birlikleri Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında çok uzun menzilli yer birlikleri sınıflamasında 5 doğru tahmin ve %100 duyarlılık ile Terran Nuclear Missile en iyi sonucu alır. Terran Siege Tank 959 tane doğru tahmin ve %36,8 duyarlılık oranı elde eder. Detaylı çok uzun menzil hata düzeyi Şekil 4.60'ta verilmiştir.



Şekil 4.60 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Uzun Menzilli Yer Birliklerinin Hata Dizeyi


Terran Siege Tank 1 ve Teran Nuclear Missile 0 kesinliğe sahiptir. Terran Siege Tank 0,37 duyarlılık değerine ve Terran Nuclear Missile 1 duyarlılık değerine

sahiptir. Terran Siege Tank 0,54 f1-puanı alırken Terran Nuclear Missile 0.01 puan alır. Ortalama f1 puanı 0,27’dir. Doğruluk %37’dir. Terran çok uzun menzil sınıflandırması Şekil 4.61’de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Siege Tank	1.00	0.37	0.54	2603
Terran Nuclear Missile	0.00	1.00	0.01	5
doğruluk			0.37	2608
makro ort	0.50	0.68	0.27	2608
ağırlıklı ort	1.00	0.37	0.54	2608

Şekil 4.61 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Çok Uzun Menzilli Yer Birlikleri Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında büyücü birlikleri sınıflamasında 8 doğru tahmin ve %100 duyarlılık ile Terran Ghost en iyi sonucu alır. Terran Science Vessel 1628 tane doğru tahmin ve %86,8 duyarlılık elde eder. Detaylı büyücü birlikleri hata dizeyi Şekil 4.62’de verilmiştir.




Şekil 4.62 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Büyücü Birliklerinin Hata Dizeyi

Terran Science Vessel 1 kesinliğe ve Terran Ghost 0,03 kesinliğe sahiptir. Terran Science Vessel 0,87 duyarlılık değerine ve Terran Ghost 1 duyarlılık değerine sahiptir. Terran Science Vessel 0,93 f1-puanı alırken Terran Ghost 0,06 puan alır. Ortalama f1 puanı 0,49'dur. Doğruluk %87'dir. Terran büyücü birlikleri sınıflaması Şekil 4.63'te verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Ghost	0.03	1.00	0.06	8
Terran Science Vessel	1.00	0.87	0.93	1876
doğruluk			0.87	1884
makro ort	0.52	0.93	0.49	1884
ağırlıklı ort	1.00	0.87	0.93	1884

Şekil 4.63 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Büyücü Birlikleri Sınıflandırma Raporu

ROC-AUC değerlerinde 1 alan ile en yüksek değer alan Terran Siege Tank, Terran Nuclear Missile, Terran Ghost ve Terran Science Vessel sınıflarıdır. En düşük değer 0,57 ile Terran Firebat ve Terran Medic sınıflarındadır. Terran detaylı menzil sınıflamasının ROC eğrileri ve AUC değerleri Şekil 4.64'de verilmiştir. Terran Valkyrie sınıfı 0,3 yanlış pozitif oranına kadar diyagonalin altında kalır. Terran Wraith 0,875 yanlış pozitif oranından sonra diyagonalin altına geçiyor. Terran Firebat ve Terran Medic sınıfları diyagonalin yalnızca biraz üzerinde yer alır. Diğer sınıflar sol üst köşeye daha yakındalar. ROC eğrileri grafiğine baktığımızda modelin ayırt ediciliğinin ve performansının ortalama olduğunu söyleyebiliriz.



Şekil 4.64 Uzun Kısa Vadeli Hafıza Ağılı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Detaylı Menzile Sınıflandırmasının ROC Eğrileri ve AUC Alanları

4.3. 1B Konvolüsyonel Model

Zerg veri kümesi ile konvolüsyonel sinir ağının hata düzeyinde her bir sınıfı tahmin etmedeki başarısı görünmektedir. Modele ait hata düzeyi Şekil 4.65'te verilmektedir. Hata düzeyinde Zerg Mutalisk sınıfına ait tahminlerin 3229 adet tahmin ve %86,5 duyarlılık ile en iyisi olduğu görülür. Zerg Defiler sınıfının 538 adet tahmin ve %33,6 duyarlılık ile en düşük doğrulukla sınıflandırılan birlik olduğu görülür. Zerg Hydralisk %80,1, Zerg Ultralisk %78,2, Zerg Overlord %60, Zerg Guardian %85,4, Zerg Queen %55,3, Zerg Scourge %51,3, Zerg Devourer %69,2, Zerg Lurker %61,2 duyarlılığa sahiptir. Ortalama doğru tahmin oranı %70'tir.




Şekil 4.65 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Hata Dizeyi

Kesinlik sıralamasında Zerg Guardian %87 ile ilk sırada yer alırken, Zerg Defiler %43 ile son sıradadır. Duyarlılık ölçütünde Zerg Mutalisk %86 ile ilk sırada yer alırken, Zerg Defiler %34 ile son sırada yer alır. En iyi f1 puanını %84 ile Zerg Guardian alırken, en düşük %38 puanını Zerg Defiler birliği alır. Ortalama f1 puanı 0,7'dir. Model doğruluğu Şekil 4.66'da %70 olarak görünmektedir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Hydralisk	0.75	0.80	0.78	9907
Zerg Ultralisk	0.70	0.78	0.74	2745
Zerg Overlord	0.69	0.60	0.64	3999
Zerg Mutalisk	0.82	0.86	0.84	3733
Zerg Guardian	0.87	0.85	0.86	342
Zerg Queen	0.61	0.55	0.58	76
Zerg Defiler	0.43	0.34	0.38	1603
Zerg Scourge	0.54	0.51	0.52	2607
Zerg Devourer	0.82	0.69	0.75	26
Zerg Lurker	0.63	0.61	0.62	4521
doğruluk			0.70	29559
makro ort	0.69	0.66	0.67	29559
ağırlıklı ort	0.69	0.70	0.70	29559


Şekil 4.66 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Zerglerin Sınıflandırma Raporu

En yüksek ROC-AUC değeri 1 alanla Zerg Guardian ve Zerg Devourer sınıfında ve en düşük alan 0,90 ile Zerg Defiler ve Zerg Scourge sınıfındadır. ROC eğrileri ve AUC değerleri Şekil 4.67’de gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.67 1B Konvolüsyonel Modelde Zerg Veri Kümesinin ROC Eğrileri ve AUC Alanları

Zerglerin menzil sınıflandırmasında 14539 adet tahmin ve %89 duyarlılıkla yakın menzil sınıfını en iyi sonucu verir. En düşük doğruluk 589 doğru tahmin ve %36,4 duyarlılıkla büyücüler sınıfında yer alır. Sadece havadan havaya saldırırlar %49,7 ve uzun menzilli birlikler %65,1 duyarlılığa sahiptir. Ortalama doğruluk %77. Hata düzeyi Şekil 4.68'de verilmiştir.




Şekil 4.68 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Menzil Hata Dizeyi

Yakın menzil %83 ile en yüksek kesinliğe sahipken, büyücü sınıfı %47 ile en düşük kesinliğe sahiptir. Duyarlılıkta yakın menzil %89 ile ilk sıradayken, büyücü %36 ile son sırada yer alır. En yüksek f1-puanı 0,86 ile yakın menzil sınıfında ve en düşük f1 puanı 0,41 ile büyücü sınıfında bulunuyor. Ortalama f1 puanı 0,62'dir. Doğruluk %77'dir. Zerglerin menzil sınıflandırma raporu Şekil 4.69'da verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Yakın menzil	0.83	0.89	0.86	16341
Havadan havaya	0.56	0.50	0.53	2645
Uzun menzil	0.72	0.65	0.68	4950
Büyücü	0.47	0.36	0.41	1619
doğruluk			0.77	25555
makro ort	0.64	0.60	0.62	25555
ağırlıklı ort	0.76	0.77	0.76	25555


Şekil 4.69 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Menzil Sınıflandırma Raporu

En yüksek ROC-AUC değeri 0.93 alanla uzun menzilli birlikler sınıfında ve en düşük alan 0,89 alan ile sadece havadan havaya saldıranlar birlikler sınıfındadır. ROC eğrileri ve AUC değerleri Şekil 4.70'te gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.70 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Menzil Sınıflamasının ROC Eğrileri ve AUC Alanları

Zerglerin detaylı menzil sınıflandırmasında yakın menzilde 9573 tahmin ve %97,4 duyarlılık ile Zerg Hydralisk en iyi sonucu alır. En düşük doğru tahmini 3578 tane tahmin ve %93,7 duyarlılık oranı ile Zerg Mutaliskler alır. Detaylı yakın menzil hata dizeyi Şekil 4.71'de verilmiştir. Doğruluk oranı %96'dır.




Şekil 4.71 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Yakın Menzil Hata Dizeyi

Yakın menzil detaylı sınıflandırmada Zerg Hydralisk %97 duyarlılık ile birinci, Zerg Ultralisk %94 ile son sırada yer alır. Duyarlılıkta Zerg Hydralisk %97 ile ilk sırada yer alırken, Zerg Mutalisk ve Zerg Ultralisk %94 duyarlılık alırlar. Zerg Hydralisk %97 ile en yüksek f1 puanına sahipken, Zerg Mutalisk %94 ile en düşük f1 puanına sahiptir. Ortalama f1 puanı 0,95'tir. Doğruluk %96'dır. Detaylı yakın menzil sınıflandırma raporu Şekil 4.72' de gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Hydralisk	0.97	0.97	0.97	9831
Zerg Ultralisk	0.96	0.94	0.95	2743
Zerg Mutalisk	0.94	0.94	0.94	3818
doğruluk			0.96	16392
makro ort	0.96	0.95	0.95	16392
ağırlıklı ort	0.96	0.96	0.96	16392

Şekil 4.72 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Yakın Menzil Sınıflandırma Raporu

Zerg sadece havadan havaya saldırılar detaylı menzil sınıflandırmasında Zerg Scourge %100 ve Zerg Devourer %81,1 kesinliğe sahiptir. Zerg Scourge 2628 adet doğru tahmin ve Zerg Devourer 30 adet doğru tahmin yapıyor. Zerg sadece havadan havaya saldırılar detaylı menzil hata düzeyi Şekil 4.73'te gösterilmiştir.




