

## Otonom Araçlar İçin Uçtan-Uca Gerçek Zamanlı, Hataya Dirençli Davranışsal Tahmin Modülü

Tolga KAYIN <sup>\*</sup>, Çağatay Berke ERDAŞ <sup>2</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü, Baskent Üniversitesi, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği bölümü, Baskent Üniversitesi, Türkiye

<sup>\*</sup>([tlg\\_kayin@hotmail.com](mailto:tlg_kayin@hotmail.com)) Başlıca yazarın mail adresi

**Özet** – Şehirleşmenin, nüfus yoğunluğunun git gide arttığı dünyada ulaşım yöntemleri de çeşitlenmekte ve insansız araçların kullanımı yaygınlaşmaktadır. İnsansız araçlar görevlerini otonom yapabilmeleri için canlılarla benzer şekilde kendi konumlarını, çevreyi algılamaları ve çevresel faktörlerin olası hareketlerini/güzergahlarını tahmin edebilmeleri gerekmektedir. Otonom araçlarda aracın doğru planlama yapabilmesi için çevresindeki nesnelere gelecekte olabileceği konumu yüksek başarıyla tahmin edilebilmesi aracın ve çevresindeki faktörlerin güvenliği için son derece önemlidir. Davranışsal tahminleme modülü olmayan bir otonom araç bütün nesnelere statik kabul edip ona planlama yapar fakat otoyol koşulları ya da şehir trafik senaryolarında araçların ya da yayaların olası güzergahları hesaba katılmadığında kaza kaçınılmaz olacaktır. Bu çalışmada tehlikeleri önlemek amacıyla hızlı ve başarılı bir robotik davranışsal tahmin modülü geliştirilmiştir.

*Anahtar Kelimeler – Otonom Araçlar, Davranışsal Tahminleme, Güzergah Tahminleme, ROS, Robotic Operating System*

### 1. GİRİŞ

Otonom araçların işlevi ve önemi günümüzde gitgide artmaktadır. Ulaşımdaki yoğunlukların azalması, insan kaynaklı kazaların ortadan kalkması için otonom araçların gelecekte önemli rol oynayacağı ön görülmektedir. Ulaşım dışında tarım, sağlık, eğitim gibi alanlarda otonom araçlar giderek yaygınlaşmaktadır. Otonom araçlar, canlılardan ilham alınarak ; çevreyi algılamak için algılama , kendi konumunu belirlemek için konumlama, nereye nasıl gidebilmek için planlama ,hareketi için kontrol ve çevresindeki objelerin olası hareket güzergahları için davranışsal tahminleme gibi modüllerden oluşmaktadır. Bununla birlikte ROS(Robotic Operating System), ZMQ, ROS2 gibi ara katman yazılımları mevcuttur. Bu ara katman yazılımları modüllerin birbirleri arasında haberleşmesini, istenilen mesajı ilgili modüle iletilmesini sağlar. Çalışmada kullandığımız ROS ara katman yazılımı araçları verilerin

görselleştirilmesi, kaydedilmesi, gözlemlenmesi gibi faydaları da sağlamaktadır.

Otonom araçlarda planlama modülünün başarılı bir şekilde sonuç vermesi için en önemli faktörlerden biri davranışsal tahmin modülüdür. Davranışsal tahmin modülü otonom aracın çevresindeki objelerin geçmiş pozisyonlarını hafızasında tutarak gelecekteki pozisyonlarını tahmin eden çıktı üretir. Bu çıktı algılama modülünün bulunduğu objeler ile birleşerek planlama modülüne girdi oluşturur. Günlük hayatta çokça yaşanan senaryolardan örnek vermek gerekirse, karşıdan karşıya geçmeye hazırlanan bir yayayı, otonom aracın göz önünde bulundurabilmesi için otonom aracın yayanın olası güzergahını bilmesi gerekmektedir. Benzer şekilde otonom araç şerit değiştirirken arkadan aracın hızına göre olası güzergahı hesaplaması gereken aksi taktirde büyük ihtimalle kaza olacaktır.