Şekil 4.73 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Sadece Havadan Havaya Saldırıları Hata Dizeyi

Zerg Scourge 1 kesinlik ve Zerg Devourer 1 kesinliğe sahiptir. Zerg Scourge 1 duyarlılık değerine ve Zerg Devourer 0,81 duyarlılık değerine sahiptir. Zerg Scourge 1 f1 puanı alırken Zerg Devourer 0,90 puan alır. Ortalama f1 puanı 0,95'tir. Doğruluk %100'dür. Zerg sadece havadan havaya saldırılar menzil sınıflandırması Şekil 4.74'te verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Scourge	1.00	1.00	1.00	2628
Zerg Devourer	1.00	0.81	0.90	37
doğruluk			1.00	2665
makro ort	1.00	0.91	0.95	2665
ağırlıklı ort	1.00	1.00	1.00	2665

Şekil 4.74 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Sadece Havadan Havaya Saldıranlar Sınıflandırma Raporu

Zerg uzun menzil detaylı sınıflamasında Zerg Guardian 342 adet doğru tahmin ve %97,4 duyarlılık oranı alırken, Zerg Lurker 4496 adet doğru tahmin ve %99,8 kesinlik elde eder. Zerglerin uzun menzil detaylı sınıflamasının hata düzeyi Şekil 4.75'te gösterilmiştir.



Şekil 4.75 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Uzun Menzil Hata Dizeyi


Zerg Guardian birliği %98, Zerg Lurker birliği %100 kesinlik elde eder. Zerg Guardian sınıfı %97 duyarlılık ve Zerg Lurker sınıfı %100 duyarlılığa sahiptir. Zerg Guardian sınıfının f1 puanı %98 ve Zerg Lurker sınıfının f1 puanı %100'dür. Ortalama

f1 puanı 0,99'dur. Doğruluk oranı %100'dür. Zerg detaylı uzun menzil sınıflamasının sınıflandırma raporu Şekil 4.76'da gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Guardian	0.98	0.97	0.98	351
Zerg Lurker	1.00	1.00	1.00	4503
doğruluk			1.00	4854
makro ort	0.99	0.99	0.99	4854
ağırlıklı ort	1.00	1.00	1.00	4854

Şekil 4.76 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Uzun Menzil Sınıflandırma Raporu

Zerg büyücüler detaylı sınıflamasında Zerg Queen 66 adet doğru tahmin ve %91,7 duyarlılığa sahiptir. Zerg Defiler 1550 adet doğru tahmin ve %98,5 duyarlılığa sahiptir. Zerg büyücüler detaylı menzil sınıflandırması hata dizeyi Şekil 4.77'de gösterilmiştir.




Şekil 4.77 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Büyücü Hata Dizeyi

Zerg büyücüler detaylı menzil sınıflandırmasında Zerg Queen 0,73 kesinlik ve Zerg Defiler 1 kesinlik alır. Zerg Queen 0,92 duyarlılık ve Zerg Defiler 0,98 duyarlılık değeri alır. Zerg Queen 0.81 f1 puanı alırken, Zerg Defiler 0,99 f1 puanı alır. Ortalama f1 puanı 0,90'dır. Doğruluk oranı %98'dir. Zerg büyücü sınıflamasının sınıflandırma raporu Şekil 4.78'de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Zerg Queen	0.73	0.92	0.81	72
Zerg Defiler	1.00	0.98	0.99	1574
doğruluk			0.98	1646
makro ort	0.86	0.95	0.90	1646
ağırlıklı ort	0.98	0.98	0.98	1646


Şekil 4.78 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Büyücü Sınıflandırma Raporu

ROC-AUC değerlerinde 1 alan ile en yüksek değer alan Zerg Ultralisk, Zerg Scourge, Zerg Devourer, Zerg Guardian ve Zerg Lurker sınıflarıdır. En düşük değer 0,98 ile Zerg Queen ve Zerg Defiler sınıflarındadır. ROC eğrilerinin dik ve sol üst köşeye yakın olmalarından modelimizin ayırt ediciliğinin ve performansının çok iyi olduğunu anlayabiliriz. Zerg detaylı menzil sınıflamasının ROC eğrileri ve AUC değerleri Şekil 4.79'da verilmiştir.



Şekil 4.79 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Detaylı Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları

Terran veri kümesi ile eğittiğimiz konvolüsyonel sinir ağının hata dizeyinde her bir sınıfı tahmin etmedeki başarısı görünmektedir. Modele ait hata dizeyi Şekil 4.80’de verilmektedir. Hata dizeyinde Terran Goliath sınıfına ait tahminlerin 1468 adet tahmin ve %75,8 duyarlılık ile en iyisi olduğu görülür. Terran Nuclear Missile sınıfının 0 adet doğru tahmin ile en düşük doğrulukla sınıflandırılan birlik olduğu görülür. Terran Ghost %80, Terran Vulture %58,7, Terran Siege Tank %39,6, Terran Wraith %67,9, Terran Science Vessel %22,4, Terran Dropship %11,2, Terran Battlecruiser %54,2, Terran Firebat %61,3, Terran Medic %62,4, Terran Valkyrie %27,3 duyarlılık yüzdesine sahiptir. Ortalama doğru tahmin oranı %53’tür.




Şekil 4.80 1B Konvolüsyonel Modelde Terran Verilerinin Hata Dizeyi

Kesinlik sıralamasında Terran Goliath %71 ile ilk sırada yer alırken, Terran Nuclear Missile %0 ile son sıradadır. Duyarlılık ölçütünde Terran Ghost %80 ile ilk sırada yer alırken, Terran Nuclear Missile %0 ile son sırada yer alır. En iyi f1 puanını %73 ile Terran Goliath ve Terran Ghost alırken, en düşük %0 puanını Terran Nuclear Missile birliği alır. Ortalama f1 puanı 0.46'dır. Model doğruluğu Şekil 4.81'de %53 olarak görünmektedir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Ghost	0.67	0.80	0.73	10
Terran Vulture	0.54	0.59	0.56	2097
Terran Goliath	0.71	0.76	0.73	1937
Terran Siege Tank	0.41	0.40	0.40	2685
Terran Wraith	0.68	0.68	0.68	187
Terran Science Vessel	0.34	0.22	0.27	1863
Terran Dropship	0.15	0.11	0.13	240
Terran Battlecruiser	0.55	0.54	0.55	83
Terran Nuclear Missile	0.00	0.00	0.00	3
Terran Firebat	0.59	0.61	0.60	1441
Terran Medic	0.55	0.62	0.59	3428
Terran Valkyrie	0.42	0.27	0.33	55
doğruluk			0.53	14029
makro ort	0.47	0.47	0.46	14029
ağırlıklı ort	0.51	0.53	0.52	14029


Şekil 4.81 1B Konvolüsyonel Modelde Terran Verilerinin Sınıflandırma Raporu

En yüksek ROC-AUC değeri 1 alan ile Terran Ghost ve Terran Nuclear Missile birliklerine aittir. En düşük alan 0,76 ile Terran Science Vessel birliğine aittir. ROC eğrileri ve AUC değerleri Şekil 4.82’de gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.82 1B Konvolüsyonel Modelde Terran Verilerinin ROC Eğrileri ve AUC Alanları

Terranların menzil sınıflandırmasında 3277 adet doğru tahmin ve %79,3 duyarlılıkla orta menzilli yer birlikleri sınıfının en iyi sonucu verir. En düşük doğruluk 588 adet doğru tahmin ve %32,2 duyarlılıkla büyücüler sınıfında yer alır. Ortalama doğruluk %62'dir. Hata dizeyi Şekil 4.83'de vermiştir.




Şekil 4.83 1B Konvolüsyonel Modelde Terran Verilerinin Menzil Hata Dizeyi

Orta menzilli yer birlikleri %75 ile en yüksek kesinliğe sahipken, büyücü sınıfı %33 ile en düşük kesinliğe sahiptir. Duyarlılıkta orta menzilli yer birlikleri %79 ile ilk sıradayken, büyücü %32 ile son sırada yer alır. En yüksek f1-puanı 0,77 ile orta menzilli yer birlikleri sınıfında ve en düşük f1 puanı 0,33 ile büyücü sınıfında bulunuyor. Ortalama f1 puanı 0.56'dır. Doğruluk %62'dir. Terranların menzil sınıflandırma raporu Şekil 4.84'de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Çok yakın menzıl yer	0.70	0.71	0.70	4951
Orta menzillli yer	0.75	0.79	0.77	4130
Orta menzillli hava	0.65	0.59	0.62	307
Çok Uzun menzıl yer	0.43	0.38	0.40	2576
Büyücü	0.33	0.32	0.33	1824
doğruluk			0.62	13788
makro ort	0.57	0.56	0.56	13788
ağırlıklı ort	0.61	0.62	0.61	13788


Şekil 4.84 1B Konvolüsyonel Modelde Terran Verilerinin Menzıl Sınıflandırma Raporu

En yüksek ROC-AUC değeri 0,97 alanla orta menzilli yer birlikleri sınıfında ve en düşük alan 0,77 alan ile çok uzun menzilli yer birlikleri ve büyücü birlikleri sınıfındadır. ROC eğrileri ve AUC değerleri Şekil 4.85’de gösterilmiştir. ROC eğrilerine bakıldığında bütün eğrilerinin diyagonalin üstünde bulunmasından modelimizin ayırt ediciliğinin ve performansının genel olarak iyi olduğunu anlayabiliriz.



Şekil 4.85 1B Konvolüsyonel Modelde Terran Verilerinin Menzıl ROC Eğrileri ve AUC Alanları

Terranların detaylı menzil sınıflandırmasında çok yakın menzilde 3124 doğru tahmin ve %89,5 duyarlılık ile Terran Medic en iyi sonucu alır. Terran Firebat 1026 tane tahmin ve %71,7 duyarlılık oranı elde eder. Detaylı çok yakın menzil hata dizeyi Şekil 4.86’da verilmiştir. Doğruluk oranı %84’tür.




Şekil 4.86 1B Konvolüsyonel Modelde Terran Verilerinin Çok Yakın Menzil Hata Dizeyi

Terran Firebat 0,74 kesinlik ve Terran Medic 0,89 kesinliğe sahiptir. Terran Firebat 0,72 duyarlılık değerine ve Terran Medic 0,89 duyarlılık değerine sahiptir. Terran Firebat 0.73 f1-puanı alırken Terran Medic 0,89 puan alır. Ortalama f1 puanı 0,81’dir. Doğruluk %84’tür. Terran çok yakın menzil sınıflandırması Şekil 4.87’de verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Firebat	0.74	0.72	0.73	1431
Terran Medic	0.89	0.89	0.89	3492
doğruluk			0.84	4923
makro ort	0.81	0.81	0.81	4923
ağırlıklı ort	0.84	0.84	0.84	4923

Şekil 4.87 1B Konvolüsyonel Modelde Terran Verilerinin Çok Yakın Menzil Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında orta menzilli yer birlikleri sınıflamasında 1884 doğru tahmin ve %91,0 duyarlılık ile Terran Vulture en iyi sonucu alır. Terran Goliath 1801 tane tahmin ve %89,8 duyarlılık oranı elde eder. Detaylı orta menzilli yer birlikleri hata dizeyi Şekil 4.88’de verilmiştir. Doğruluk oranı %90’dır.



Şekil 4.88 1B Konvolüsyonel Modelde Terran Verilerinin Orta Menzilli Yer Birliklerinin Hata Dizeyi


Terran Vulture 0,90 kesinlik ve Terran Goliath 0,91 kesinliğe sahiptir. Terran Vulture 0,91 duyarlılık değerine ve Terran Goliath 0,90 duyarlılık değerine sahiptir.

Terran Vulture 0,91 f1-puanı alırken Terran Goliath 0,90 puan alır. Ortalama f1 puanı 0,90'dır. Doğruluk %90'dır. Terran orta menzilli yer birlikleri sınıflaması Şekil 4.89'da verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Vulture	0.90	0.91	0.91	2070
Terran Goliath	0.91	0.90	0.90	2006
doğruluk			0.90	4076
makro ort	0.90	0.90	0.90	4076
ağırlıklı ort	0.90	0.90	0.90	4076

Şekil 4.89 1B Konvolüsyonel Modelde Terran Verilerinin Orta Menzilli Yer Birliklerinin Sınıflandırma Raporu

Terranların orta menzilli hava birlikleri detaylı sınıflandırmasında Terran Wraith 10520 adet tahmin ve %99,7 duyarlılık ile en iyi sonucu alır. En düşük doğru tahmini 11 tahmin ve %21,2 ile Terran Valkyrie alır. Terran Battlecruiser sınıfı 43 adet doğru tahmin ve %53,8 duyarlılık oranına sahiptir. Detaylı orta menzilli hava birlikleri hata düzeyi Şekil 4.90'da verilmiştir.




Şekil 4.90 1B Konvolüsyonel Modelde Terran Verilerinin Orta Menzilli Hava Birliklerinin Hata Dizeyi

Orta menzilli hava birlikleri sınıflandırmasında Terran Wraith %99 kesinlik ile birinci, Terran Valkyrie %38 ile son sırada yer alır. Terran Battlecruiser %75 kesinliğe sahiptir. Duyarlılıkta Terran Wraith %100 ile ilk sırada yer alırken, Terran Valkyrie %21 ile son sırada yer almaktadır. Terran Battlecruiser %54 duyarlılık değeri alır. Terran Wraith %99 ile en yüksek f1 puanına sahipken, Terran Battlecruiser %63 ve Terran Valkyrie %27 f1 puanına sahiptir. Ortalama f1 puanı 0,63'tür. Doğruluk %99'dur. Detaylı orta menzilli hava birlikleri sınıflandırma raporu Şekil 4.91' de gösterilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Wraith	0.99	1.00	0.99	10551
Terran Battlecruiser	0.75	0.54	0.63	80
Terran Valkyrie	0.38	0.21	0.27	52
doğruluk			0.99	10683
makro ort	0.71	0.58	0.63	10683
ağırlıklı ort	0.99	0.99	0.99	10683

Şekil 4.91 1B Konvolüsyonel Modelde Terran Verilerinin Orta Menzilli Hava Birliklerinin Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında çok uzun menzilli yer birlikleri sınıflamasında 2603 doğru tahmin ve %100 duyarlılık ile Terran Siege Tank en iyi sonucu alır. Terran Nuclear Missile 2 tane doğru tahmin ve %40 duyarlılık oranı elde eder. Detaylı çok uzun menzil hata düzeyi Şekil 4.92’de verilmiştir.



Şekil 4.92 1B Konvolüsyonel Modelde Terran Verilerinin Çok Uzun Menzilli Yer Birliklerinin Hata Dizeyi


Terran Siege Tank ve Terran Nuclear Missile 1 kesinliğe sahiptir. Terran Siege Tank 1 duyarlılık değerine ve Terran Nuclear Missile 0,40 duyarlılık değerine sahiptir.

Terran Siege Tank 1 f1-puanı alırken Terran Nuclear Missile 0,57 puan alır. Ortalama f1 puanı 0,79'dur. Doğruluk %100 değerindedir. Terran çok uzun menzil sınıflandırması Şekil 4.93'te verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Siege Tank	1.00	1.00	1.00	2603
Terran Nuclear Missile	1.00	0.40	0.57	5
doğruluk			1.00	2608
makro ort	1.00	0.70	0.79	2608
ağırlıklı ort	1.00	1.00	1.00	2608

Şekil 4.93 1B Konvolüsyonel Modelde Terran Verilerinin Çok Uzun Menzilli Yer Birliklerinin Sınıflandırma Raporu

Terranların detaylı menzil sınıflandırmasında büyücü birlikleri sınıflamasında 1872 doğru tahmin ve %99,8 duyarlılık ile Terran Science Vessel en iyi sonucu alır. Terran Ghost 6 tane doğru tahmin ve %75 duyarlılık elde eder. Detaylı büyücü birlikleri hata dizeyi Şekil 4.94'te verilmiştir.




Şekil 4.94 1B Konvolüsyonel Modelde Terran Verilerinin Büyücü Birliklerinin Hata Dizeyi

Terran Science Vessel 1 kesinliğe ve Terran Ghost 0,60 kesinliğe sahiptir. Terran Science Vessel 1 duyarlılık değerine ve Terran Ghost 0,75 duyarlılık değerine sahiptir. Terran Science Vessel 1 f1-puanı alırken Terran Ghost 0,67 puan alır. Ortalama f1 puanı 0.83'tür. Doğruluk %100'dür. Terran büyücü birlikleri sınıflaması Şekil 4.95'te verilmiştir.

	kesinlik	duyarlılık	f1-puanı	destek
Terran Ghost	0.60	0.75	0.67	8
Terran Science Vessel	1.00	1.00	1.00	1876
doğruluk			1.00	1884
makro ort	0.80	0.87	0.83	1884
ağırlıklı ort	1.00	1.00	1.00	1884

Şekil 4.95 1B Konvolüsyonel Modelde Terran Verilerinin Büyücü Birliklerinin Sınıflandırma Raporu

ROC-AUC değerlerinde 1 alan ile en yüksek değer alan Terran Battlecruiser, Terran Nuclear Missile, Terran Ghost ve Terran Science Vessel sınıflarıdır. En düşük değer 0,80 ile Terran Siege Tank sınıfındadır. ROC eğrilerinin diyagonalin üstünde bulunmasından ve eğrilerin çoğunluğunun sol üst köşeye yakın olmasından modelimizin ayırt ediciliğinin ve performansının iyi olduğunu anlayabiliriz. Terran detaylı menzil sınıflamasının ROC eğrileri ve AUC değerleri Şekil 4.96'da verilmiştir.



Şekil 4.96 1B Konvolüsyonel Modelde Terran Verilerinin Detaylı Menzil Sınıflandırmasının ROC Eğrileri ve AUC Alanları

5. TARTIŞMA

İleri beslemeli sinir ağı modelinde Zerg veri kümesinde her bir birlikte temel sınıflandırmadan detaylı menzil sınıflandırmasına geçildiğinde f1 puanında artış gözlemlendi. AUC alanlarında ise hali hazırda 1 AUC alanına sahip birlikler bu alanı korurken, diğer birliklerin AUC alanlarının da temel sınıflandırmadan daha yüksek değerde olduğu görüldü. Zerg verilerinin ileri beslemeli sinir ağı modelinde temel sınıflandırma ve detaylı menzil sınıflandırması f1-puanları ve AUC alanlarının karşılaştırması Tablo 5.1’de verilmiştir. F1 puanında en büyük yükseliş 0.33 değerden 0.99 değerine Zerg Defiler birliğinde gözlemlendi. En az yükseliş 0.83 f1 puanından 0.94 f1 puanına Zerg Mutalisk birliğinde gözlemlendi. AUC alanlarında en büyük artış 0.89 değerinden 0.98 değerine Zerg Defiler birliğinde gözlemlendi.