Geliştirilen davranışsal tahmin modülü ROS tabanlı olup gerçek zamanlı çalışmaktadır.Çok modlu koşullu varyasyonel otomatik kodlayıcı

(Multimodal Conditional Variational Auto Encoder) tabanlı modele[1] ROS ara katmanı, dinamik geçmiş bilgisi tutup bırakma yapısı, yön hatası düzeltme, kovaryans dağılımı görselleştirme, planlama modülüne entegrasyonu ve uygun mesaj tipi uyumlandırılması gibi özellikler eklenmiştir. Bu sayede çevresindeki araçların olası güzergahlarını planlama modülüne gönderecek uçtan-uca bir otonomi modülü yapısı oluşturulmuştur.

Çalışmanın bundan sonraki bölümünde öncelikle davranışsal tahmin yaklaşımları ve literatürdeki çalışmalar özetlenecek, daha sonra çalışmada kullanılan metodolojideye dair bilgi verilip, geliştirilen modül detaylıca aktarılacaktır. Sonrasında ise test verileri ile elde edilen sonuçlar paylaşılacaktır. Son olarak ise çalışmanın sonucu ifade edilecek ve gelecek çalışmalara dair öneriler paylaşılacaktır.

## 2. MATERYAL VE YÖNTEM

### A. BENZER YÖNTEMLER

Otonom araçların; algılama , konumlama, planlama gibi alanlarına nazaran davranışsal tahmin

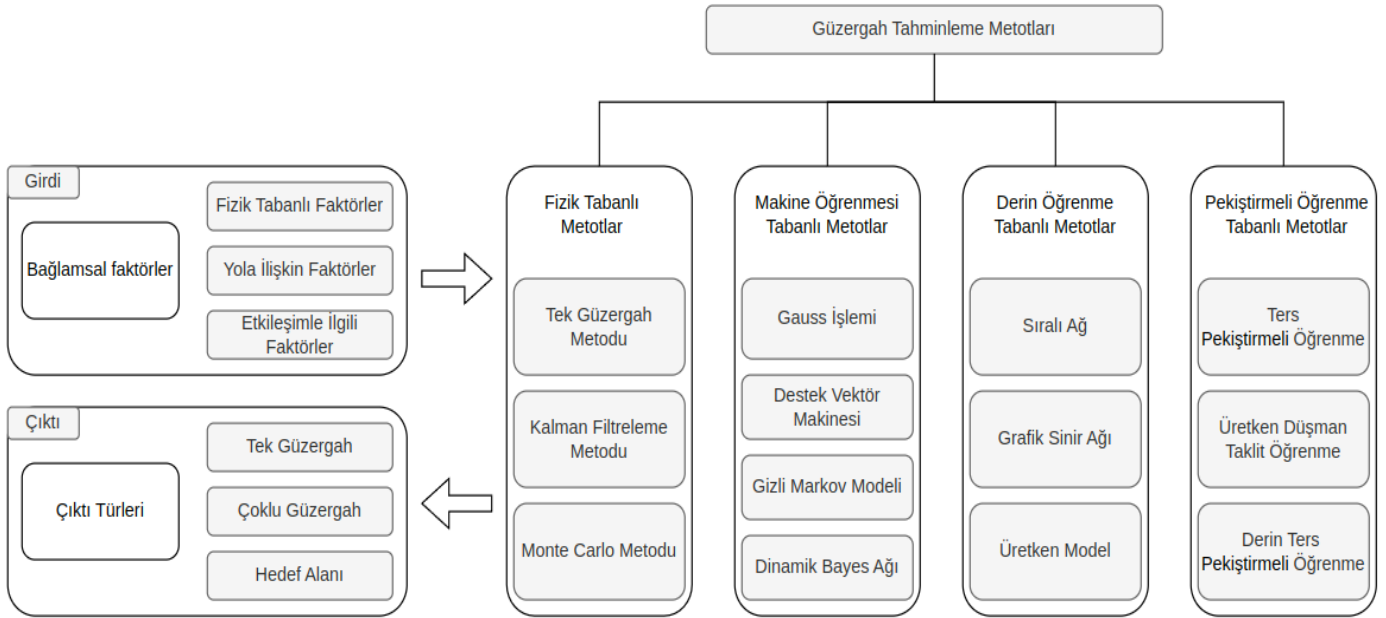
Güzergah Tahminleme yaklaşımları incelendiğinde gösterim, çıktı tipi, modelleme, durumsal farkındalık gibi yaklaşımlar mevcut olsa da bu makalede çalışmalarını kategorize etmede ana yaklaşım olarak modelleme farkları kullanılacaktır. Bununla birlikte çalışmalar gösterim türleri, çıktı tipleri ve durumsal farkındalık yönünden de bilgilendirmeler yapılacaktır.