Tablo 5.1 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması

Zerg Birlikleri	Temel Sınıflandırma F1-Puanı	Detaylı Menzil Sınıflandırması F1-Puanı	Temel Sınıflandırma AUC Alanı	Detaylı Menzil Sınıflandırması AUC Alanı
Zerg Hydralisk	0,76	0,97	0,92	0,99
Zerg Ultralisk	0,70	0,94	0,97	1,0
Zerg Mutalisk	0,83	0,94	0,98	0,99
Zerg Guardian	0,83	0,97	1,0	1,0
Zerg Queen	0,54	0,83	0,91	0,99
Zerg Defiler	0,33	0,99	0,89	0,98
Zerg Scourge	0,46	1,0	0,88	1,0
Zerg Devourer	0,78	0,96	1,0	1,0
Zerg Lurker	0.60	1,0	0,92	1,0

İleri beslemeli sinir ağı modelinde Zerg veri kümesi temel sınıflandırma ortalama f1 puanı 0.65 değerden detaylı menzil sınıflamasında 0.95 değere yükseldi. Temel sınıflandırma ortalama AUC alanı 0.94 değerden 0.99 değere yükseldi. Zerg verilerinin ileri beslemeli sinir ağı modelinde ortalama f1 puanları ve ortalama AUC alanlarının karşılaştırması Tablo 5.2’de verilmiştir.

Tablo 5.2 İleri Beslemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması

Veri Kümesi	Temel Sınıflandırma Ortalama F1-Puanı	Detaylı Menzil Sınıflandırması Ortalama F1-Puanı	Temel Sınıflandırma Ortalama AUC Alanı	Detaylı Menzil Sınıflandırması Ortalama AUC Alanı
Zerg	0,65	0,95	0,94	0,99

İleri beslemeli sinir ağı Terran veri kümesinde her bir birlikte temel sınıflandırmadan detaylı menzil sınıflandırmasına geçildiğinde f1 puanında artış gözlemlendi. AUC alanlarında Terran Firebat ve Terran Valkyrie birliklerinde düşüş, Terran Wraith birlikte eşitlik, diğer birliklerde yükseliş görüldü. Terran verilerinin ileri beslemeli sinir ağı modelinde temel sınıflandırma ve detaylı menzil sınıflandırması f1-puanları ve AUC alanlarının karşılaştırması Tablo 5.3'te verilmiştir. F1 puanında en büyük yükseliş 0.24 değerden 1 değerine Terran Science Vessel birliğinde gözlemlendi. En az yükseliş 0.70 f1 puanından 0.71 f1 puanına Terran Ghost birliğinde gözlemlendi. AUC alanlarında en büyük artış 0.75 değerinden 1 değerine Terran Science Vessel birliğinde gözlemlendi. AUC alanlarında en büyük düşüş 0,92 değerden 0,89 değerine Terran Firebat sınıfında gözlemlendi.

Tablo 5.3 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması

Terran Birlikleri	Temel Sınıflama F1-Puanı	Detaylı Menzil Sınıflandırması F1-Puanı	Temel Sınıflandırma AUC Alanı	Detaylı Menzil Sınıflandırması AUC Alanı
Terran Ghost	0,70	0,71	0,99	1,0
Terran Vulture	0,57	0,91	0,89	0,97
Terran Goliath	0,76	0,91	0,97	0,97
Terran Siege Tank	0,38	1,0	0,78	0,80
Terran Wraith	0,68	0,99	0,97	0,97
Terran Science Vessel	0,24	1,0	0,75	1,0
Terran Battlecruiser	0,45	0,64	0,98	1,0
Terran Nuclear Missile	0,0	0,57	0,99	1,0
Terran Firebat	0,56	0,71	0,92	0,89
Terran Medic	0,59	0,88	0,85	0,89
Terran Valkyrie	0,26	0,36	0,98	0,97

İleri beslemeli sinir ağı modelinde Terran veri kümesi temel sınıflandırma ortalama f1 puanı 0.47 değerden detaylı menzil sınıflamasında 0.79 değere yükseldi. Temel sınıflandırma ortalama AUC alanı 0.92 değerden 0.95 değere yükseldi. Terran

verilerinin ileri beslemeli sinir ağı modelinde ortalama f1 puanları ve ortalama AUC alanlarının karşılaştırması Tablo 5.4’te verilmiştir.

Tablo 5.4 İleri Beslemeli Sinir Ağı Modelinde Terran Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması

Veri Kümesi	Temel Sınıflandırma Ortalama F1-Puanı	Detaylı Menzil Sınıflandırması Ortalama F1-Puanı	Temel Sınıflandırma Ortalama AUC Alanı	Detaylı Menzil Sınıflandırması Ortalama AUC Alanı
Terran	0.47	0,79	0,92	0,95

Uzun kısa vadeli hafıza ağılı özyinelemeli sinir ağı modelinde Zerg veri kümesinde her bir birlikte temel sınıflandırmadan detaylı menzil sınıflandırmasına geçildiğinde f1 puanında artış gözlemlendi. AUC alanlarında ise hali hazırda 1 AUC alanına sahip Zerg Devourer birliği bu alanı korurken, diğer birliklerin AUC alanlarının da temel sınıflandırmadan daha yüksek değerde olduğu görüldü. Uzun kısa vadeli hafıza ağılı özyinelemeli sinir ağı modelinde Zerg verilerinin temel sınıflandırma ve detaylı menzil sınıflandırması f1-puanları ve AUC alanlarının karşılaştırması Tablo 5.5’te verilmiştir. F1 puanında en büyük yükseliş 0.33 değerden 0,99 değerine Zerg Defiler birliğinde gözlemlendi En az yükseliş 0.83 f1 puanından 0.94 f1 puanına Zerg Mutalisk birliğinde gözlemlendi. AUC alanlarında en büyük artış 0.89 değerinden 0,98 değerine Zerg Defiler birliğinde gözlemlendi.

Tablo 5.5 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması

Zerg Birlikleri	Temel Sınıflandırma F1-Puanı	Detaylı Menzil Sınıflandırması F1-Puanı	Temel Sınıflandırma AUC Alanı	Detaylı Menzil Sınıflandırması AUC Alanı
Zerg Hydralisk	0,75	0,97	0,92	0,99
Zerg Ultralisk	0,71	0,95	0,97	1,0
Zerg Mutalisk	0,83	0,94	0,98	0,99
Zerg Guardian	0,84	0,98	0,99	1,0
Zerg Queen	0,58	0,81	0,94	0,98
Zerg Defiler	0,33	0,99	0,89	0,98
Zerg Scourge	0,49	1,0	0,89	1,0
Zerg Devourer	0,73	0,99	1,0	1,0
Zerg Lurker	0,60	1,0	0,92	1,0

Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı modelinde Zerg veri kümesi temel sınıflandırma ortalama f1 puanı 0,65 değerden detaylı menzil sınıflamasında 0,96 değere yükseldi. Temel sınıflandırma ortalama AUC alanı 0,94 değerden 0,99 değere yükseldi. Zerg verilerinin Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı modelinde ortalama f1 puanları ve ortalama AUC alanlarının karşılaştırması Tablo 5.6’da verilmiştir.

Tablo 5.6 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Zerg Veri Kümesinin Temel Sınıflandırma ve Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması

Veri Kümesi	Temel Sınıflandırma Ortalama F1-Puanı	Detaylı Menzil Sınıflandırması Ortalama F1-Puanı	Temel Sınıflandırma Ortalama AUC Alanı	Detaylı Menzil Sınıflandırması Ortalama AUC Alanı
Zerg	0,65	0,96	0,94	0,99

Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı modeli Terran veri kümesinde temel sınıflandırmadan detaylı menzil sınıflandırmasına geçildiğinde Terran Ghost, Terran Battlecruiser, Terran Firebat, Terran Medic ve Terran Valkyrie sınıflarında düşüş, Terran Vulture,, Terran Goliath, Terran Siege Tank, Terran Wraith, Terran Science Vessel, Terran Nuclear Missile sınıflarında artış gözlemlendi. AUC alanlarında Terran Goliath, Terran Wraith, Terran Battlecruiser, Terran Firebat, Terran Medic ve Terran Valkyrie sınıflarında düşüş, Terran Ghost sınıfında eşitlik, Terran Vulture, Terran Siege Tank, Terran Science Vessel ve Terran Nuclear Missile sınıfında artış görüldü. Terran verilerinin uzun kısa vadeli hafıza ağı özyinelemeli modelinde temel sınıflandırma ve detaylı menzil sınıflandırması f1-puanları ve AUC alanlarının karşılaştırması Tablo 5.7’de verilmiştir. F1 puanında en büyük yükseliş 0.29 değerden 0,93 değerine Terran Science Vessel birliğinde olduğu gözlemlendi. En büyük düşüş 0,56 f1 puanından 0.05 f1 puanına Terran Medic birliğinde gözlemlendi. AUC alanlarında en büyük artış 0.75 değerinden 1 değerine Terran Science Vessel birliğinde gözlemlendi. AUC alanlarında en büyük düşüş 0,99 değerden 0,59 değerine Terran Valkyrie sınıfında gözlemlendi.

Tablo 5.7 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması

Terran Birlikleri	Temel Sınıflama F1-Puanı	Detaylı Menzil Sınıflandırması F1-Puanı	Temel Sınıflandırma AUC Alanı	Detaylı Menzil Sınıflandırması AUC Alanı
Terran Ghost	0,67	0,06	1,0	1,0
Terran Vulture	0,54	0,89	0,89	0,95
Terran Goliath	0,74	0,88	0,97	0,95
Terran Siege Tank	0,41	0,54	0,78	1,0
Terran Wraith	0,68	0,99	0,98	0,71
Terran Science Vessel	0,29	0,93	0,75	1,0
Terran Battlecruiser	0,56	0,0	0,98	0,91
Terran NuclearMissile	0,0	0,01	0,97	1,0
Terran Firebat	0,56	0,45	0,92	0,57
Terran Medic	0,56	0,05	0,84	0,57
Terran Valkyrie	0,23	0,0	0,99	0,59

Uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı modelinde Terran veri kümesi temel sınıflandırma ortalama f1 puanı 0.48 değerden detaylı menzil sınıflamasında 0,44 değerine düştü. Temel sınıflandırma ortalama AUC alanı 0,91 değerden 0,84 değerine düştü. Terran verilerinin Uzun kısa vadeli hafıza ağı

özyinelemeli sinir ağı modelinde ortalama f1 puanları ve ortalama AUC alanlarının karşılaştırması Tablo 5.8’de verilmiştir.

Tablo 5.8 Uzun Kısa Vadeli Hafıza Ağı Özyinelemeli Sinir Ağı Modelinde Terran Veri Kümesinin Temel Sınıflandırma ve Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması

Veri Kümesi	Temel Sınıflandırma Ortalama F1-Puanı	Detaylı Menzil Sınıflandırması Ortalama F1-Puanı	Temel Sınıflandırma Ortalama AUC Alanı	Detaylı Menzil Sınıflandırması Ortalama AUC Alanı
Terran	0,48	0,44	0,91	0.84

1B konvolüsyonel modelde Zerg veri kümesinde her bir birlikte temel sınıflandırmadan detaylı menzil sınıflandırmasına geçildiğinde f1 puanında artış gözlemlendi. AUC alanlarında ise hali hazırda 1 AUC alanına sahip birlikler bu alanı korurken, diğer birliklerin AUC alanlarının da temel sınıflandırmadan daha yüksek değerde olduğu görüldü. 1B konvolüsyonel modelde Zerg verilerinin temel sınıflandırma ve detaylı menzil sınıflandırması f1-puanları ve AUC alanlarının karşılaştırması Tablo 5.9’da verilmiştir. F1 puanında en büyük yükseliş 0,38 değerinden 0,99 değere Zerg Defiler birliğinde gözlemlendi. En az yükseliş 0,83 f1 puanından 0,94 f1 puanına Zerg Mutalisk birliğinde gözlemlendi. AUC alanlarında en büyük artış 0,90 değerinden 0,98 değerine Zerg Defiler birliğinde gözlemlendi.

Tablo 5.9 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması

Zerg Birlikleri	Temel Sınıflandırma F1-Puanı	Detaylı Menzil Sınıflandırması F1-Puanı	Temel Sınıflandırma AUC Alanı	Detaylı Menzil Sınıflandırması AUC Alanı
Zerg Hydralisk	0,78	0,97	0,92	0,99
Zerg Ultralisk	0,74	0,95	0,98	1,0
Zerg Mutalisk	0,84	0,94	0,98	0,99
Zerg Guardian	0,86	0,98	1,0	1,0
Zerg Queen	0,58	0,81	0,93	0,98
Zerg Defiler	0,38	0,99	0,90	0,98
Zerg Scourge	0,52	1,0	0,90	1,0
Zerg Devourer	0,75	0,90	1,0	1,0
Zerg Lurker	0,62	1,0	0,93	1,0

1B konvolüsyonel modelde Zerg veri kümesinin temel sınıflandırma ortalama f1 puanı 0.67 değerden detaylı menzil sınıflamasında 0.95 değere yükseldi. Temel sınıflandırma ortalama AUC alanı 0.95 değerden 0.99 değere yükseldi. Zerg verilerinin 1B konvolüsyonel modelde ortalama f1 puanları ve ortalama AUC alanlarının karşılaştırması Tablo 5.10’da verilmiştir.

Tablo 5.10 1B Konvolüsyonel Modelde Zerg Veri Kümesinin Temel Sınıflandırma ve Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması

Veri Kümesi	Temel Sınıflandırma Ortalama F1-Puanı	Detaylı Menzil Sınıflandırması Ortalama F1-Puanı	Temel Sınıflandırma Ortalama AUC Alanı	Detaylı Menzil Sınıflandırması Ortalama AUC Alanı
Zerg	0,67	0,95	0,95	0,99

1B konvolüsyonel modelde Terran veri kümesinde temel sınıflandırmadan detaylı menzil sınıflandırmasına geçildiğinde Terran Ghost ve Terran Valkyrie sınıflarında f1 puanında düşüş, geriye kalan sınıflarda artış gözlemlendi. AUC alanlarında Terran Goliath, Terran Wraith, Terran Firebat ve Terran Valkyrie birliklerinde düşüş, Terran Ghost ve Terran Nuclear Missile birliklerinde 1 değerine eşitlik, diğer birliklerde yükseliş görünüyor. Terran verilerinin 1B konvolüsyonel modelde temel sınıflandırma ve detaylı menzil sınıflandırması f1-puanları ve AUC alanlarının karşılaştırması Tablo 5.11’de verilmiştir. F1 puanında en büyük yükseliş 0,27 değerinden 1 değerine Terran Science Vessel birliğinde olmuştur. En büyük düşüş Terran Ghost birliğinde 0,73’ten 0,67 değerine ve Terran Valkyrie sınıfında 0,33 değerinden 0,27 değerine gözlemlendi. AUC alanlarında en büyük artış 0,76 değerinden 1 değerine Terran Science Vessel birliğinde gözlemlendi. AUC alanlarında en büyük düşüş 0,93 değerinden 0,90 değerine Terran Firebat ve 0,96 değerinden 0,93 değerine Terran Vakyrrie sınıfında gözlemlendi.

Tablo 5.11 1B Konvolüsyonel Modelde Terran Verilerinin Temel Sınıflandırma ve Detaylı Menzil Sınıflandırması F1-puanları ve AUC Alanlarının Karşılaştırması

Terran Birlikleri	Temel Sınıflama F1-Puanı	Detaylı Menzil Sınıflandırması F1-Puanı	Temel Sınıflandırma AUC Alanı	Detaylı Menzil Sınıflandırması AUC Alanı
Terran Ghost	0,73	0,67	1,0	1,0
Terran Vulture	0,56	0,91	0,90	0,96
Terran Goliath	0,73	0,90	0,97	0,96
Terran Siege Tank	0,40	1,0	0,78	0,80
Terran Wraith	0,68	0,99	0,99	0,97
Terran Science Vessel	0,27	1,0	0,76	1,0
Terran Battlecruiser	0,55	0,63	0,99	1,0
Terran NuclearMissile	0,0	0,57	1,0	1,0
Terran Firebat	0,60	0,73	0,93	0,90
Terran Medic	0,59	0,89	0,85	0,90
Terran Valkyrie	0,33	0,27	0,99	0,96

1B konvolüsyonel modelde Terran veri kümesi temel sınıflandırma ortalama f1 puanı 0,49 değerden detaylı menzil sınıflamasında 0,78 değere yükseldi. Temel sınıflandırma ortalama AUC alanı 0,92 değerden 0,95 değere yükseldi. Terran verilerinin 1B konvolüsyon modelde ortalama f1 puanları ve ortalama AUC alanlarının karşılaştırması Tablo 5.2’de verilmiştir.

Tablo 5.12 1B Konvolüsyonel Modelde Terran Verilerinin Temel Sınıflandırma ve Menzil Sınıflandırması Ortalama F1-puanları ve Ortalama AUC Alanlarının Karşılaştırması

Veri Kümesi	Temel Sınıflandırma Ortalama F1-Puanı	Detaylı Menzil Sınıflandırması Ortalama F1-Puanı	Temel Sınıflandırma Ortalama AUC Alanı	Detaylı Menzil Sınıflandırması Ortalama AUC Alanı
Terran	0,49	0,78	0,92	0,95

Temel sınıflandırmada sınıfların çoğunda bütün modellerde doğru tahminlerin duyarlılık yüzdesinin yanlış tahminlerden daha yukarıda olduğu gözlemlendi. Sadece Terran Science Vessel, Terran Dropship, Terran Nuclear Missile ve Terran Valkyrie sınıflarında yanlış sınıfa en yüksek duyarlılık yüzdesi ile tahmin yapıldığı görüldü. Detaylı menzil sınıflandırmasında, Terran detaylı menzil veri kümeleri ile eğitilen uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı modeli hariç, bütün sınıflarda doğru tahminlerin duyarlılık yüzdesinin diğer sınıflardan daha yüksekte olduğu görüldü.

En iyi tahminler uzun kısa vadeli hafıza ağı özyinelemeli sinir ağı modelinde Zerg sadece havadan havaya saldıranlar veri kümesi ile alındı. Zerg Scoure birliğinde 2627 ve 1 yanlış tahmin yaptığı gözlemlendi. Zerg Devourer biriminde 37 adet doğru tahmin yaptığı ve hiç yanlış tahmin yapmadığı gözlemlendi.

Zerg veri kümesinin temel sınıflandırmada en düşük f1 puanı 0,65 değerinin, Terran veri kümesinin en yüksek f1 puanı 0,49 değerinden ve Zerg veri kümesi detaylı menzil sınıflamasının en düşük f1 puanı 0,95 değerinin Terran veri kümesinin detaylı menzil sınıflandırmasının en yüksek f1 puanı 0,79 değerinden daha yüksek olmasından modellerin Zerg veri kümesi için daha iyi sonuç verdiği anlaşıyor. Hatta özyinelemeli modelde detaylı menzil sınıflandırmasının f1 puanlarının ortalamalarının, temel sınıflandırmadan daha düşük çıktığı gözlemlendi. AUC alanlarında da Zerg veri kümesinin detaylı menzil sınıflamasında bütün modellerin ortalama AUC değerleri 0,99 değerinde; Terran veri kümesinde detaylı menzil sınıflamasında en yüksek AUC değeri 1B konvolüsyonel model ve ileri beslemeli sinir ağı modelinde 0,95 değerindedir. Genel olarak bakıldığında, Terran veri kümesi ile özyinelemeli sinir ağı hariç, detaylı menzil sınıflandırmasında doğruluğun, f1 puanlarının ve AUC değerlerinin yüksek olduğu görülmektedir. Modeller performanslı ve ayırt edicilikleri yüksektir.