Yapılan çalışmalar modelleme metotları yönünden incelendiğinde; Şekil.1'de gösterildiği üzere davranışsal tahmin metotları ; fizik tabanlı, makine öğrenmesi tabanlı, derin öğrenme tabanlı ve pekiştirmeli öğrenme tabanlı metotlardan oluşmaktadır.

### A.1-)FİZİK TABANLI METOTLAR

Fizik tabanlı metotlar aracın dinamik ve kinematiklerinden bilgiler alır. Tek güzergah, Kalman filtreleme, Monte Carlo metotlarından oluşur.

[4]-[15] çalışmaları tek güzergah(single trajectory), [16]-[25] çalışmaları Kalman filtreleme(Kalman filtering), [26]-[29] çalışmaları ise Monte Carlo metodunu kullanmışlardır. Bu çalışmalarda genel olarak hız ve ivme gibi fizik



Şekil 1.: Güzergah Tahmin Metotları

alanında daha az araştırma mevcuttur. Bunun en büyük nedeni çevresel faktörlerin gelecek zamandaki yerlerinin tespiti diğer alanlardaki problemlere göre daha zor olmasıdır.

tabanlı faktörler girdi olarak kullanılırken,[10],[18] ve [20]'de yola ilişkin faktörler de girdi olarak kullanılmıştır. Çıktı olarak genellikle tek güzergah çıktı verilirken [30]-[32], [33] [26], [27]-[29],

çoklu güzergah, [33] and [28] ise hedef alanı şeklinde çıktı vermektedir.

#### A.2-)MAKİNE ÖĞRENMESİ TABANLI METOTLAR

Fizik tabanlı metotların aksine makine öğrenmesi metotları data mining yaparak predicted trajectory elde edilmesi prensibine dayanır. En çok kullanılan başlıca makine öğrenmesi metotları Gauss işlemi(gaussian process), destek vektör makinesi (support vector machine),gizli Markov modeli (Hidden Markov model),dinamik bayes ağı (Dynamic bayesian network),K-Yakın Komşuluğu (K-nearest neighbors),karar ağacı(decision tree) metotlarıdır. Makine öğrenmesi tabanlı metotlar ile yapılmış çalışmalar incelendiğinde, [27],[28],[30]-[35] çalışmaları Gauss işlemi, [29],[36],[37],[38],[39] çalışmaları destek vektör makinesi, [32],[40]-[47] çalışmaları gizli Markov modeli,[48]-[55] çalışmaları dinamik bayes ağı metotlarını kullanmıştır. Bu metottaki çalışmaların çıktıları çoğunlukla çoklu güzergah olmakla birlikte modelin harita , sahne , etkileşim gibi durumsal farkındalık durumları arttıkça başarıyı da arttırdığı gözlemlenmiştir.

#### A.3-)DERİN ÖĞRENME TABANLI METOTLAR

Derin öğrenme tabanlı metotlar geçmiş güzergahın çeşitli özellik çıkarımı ve regresyon işlemleri yapılarak elde edilen modelin sonucunda güzergah elde edilmesi prensibine dayanır. Güzergah tahminleme alanındaki çalışmaların çoğu derin öğrenme tabanlı yaklaşımlardan oluşmaktadır. Derin öğrenme tabanlı yüzden fazla çalışma mevcuttur. Bu çalışmada yalnızca anaakım çalışmalar ele alınmıştır.

Derin öğrenme tabanlı metotlar; sıralı ağ (sequential network), grafik sinir ağı (graph neural network) ve üretken model (generative model) metotlarından oluşmaktadır. Sıralı ağ metotları; tekrarlayan sinir ağı(Recurrent neural network), evrişimli sinir ağı (Convolutional neural network), tekrarlayan ve evrişimli sinir ağı (RNN and CNN) ve dikkat mekanizması (Attention mechanism), üretken model metotları ise üretken düşmanlık ağı (Generative adversarial network) ve koşullu varyasyonel otomatik kodlayıcı metotlarından oluşmaktadır.