Zerg modellerinde 10, Terran modellerinde 12 çıkış olması ve Zerg veri kümesinin Terran veri kümesinden daha fazla satıra sahip olması Zerg modellerinin daha iyi sonuç vermesine katkı sağladığı düşünülebilir. Aynı zamanda Zerg birliklerinin menzillerinin birbirlerinden farklı olması ve Terran birliklerinin menzillerinin 5 ve 6 değerinde yoğunlaşması da bu sonucu ortaya çıkarmış olabilir. Diğer yandan Terran veri kümesindeki birlik sayısı orantısızlığı da modellerin doğru sonuç vermesini engellemiş olabilir.

Büyücü birliklerinden Zerg Defiler ve Terran Science Vessel detaylı menzil sınıflamasında en yüksek f1 puanı ve AUC alanı artışı olan birliklerdir. Büyücülerin genelde her duruma uygun olması sebebiyle modeller özel durumları ayırt edemiyor olabilir fakat detaylı sınıflandırmaya geçildiğinde büyücünün kullanımına uygun durumları başarılı ayırt ediyorlar.

Zerg veri kümesi için modelleri değerlendirdiğimizde en yüksek ortalama f1 puanın 0,95 puanla uzun kısa vadeli hafıza ağı özyinelemeli sinir ağında detaylı menzil sınıflandırmasında olduğunu görülmektedir. Diğer modellerden 0.1 değerinde daha yüksektir. Detaylı menzil sınıflaması AUC alanları her modelde eşit olduğundan Zerg veri kümesi için uzun kısa vadeli hafıza ağı özyinelemeli sinir ağının en iyi model olduğu sonucunu çıkarıyoruz. Temel sınıflandırma için ise en yüksek f1 puanı olan 0,67 değerine sahip olduğu ve AUC değerlerinde en yüksek AUC değeri 0,95 alan değerine sahip 1B konvolüsyonel modelin en iyi model olduğu anlaşıyor. Diğer modellerden f1 puanında 0.2 değerinde daha yüksekte ve AUC alanlarında, diğer modellerden 0,1 değerinde daha yüksektir.

Terran veri kümesi için modelleri değerlendirdiğimizde detaylı menzil sınıflandırmasında en yüksek f1 puanının 0,79 puanla ileri beslemeli sinir ağında olduğunu görüyoruz. Ardından gelen konvolüsyonel modelden f1 puanı 0,1 değerinde daha yüksektir. AUC alanları ileri beslemeli sinir ağı modeli ve konvolüsyonel modelde 0,95 değerine eşittir. İleri beslemeli sinir ağının Terran veri kümesi detaylı menzil sınıflandırması için en iyi model olduğunu anlayabiliriz. Temel sınıflandırma için 0.49 f1 puanı ve 0.92 değerinde AUC alanı ile 1B konvolüsyonel modelin Terran veri kümesi için en iyi temel sınıflandırma modeli olduğunu görebiliriz.

6. GEÇERLİLİĞE TEHDİTLER

Çalışmamızda geçerliliğe tehditler bulunmaktadır.

6.1. İçsel Tehditler

- Çok az bir oyunda veri tabanında, özellikle Zerg Defiler birliğinde, destroy karesi dönüşüm komutundan önce geliyor. Belki bunun Zerg Defiler'in başka bir Zerg birliğini yok edip kendisine enerji ürettiği "consume" büyüğü sebebi ile ilgisi olabilir.
- Zerg oyuncunun larva birliğe verdiği son dönüşüm komutunun her zaman gerçekleştiği farz edildi ama bazı durumlarda, kaynak yetersizliğinden dolayı, bu birlik üretilmeye başlanmamış olabilir.
- Eğer Zerg oyuncusu larvaya bir birlik türüne üretim emri vermiş ve kaynak yetersizliği sebebi ile bu birlik üretilmemiş, sonra aynı larvaya başka bir birlik türüne üretim emri vermişse ilk üretim emri verilen birlikte veri kümesinde üretilmiş olarak bulunuyor.
- Zerg binalarının üretim komutları UnitGroupID'den verildiğinden, hangi UnitID'ye sahip Drone'a verildiği bilinmiyor. Bu yüzden bu birliğin ne zaman yok edildiği bilinmiyor. Bu sebeple Zerg binalarını veri kümesinde yok edilmiyor.

6.2. Dışsal Tehditler

Starcraft oyunu çok geniş bir durum ve eylem alanında oynandığı için çalışmamızda elde edilen değerler kullandığımız veri tabanındaki oyunlar için geçerlidir. Oynanacak oyunlarda göstereceği performans gözlenmelidir.

7. SONUÇ

Sistemantik literatür taramasında keşfedilen başarılı öznitelikler ve modellere uygun veri kümeleri profesyonel oyuncuların oyunlarının detaylı verilerinden oluşan veri tabanından işlemlerden geçirilerek oluşturuldu. Starcraft oyunundaki iki ırkın, Zerg ve Terran oyuncularının verileri Zerg ve Terran veri kümelerinde toplandı. Her bir satırda oyuncuda ve rakipte her birlik türünden kaç adet bulunduğu ve bu durumda oyuncunun hangi birliği üretmeyi seçtiği çıkış sütununa işlendi. Toplamda 2 adet, Zerg ve Terran veri kümesi elde edildi. Bu temel veri kümeleri ile ileri beslemeli sinir ağı modeli, uzun kısa vadeli hafıza ağılı özyinelemeli modeli ve 1B konvolüsyonel model eğitildi. Ardından birlikler menzillerine göre sınıflandırıldı ve eğitim tekrar gerçekleştirildi. Bunun ardından, modeller sadece aynı menzil sınıflamasındaki birliklerin bulunduğu veri kümesi ile eğitildi. Bulgular sunuldu. Genel olarak, Terran veri kümesi ile eğitilen uzun kısa vadeli hafıza ağılı özyinelemeli model hariç, detaylı menzil sınıflaması değerleri her iki veri kümesinde de temel sınıflandırmanın yukarısında oldu. Özellikle büyücü sınıflamalarında en büyük artış gerçekleşti. Zerg ırkı detaylı menzil sınıflamasında Terran ırkının üzerinde AUC alanlarına ve f1 puanlarına sahip oldu.

Modellerin daha iyi hale gelmesi için daha fazla profesyonel ve yüksek seviye oyunlar bulunabilir. Starcraft'ta yüksek sayıda hamle olsa da aslında oyuna katkıda bulunmayan hamleler bu modeller kullanarak elenebilirler. Profesyonel oyun sayıları belli bir rakamda olduğundan eğitimin ardından pekiştirmeli öğrenmeye geçilebilir. Her bir oyuncunun kendine özel veri kümesi hazırlanıp modeller eğitilebilir ve bunun ardında pekiştirmeli öğrenmeye geçilip sonuçlar gözlemlenebilir.

Zerg veri kümesi için, yüksek f1 puanı ve AUC alanları, ile en iyi modelin uzun kısa vadeli hafıza ağılı özyinelemeli modeli ve Terran veri kümesi için en iyi modelin ileri beslemeli sinir ağı modeli olduğuna karar verildi.

KAYNAKÇA

Barbara Kitchenham and Stuart Charters. (2007). Guidelines for performing Systematic Literature Reviews in Software Engineering.

David Churchill, A. S. (2016). Fast Heuristic Search for RTS Game Combat Scenarios.

Frederik Schadd, S. B. (2014). Opponent Modelling In Real-time Strategy Games.

Géron, A. (2019). Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media.

Guillaume Chaslot, S. B. (2008). Monte-Carlo Tree Search: A New Framework for Game AI. Proceedings of the Fourth Artificial Intelligence and Interactive Digital Entertainment Conference.

Jagdale, D. (2021, Ekim). Finite State Machine in Game Development. International Journal of Advanced Research in Science, Communication and Technology (IJARSCT), s. 384-390.

Johansson, J. H. (2008). A Multiagent Potential Field-Based Bot for Real-Time Strategy Games.

Johansson, J. H. (2008). Dealing with Fog of War in a Real Time Strategy Game. IEEE Symposium on Computational Intelligence and Games (CIG'08).

Liquipedia. (2008, 07 25). Liquipedia. Liquipedia.net: <https://liquipedia.net/starcraft/File:9pool.png> adresinden alındı

Liquipedia. (2016, 02 25). Liquipedia. liquipedia.net: <https://liquipedia.net/starcraft/File:Hydralurkzvt.png> adresinden alındı

Marcel van der Heijden, S. B. (2008). Dynamic Formations in Real-Time Strategy Games. IEEE Symposium on Computational Intelligence and Games (CIG'08).

Piotr Mirowski, R. P. (2017). Learning To Navigate In Complex Environments. ICLR.

Sander Bakkes, P. S. (2007). Predicting Success in an Imperfect-Information.

Sander Bakkes, P. S. (2008). Rapid Adaptation of Video Game AI. IEEE Symposium on Computational Intelligence and Games (CIG'08).

Santiago Ontañón, G. S. (2013). A Survey of Real-Time Strategy Game AI. TCIAIG, s. 1-19.

Tesauro, G. (1992). Practical Issues in Temporal Difference Learning. Machine Learning, s. 257-277.

Volodymyr Mnih, K. K. (2013). Playing Atari with Deep Reinforcement Learning.

Watson, G. R. (2014). An Improved Dataset and Extraction Process for Starcraft AI. Proceedings of the Twenty-Seventh International Florida Artificial Intelligence Research Society Conference.