Derin öğrenme tabanlı çalışmaların başlıcaları incelendiğinde; [56] tekrarlayan sinir ağı, [57]-[59] evrişimli sinir ağı , [60],[61] tekrarlayan ve evrişimli sinir ağı, [62],[63] dikkat mekanizması,

sıralı ağ metotlarını , [64] , [65] grafik sinir ağı metodunu; [66],[67] üretken model metotlarını kullanmışlardır.

Derin öğrenme tabanlı çalışmalara fizik ve makine öğrenmesi tabanlı çalışmalara kıyasla daha kapsamlı çıktı ve girdi verilebilmektedir. Bu çalışmalar çoğunlukla nesnelerin etkileşimleri girdiler almakta olup çoklu güzergah ya da hedef alanı tipi çıktılar sağlamaktadırlar.

#### A.4-)PEKİŞTİRMELİ ÖĞRENME TABANLI METOTLAR

Son yıllarca çalışmaların oldukça arttığı pekiştirmeli öğrenme yaklaşımı güzergah tahminleme alanında da karşımıza çıkmaktadır. Pekiştirmeli öğrenme metodu karar-ödül prensibine dayanır, ödülü maksimize edecek kararı bulmaya yoğunlaşır.

Pekiştirmeli öğrenme metodu; Ters pekiştirmeli öğrenme (Inverse reinforcement learning), üretken taklit düşman öğrenme (generative adversarial imitation learning) ve derin ters pekiştirmeli öğrenme (deep inverse reinforcement learning) metotlarından oluşmaktadır. [68]-[74] çalışmaları ters pekiştirmeli öğrenme ,[75]:[78] çalışmaları üretken taklit düşman öğrenme ,[79]-[84] çalışmaları derin ters pekiştirmeli öğrenme metotlarını kullanmışlardır.

Pekiştirmeli öğrenme metotları da derin öğrenme metotlarına benzer şekilde yol ve sahneye ilişkin faktörler gibi kapsamlı girdiler alıp yine çoklu güzergah ve hedef alanı şeklinde kapsamlı çıktılar sağlayabilmektedirler.

#### VERİSETLERİ

Yukarıda belirtilen metotların ya da modellerin eğitilmesi ya da test edilmeleri için verisetleri gereklidir. Bu verisetleri çeşitli sensör verileri, harita verileri bunların ilişki tanımlarından oluşmaktadır. Bunlardan başlıcaları , KITTI, NuScenes, Argoverse ve NGSIM verisetleridir. İlerleyen kısımlarda çeşitli çalışmaların bu veri setleri üzerindeki karşılaştırmaları verilecektir.

Tablo 1: NGSIM otoyol sürüş verisetinde eğitilmiş güzergah tahminleme modellerinin karşılaştırılması

<u>Sınıflandırma Metotları</u>	<u>Modeller</u>	<u>Kök Ortalama Kare Hatası(m)</u>				
		<u>1s</u>	<u>2s</u>	<u>3s</u>	<u>4s</u>	<u>5s</u>
<u>Tek Güzergah</u>	Constant Velocity[61]	0.73	1.78	3.13	4.78	6.68
<u>Kalman Filtreleme</u>	IMM-KF[25]	0.58	1.36	2.28	3.37	4.55
<u>Gizli Markov Modeli</u>	C-VGMM+VIM[45]	0.66	1.56	2.75	4.24	5.99
<u>Tekrarlayan Sinir Ağı</u>	M-LSTM[85]	0.58	1.26	2.12	3.24	4.66
<u>Tekrarlayan Sinir Ağı</u>	MFP-1[56]	0.54	1.16	1.90	2.78	3.83
<u>Evrişimli Sinir Ağı ve Tekrarlayan Sinir Ağı</u>	CS-LSTM(M)[61]	0.62	1.29	2.13	3.20	4.52
<u>Dikkat Mekanizması</u>	MHA-LSTM[86]	0.41	1.01	1.74	2.67	3.83
<u>Grafik Sinir Ağı</u>	GRIP++[87]	0.38	0.89	1.45	<b>2.14</b>	<b>2.94</b>
<u>Grafik Sinir Ağı</u>	GISNet[88]	<b>0.33</b>	<b>0.83</b>	<b>1.42</b>	2.14	3.23
<u>Üretken Model</u>	MATF-GAN[89]	0.66	1.34	2.08	2.97	4.13
<u>Üretken Model</u>	TS-GAN[66]	0.60	1.24	1.95	2.78	3.72
<u>Ters Takviyeli Öğrenme</u>	L-IRL[90]	1.12	2.29	2.31	3.38	4.45
<u>Üretken Düşman Taklit Öğrenme</u>	GAIL-GRU[75]	0.69	1.51	2.55	3.65	4.71
<u>Derin Ters Takviyeli Öğrenme</u>	MEDIRL[81]	1.35	2.57	2.83	3.69	4.88
<u>Derin Ters Takviyeli Öğrenme</u>	DN-IRL[91]	0.54	1.02	1.91	2.43	3.76