Yu Chen, Y. L. (2019). Macro and Micro Reinforcement Learning for Playing Nine-ball Pool.

Zhen, Y., Wanpeng, Z., & Hongfu, L. (2018). Artificial Intelligence Techniques on Real-time Strategy Games. CSAI '18 (pp. 11-21). Shenzhen: ACM.



EK1. LİTERATÜR TARAMASINDA KEŞFEDİLEN ENGELLER VE ÖNERİLEN ÇÖZÜMLER

Tablo A.1 Literatür Taramasında Keşfedilen Engeller ve Çözümler

Engeller	Önerilen Çözümler	Referanslar
CPU'daki yük zaman içinde dalgalanır ve performans limitine ulaşabilir. Bu yoğunlukla, yapay zekanın en fazla olasılık ve karar verme ile karşılaştığı, büyük çapta olan saldırılarda meydana gelir.	Algoritma mümkün olan en az işlem kaynakları ile başarılı bir şekilde çalışmalı ve işe yarar bir çözümü çabuk sunmalıdır. Yapay zekaya daha fazla zaman tanınırsa, bu çözüm, ardından, genişletilebilir.	S13
Kompleks Problem Çözümü (Uzaktaki bir konuma ilerleme benzeri)	Bir parçalar oluşumu, bir çözüm yolu bulunduktan sonra (ör. A* algoritması kullanılmasından sonra) başka bir zaman kullanılmak üzere saklanır. Bu saklanan oluşum, daha karmaşık bir problem çözerken, çözüm arama zamanını hatıra değer bir ölçüde azaltabilir.	S31
Öğrenme temelli veya çevrimdışı optimizasyon uzun zaman alır.	Çevrimiçi optimizasyon eğitime ihtiyaç duymaz ve eylemleri ardı ardına anında organize eder.	S6
Tatminkar bir performans sergilemek için, dev tarihsel veri ve/veya çok sayıda eğitim seansları gereklidir.	Bir oyun yapay zeka tasarımı davranışlarını çevrimiçi ayarlayabilir.	S41
Eylemi, hesaplama uğruna ertelemek.	Birliklere manevra yaptırmanın optimal yaklaşımın belirlenmesi (Sebeplendirme işlemine daha fazla elemanın eklenmesinin masrafı, karar vermek yerine, optimizasyonun potansiyel avantajlarına katkı sağlayıp sağlamadığına bakılırken, iyi değerlendirilmelidir.) için YGA (ağaçlara uygulanan yukarı güven hatları) çevrimdışı eğitim ve simülasyonla kombinasyonlanır.	S30
Kaynak planlaması, belirsizlik altında karar verme, mekansal ve zamansal mantık çıkarma, farklı yapay zekalar arasında iş birliği, rakip modellemesi ve gerçek zamanlı rekabet planlaması,	Planlama, sabit kod yaklaşımlar, vaka temelli muhakeme, Evrimsel Algoritmalar ve yapay öğrenme, stratejide anahtar teknolojiler. Genetik algoritmalar, Oyun Ağacı Araması, Evrimsel Algoritmalar, vaka temelli muhakeme, Monte	S10

gerçek zamanlı strateji oyunlarında erken yapay zeka araştırmalarında altı farklı sorun olarak öne çıktı.	Carlo Ağaç araması, Bayesian Model ve yapay öğrenme, taktiklerde anahtar teknolojilerdir.	
Grafikler yerine yapay zeka geliştirilmeye ayrılan zaman.	Zengin veri ve ortam.	S35
Yapay zeka bütün kullanıcı eylemlerini biliyor.	Makine Öğrenmesi	S37
Her bir birlik için ikna haritası parametrelerinin ayarlanması.	Üç ikna haritasının, üç potansiyel alan ile kolayca değiştirilebilen bir şekilde kombinasyonlanması.	S14
Tam olmayan durum verisi ve geciken ödüller sebebi ile, eylemler ve ödüller arasında korelasyon gözlemlenmesi güç.	Derin Q Öğrenmesi	S18, S24
Hafıza ve zaman, Q-Learning için iki ana engededir. Biraz uzun bir oyunda her bir potansiyel eylem için Q değerlerini kayıt alacak bir hafıza devasadır ve gerekli Q tablosunu oluşturacak her bir durumu inceleyecek zaman bulunması uygulanabilir değildir.	Derin Q-Öğrenmesi, aslında, bir sinir ağına o an ki durum verilerek Q değerinin tahmin edilmesi ile Q tablosunun ortadan kaldırılması metodudur.	S20
Araştırma ve suistimal arasındaki takas pekiştirmeli öğrenmedeki en zorlu konulardan biridir. Poliçedeki her adımda en iyi eylemi gerçekleştirsek, yerel optimumda kalacağımız oldukça bellidir. Diğer yandan, devasa durum alanını araştırırsak, model yakınsamada oldukça zorlanacaktır.	Eğitimde eylemleri seçmek için, bu anki en iyi eylemi 1-epsilon olasılığı ile seçen ve epsilon olasılığı ile rasgele araştırma eylemi alan, epsilon-cimri tekniği kullanılır.	S27
Çoğu durumda, yapay zeka geliştiricileri, daha güçlü oyun ajanlarını yaratırken, oyun özelinde uzmanlıklarına ve işlem kapasitesindeki artışlara güvenir. Özünde yapay zeka, daha akıllı hale gelmek yerine, uzman bilgisi ve işlemci gücü ile bezenmiştir.	XLM formatında yazılan bir gerçek zamanlı strateji dili daha kolay bir makine öğrenmesi imkanı sağlar.	P56
Her bir logun hangi kısımlarının alınıp, analiz	Çarpışma verilerinin ayrıştırılması, anahtar özelliklerin tanımlanması	P57

edilerek, metrikleri anlamlı bir şekilde ifade edebileceğinin keşfi.	ve K-ortalama kümeleme kullanılması.	
Oyunun iyi anlaşılması.	Gelecek modelleme planlarının geliştirilmesi için dışarıdan danışman yardımı alındı.	S33
Veri kümesi eksik.	Tek botun aynı taktiği farklı botlara karşı oynamaya ayarlandığı, BWAPI'den bilgisayara karşı bilgisayar maçlarının replay kayıtları.	S33
Özellik seçimi.	Özellikler replay gözlemi ve profesyonel danışmanlık aracılığıyla belirlendi.	S33
Konseptin kanıtlanması için strateji.	Model geliştirmesi için test senaryosu olan sadece dört taktiğe odaklanmak.	S33
Gerçek zaman özelliği.	Oyunun gerçek doğasından dolayı, eylemleri gruplandırmak için bir zaman aralığı seçildi.	S33
Belli eylemlerin, durum varlıkları arasında bir ilişkiyi temsil etmesinden dolayı, durum ve eylem açısından poliçeleri parametrelemenin açık, belirgin bir yöntemi olmaması.	Bir serüvenin başında derin ağ ayarlarının küçük bir kısmını rasgele dönüştürerek ve dönüştürülmüş, gerekirci poliçeyi serüvende uygulayarak, direk olarak poliçe alanı araştırılır.	S29

EK2. SLR ÇALIŞMASINDA SEÇİLEN YAYINLAR

- [S1] Tavares, A. R., Zuin, G. L., Azpurua, H., & Chaimowicz, L. (2017). Combining genetic algorithm and swarm intelligence. *SBC Journal on Interactive Systems*, 4-19.
- [S2] Justesen, N., & Risi, S. (2017). Continual Online Evolutionary Planning for In-Game Build Order Adaptation in StarCraft. *GECCO '17*. Berlin.
- [S3] Zelinka, I., & Sikora, L. (2015). StarCraft: Brood War - Strategy Powered by the SOMA Swarm Algorithm. *IEEE CIG*, (pp. 511-516).
- [S4] Ferreira, L., Pereira, R., Toledo, C., & Pereira, R. (2014). Evolutionary Approaches to Evolve AI Scripts for a RTS Game. *GECCO'14*, 47-48.
- [S5] Shah, C. S., Shah, S. M., & Singh, D. (2011). Performance Improvement in Game Playing using Evolutionary Computation by Large Search Space Exploration.
- [S6] Liu, Y., Li, C., & Zeng, S. (2020). A Simulation-based Online Evolutionary Algorithm for Combat in StarCraft II. *12th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, (pp. 113-116).
- [S7] Tong, C. K., On, C. K., & Mountstephens, J. (2012). Game AI Generation using Evolutionary Multi-Objective Optimization. *IEEE World Congress on Computational Intelligence*. Brisbane.
- [S8] Keaveney, D., & O'Riordan, C. (2011). Evolving Coordination for Real-Time Strategy Games. *IEEE Transactions On Computational Intelligence And AI In Games*, (pp. 155-167).
- [S9] Freitas, J. M., Souza, F. R., & Bernardino, H. S. (2018). Evolving Controllers for Mario AI Using Grammar-based Genetic Programming. *IEEE Congress on Evolutionary Computation (CEC)*.
- [S10] Zhen, Y., Wanpeng, Z., & Hongfu, L. (2018). Artificial Intelligence Techniques on Real-time Strategy Games. *CSAI '18* (pp. 11-21). Shenzhen: ACM.
- [S11] Lin, J., He, J., & Zhang, N. (2019). Application of behavior tree in AI design of MOBA games. *2nd IEEE International Conference on Knowledge Innovation and Invention*, (pp. 323-326).
- [S12] Leece, M., & Jhala, A. (2014). Opponent State Modeling In RTS games with limited information using Markov Random Fields.
- [S13] Rogers, K. D., & Skabar, A. A. (2014). A Micromanagement Task Allocation System for Real-Time Strategy Games. *IEEE Transactions On Computational Intelligence And AI In Games*, 67 - 77.

- [S14] Liu, S., Louis, S. J., & Nicolescu, M. (2013). Comparing Heuristic Search Methods for Finding Effective Group Behaviors in RTS Game. IEEE Congress on Evolutionary Computation, (pp. 1371-1378). Cancun.
- [S15] Hu, W., Zhang, Q., & Mao, Y. (2011). Component-Based Hierarchical State Machine - A Reusable and Flexible Game AI Technology.
- [S16] Shantia, A., Begue, E., & Wiering, M. (n.d.). Connectionist Reinforcement Learning for Intelligent Unit Micro Management in StarCraft.
- [S17] Xie, D., & Zhong, X. (2019). Deep Deterministic Policy Gradients with Transfer Learning Framework in StarCraft Micromanagement.
- [S18] Andersen, P.-A., Goodwin, M., & Granmo, O.-C. (2018). Deep RTS: A Game Environment for Deep Reinforcement Learning in Real-Time Strategy Games.
- [S19] Tian, Y., Gong, Q., Shang, W., Wu, Y., & Zitnick, C. L. (2017). ELF: An Extensive, Lightweight and Flexible Research Platform for Real-time Strategy Games. 31st Conference on Neural Information Processing Systems (NIPS 2017), (pp. 1-14). Long Beach.
- [S20] Paudel, P. (2020). Exploring Game Playing AI using Reinforcement Learning Techniques.
- [S21] Kamon, S., Nguyen, T. D., Harada, T., Thawonmas, R., & Nishikawa, I. (2015). Improving Heuristic Search for RTS-Game Unit Micromanagement Using Reinforcement Learning. IEEE 4th Global Conference on Consumer Electronics (GCCE), (pp. 25-26).
- [S22] Kowalczyk, Z., Cybulski, J., & Czubenko, M. (2019). JamesBot – an intelligent agent playing StarCraft II.
- [S23] Justesen, N., & Risi, S. (2017). Learning Macromanagement in StarCraft from Replays using Deep Learning. IEEE Conference on Computational Intelligence and Games, (pp. 162-169).
- [S24] Kim, H., & Lee, W. (2021). Real-Time Path Planning Through Q-learning's Exploration Strategy Adjustment. 2021 International Conference on Electronics, Information, and Communication (ICEIC).
- [S25] Zhang, T., Li, X., Li, X., Liu, G., & Tian, M. (2020). Reinforcement Learning based Strategy Selection in StarCraft: Brood War.
- [S26] Tang, Z., Zhao, D., Zhu, Y., & Guo, P. (2018). Reinforcement Learning for Build-Order Production in StarCraft II. 8th International Conference on Information Science and Technology, (pp. 153-158).
- [S27] Shao, K., Zhu, Y., & Zhao, D. (2018). StarCraft Micromanagement with Reinforcement Learning and Curriculum Transfer Learning.

- [S28] Wender, S., & Watson, I. (2012). Applying Reinforcement Learning to Small Scale Combat in the Real-Time Strategy Game StarCraft:Broodwar. IEEE Conference on Computational Intelligence and Games (CIG'12).
- [S29] Usunier, N., Synnaeve, G., Lin, Z., & Chintala, S. (2016). Episodic Exploration for Deep Deterministic Policies: An Application to StarCraft Micromanagement Tasks.
- [S30] Bowen, N., Todd, J., & Sukthankar, G. (2013). Adjutant Bot: An Evaluation of Unit Micromanagement Tactics.
- [S31] Ho, S.-B., & Liausvia, F. (2014). A Rapid Learning and Problem Solving Method Application To The Starcraft Game Environment.
- [S32] Synnaeve, G., & Bessiere, P. (2016). Multiscale Bayesian Modeling for RTS Games: An Application to StarCraft AI. IEEE Transactions On Computational Intelligence And AI In Games, (pp. 338-350).
- [S33] Certicky, M., Sarnovsky, M., & Varga, T. (2020). Use of Machine Learning Techniques in Real-time Strategy Games.
- [S34] Nguyen, T., Nguyen, K., & Thawonmas, R. (2014). Integrating Fuzzy Integral and Heuristic Search for Unit Micromanagement in RTS Games. IEEE Congress on Evolutionary Computation (CEC), (pp. 9-12). Beijing.
- [S35] Tanuar, E., Abbas, B. S., Trisetyarso, A., Kang, C.-H., Gaol, F. L., & Suparta, W. (2018). Back Propagation Neural Network Experiment On Team Matchmaking MOBA game. International Conference on Information and Communications Technology (ICOIACT), (pp. 240-243).
- [S36] Adhikari, N. K., Liu, S. J., & Spurgeon, W. (2018). Co-evolving Real-Time Strategy Game Micro. IEEE Symposium Series on Computational Intelligence SSCI 2018, 1990-1997.
- [S37] Wang, H., Hg, P. H., Niu, B., & Shiu, S. C. (2009). Case Learning and Indexing in Real Time Strategy Games. Fifth International Conference on Natural Computation, (pp. 100-104).
- [S38] Young, J., Smith, F., Atkinson, C., Poyner, K., & Chothia, T. (2021). SCAIL: An integrated Starcraft AI System. IEEE Conference on Computational Intelligence and Games (CIG'12), (pp. 438-445).
- [S39] Nguyen, T., Nguyen, K., & Thawonmas, R. (2013). Potential Flow for Unit Positioning During Combat in StarCraft. IEEE 2nd Global Conference on Consumer Electronics (GCCE), (pp. 10-11).
- [S40] Bakkes, S. C., Spronck, P. H., & Herik, J. v. (2009). Opponent modelling for case-based adaptive game AI. Entertainment Computing 1, 27-37.

- [S41] Carneiro, E. M., Cunha, A. M., & Dias, L. A. (2014). Adaptive Game AI Architecture with Player Modeling. 11th International Conference on Information Technology: New Generations, (pp. 40-45).
- [S42] Ballinger, C., & Louis, S. (2013). Comparing Heuristic Search Methods for Finding Effective Real-Time Strategy Game Plans. IEEE Symposium on Computational Intelligence for Security and Defense Applications (CISDA).
- [S43] Silva, C., Moraes, R. O., Lelis, L. H., & Gal, K. (2019). Strategy Generation for Multiunit Real-Time Games via Voting. IEEE Transactions On Games, (pp. 426-435).
- [S44] Kumar, V., Singh, D., Bhardwaj, G., & Bhatia, A. (2020). Application of Neurological Networks in an AI for Chess Game. Research, Innovation, Knowledge Management and Technology Application for Business Sustainability (INBUSH), (pp. 125-130).
- [S45] Burmeister, J., & Wiles, J. (1995). The Challenge of Go as a Domain for AI Research: A Comparison Between Go and Chess.
- [S46] Sanchez-Ruiz, A., Lee-Urban, S., Munoz-Avila, H., Diaz-Agudo, B., & Gonzalez-Calero, P. (2014). Game AI for a Turn-based Strategy Game with Plan Adaptation and Ontology-based retrieval.
- [S47] Preuss, M., Beume, N., Danielsiek, H., Hein, T., Naujoks, B., Piatkowski, N., . . . Wessing, S. (2012). Towards Intelligent Team Composition and Maneuvering in Real-Time Strategy Games. IEEE Transactions On Computational Intelligence And AI In Games, 2, 82-97.
- [S48] Wang, Z., Nguyen, K. Q., Thawonmas, R., & Rinaldo, F. (2012). Monte-Carlo Planning For Unit Control In Starcraft. The 1st IEEE Global Conference on Consumer Electronics 2012, (pp. 263-264).
- [S49] Urmanov, M., Alimanova, M., & Askar, N. (2019). Training Unity Machine Learning Agents using reinforcement learning method. 15th International Conference on Electronics Computer and Computation (ICECCO).
- [S50] Silva, V. d., & Chaimowicz, L. (2014). On the Development of Intelligent Agents for MOBA Games. 14th Brazilian Symposium on Computer Games and Digital Entertainment, (pp. 142-151).
- [S51] Padmanahan, V., Goud, P., Pujari, A. K., & Sethy, H. (2015). Learning in Real-time Strategy Games. International Conference on Information Technology, (pp. 165-170).
- [S52] Neilsen, M. L. (2018). Two-player games for learning real-time model checking. International Conference on Computational Science and Computational Intelligence (CSCI), (pp. 549-554).
- [S53] Kristoffk, S., Malik, P., Kasas, M., & Neupauer, S. (2020). StarCraft agent strategic training on a large human versus human game replay dataset.

Proceedings of the Federated Conference on Computer Science and Information Systems, (pp. 391-399).

- [S54] Kim, M.-J., Kim, K.-J., Kim, S., & Dey, A. K. (2018). Performance Evaluation Gaps in a Real-Time Strategy Game Between Human and Artificial Intelligence Players. *IEEE Access*, 6, 13575-13586.
- [S55] Kim, M.-J., Kim, S., Kim, K.-J., & Dey, A. K. (2016). Evaluation of StarCraft Artificial Intelligence Competition Bots by Experienced Human Players. *Late-Breaking Work: Games & Playful Interaction*, 1915-1921.
- [S56] Hayes, R., Beling, P., & Scherer, W. (2014). The Need For A Real Time Strategy Game Language. *Proceedings of the 2014 Winter Simulation Conference*, (pp. 3495-3504).
- [S57] Gow, J., Baumgarten, R., Cairns, P., Colton, S., & Miller, P. (2012). Unsupervised Modeling of Player Style With LDA. *IEEE Transactions On Computational Intelligence And AI In Games*, 4, 152-156.
- [S58] Gabriel, I., Negru, V., & Zaharie, D. (2012). Neuroevolution based Multi-Agent System For Micromanagement in Real-Time Strategy Games. 32-34.
- [S59] Cunha, R. d., & Chaimowicz, L. (2010). An Artificial Intelligence System to Help The Player of Real-Time Strategy Games. *Brazilian Symposium on Computer Games and Digital Entertainment*, (pp. 71-81). Belo Horizonte.