Tablo 2: Argovese şehir içi verisetinde eğitilmiş güzergah tahminleme modellerinin karşılaştırılması

<u>Sınıflandırma Metotları</u>	<u>Modeller</u>	<u>K<sup>1</sup>=6</u>			<u>K<sup>1</sup>=1</u>		
		<u>minNYDH</u>	<u>minOYDH</u>	<u>FO</u>	<u>minNYDH</u>	<u>minOYDH</u>	<u>FO</u>
<u>Fizik Tabanlı</u>	CV[92]	7.57	3.39	0.82	7.89	3.53	0.84
<u>Makine Öğrenmesi Tabanlı</u>	NN+map[92]	4.03	2.08	0.58	8.12	3.65	0.84
<u>Tekrarlayan Sinir Ağı</u>	LSTM+map[92]	5.44	2.34	0.69	6.81	2.96	0.81
<u>Tekrarlayan Sinir Ağı</u>	Jean[93]	1.49	0.93	0.19	4.18	1.86	0.63
<u>Dikkat Mekanizması</u>	SceneTransformer[94]	<b>1.23</b>	<b>0.80</b>	0.13	-	-	-
<u>Dikkat Mekanizması</u>	mmTransformer[63]	1.34	0.84	0.15	-	-	-
<u>Grafik Sinir Ağı</u>	LaneGCN[95]	1.36	0.87	0.16	3.78	1.71	0.59
<u>Grafik Sinir Ağı</u>	DenseTNT[65]	1.45	0.93	<b>0.11</b>	-	-	-
<u>Grafik Sinir Ağı</u>	LaneRCNN[96]	1.45	0.90	0.12	<b>3.69</b>	<b>1.69</b>	<b>0.57</b>
<u>Üretken Model</u>	PRIME[67]	1.56	1.22	0.12	3.82	1.91	0.59

<sup>1</sup> güzergah çıktısı sayısı

## DEĞERLEDİRME METRİKLERİ

Çalışmaların başarısının ölçülebilmesi için güvenilir ve kapsamlı metriklere ihtiyaç vardır. Benzer çalışmaları karşılaştırmada kullanılacak bazı metrik şunlardır:

**Kök Ortalama Kare Hatası (Root Mean Squared Error):** Bu metrik, tahmin hatasının karesinin ortalamasının kareköküdür.

**Ortalama Yer Değiştirme Hatası (Average Displacement Error):** Tahmin edilen güzergah ile gerçek güzergah arasındaki ortalama mesafedir.

**Nihai Yer Değiştirme Hatası (Final displacement error):** Tahmin edilen nihai nokta ile gerçek nokta arasındaki mesafedir.

**Fark Oranı (Miss Rate) :** Tahmin edilen konumun gerçek konum karşılığı farklarının iki metreyi geçtiği yerlerin, iki metreyi geçmediği yerlere oranıdır.

Tablo 1 ve 2'ye bakıldığında fizik tabanlı ve makine öğrenme tabanlı metotlar düşük hesaplama yükü gerektirse de tahmin edilen zaman arttıkça ( $2sn >$ ) başarımları oldukça düşmektedir. Bu iki metoda kıyasla derin öğrenme ve pekiştirmeli öğrenme tabanlı öğrenme metotlar daha çok işlem yükü getirmelerine rağmen daha uzun zamanı

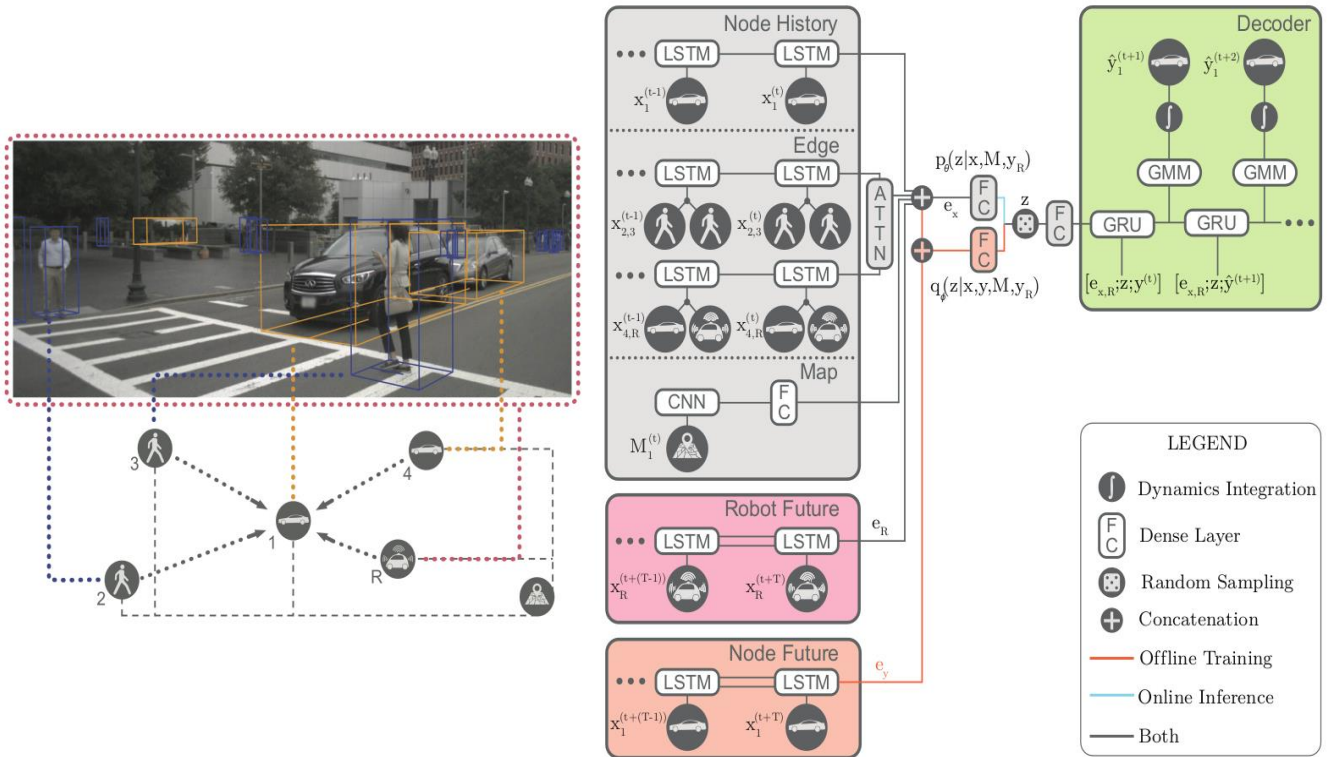
Derin öğrenme ve pekiştirmeli öğrenme tabanlı metotlar karşılaştırıldığında derin öğrenme tabanlı metotların daha başarılı olduğu görülmektedir.

Açık kaynaklı, ROS altyapılı, uçtan uca, konfigüre edilebilir, hataya dayanıklı, çoklu nesne tipi tahmini yapabilen bir davranışsal tahminleme modülü bulunamamıştır. Bulunabilen en benzer çalışma[90] ROS ile yalnızca yayaların güzergahlarını eden bir çalışmadır.

## B. YÖNTEM

Bu makalede, çoklu sınıflandırma yapısında olması, yeni ve araç güzergah tahmini için kapsamlı veri setinde eğitilmesi (nuScenes), açık kaynaklı olması, literatür taraması kısmında da belirtildiği üzere grafik yapılı evrişimli modellerin daha başarılı olduğunu gösteren birçok çalışmanın olması, hem çoklu güzergah hem hedef alanı çıktı vermesi, sahne ve harita farkındalıklı bir model olması sebeplerinden ötürü bu makale Trajectron++ modeli ele alınmıştır. Trajectron++ Şekil 2'de gösterildiği gibi harita etkileşim farkındalıklı bir yapıdadır.

Bu model üzerinde yapılan çalışmalar;



Şekil 2: Trajectron++ Model Mimarisi[1] başarılı bir şekilde tahmin edebilmektedirler.

```

trajectron > conf > ⚙️ waypointprediction.conf
 1  <?xml version="1.0" ?>
 2  <AdapterConfig>
 3    <Adapter>
 4      <Parameter name="SensorFusion" />
 5      <Parameter mode="SUBSCRIBER" />
 6      <Parameter message_history="10" />
 7      <Parameter topic="/sensor_fusion" />
 8    </Adapter>
 9    <Adapter>
10      <Parameter name="PredictedDetectedObjectArray" />
11      <Parameter mode="PUBLISHER" />
12      <Parameter message_history="10" />
13      <Parameter topic="/predicted_trajectories" />
14    </Adapter>
15    <Adapter>
16      <Parameter name="TrajectoryVisual" />
17      <Parameter mode="PUBLISHER" />
18      <Parameter message_history="10" />
19      <Parameter topic="/predicted_markers" />
20    </Adapter>
21    <Adapter>
22      <Parameter name="PointCloud2" />
23      <Parameter mode="PUBLISHER" />
24      <Parameter message_history="1" />
25      <Parameter topic="/predicted_pc" />
26    </Adapter>
27  </AdapterConfig>

```

Şekil 3: Rostopic Konfigürasyon Dosyası

- ROS arakatmanı eklenmiştir, ROS algılama modülünden gelen veri, modeldeki girdi verisi formatına uygun hale getirilmiştir. Bununla birlikte dinamik geçmiş tut/bırak yapısı oluşturulmuş bu sayede takip edilen objelerin geçmişleri biriktirilmiş, takip edilmeyen objenin modele girmesi engellenmiştir.

- Yazılan geçmiş kayıt fonksiyonu ile takip edilen objelerin yön, pozisyon ve sınıflandırma bilgileri uzaklık ve hız filtrelerin geçirilerek ilgili python sözlük yapısında geçmiş bilgisinin biriktirilmesi sağlanmıştır. Yine yazılan geçmiş güncelleme fonksiyonu ile takip edilmeyen objenin sözlükten silinmesi ve modele yalnızca araç ve yaya tipinde girdi girmesi sağlanmıştır.

- Geçmiş kayıt fonksiyonunda modele girdi olarak giren yön verisi hem segmentasyon çıktısından gelen doğrultu bilgisinden hem de araç pozisyonundan bulunan doğrultu bilgisinden alınması sağlanmıştır. Segmentasyon çıktısı aracın doğrultusunu doğru vermekle birlikte yönünü çoğu zaman 180 derece

ters vermektedir. Pozisyon bilgisinden yön bulunurken ise özellikle dönel yollarda yön değeri hatalı çıkmaktadır. Pozisyon bilgisinden alınan yön değeri ile segmentasyondan gelen değer 90 dereceden fazla ise segmentasyondan gelen doğrultu bilgisi 180 derece çevrilerek hataya dayanıklı bir yön bilgisi elde etme yapısı oluşturulmuştur. Bununla birlikte takip edilen objeler için hız ve ilgi çapı filtresi oluşturulmuş ve araçtan uzakta ya da algılama sisteminden gelen çok düşük hızlardaki objelerin modele girmemesi bu sayede algoritmanın daha verimli çalışması sağlanmıştır. Modelden çıkan güzergah tahmini bilgisi ise planlama modülüne uygun mesaj tipine dönüştürülmüş ve görselleştirilmiştir. Rostopic ve ROS mesaj tiplerinin kolayca anlaşılması ve konfigüre edilebilmesi amacıyla Fig 3'deki gibi konfigürasyon dosyası oluşturulmuştur.

#### 4. TARTIŞMA

Bu çalışmanın sonucunda elde edilecek davranışsal tahminleme modülü ile otonom aracın hareketli nesnelere bulunduğu ortamda hata yapma ihtimali önemli oranda azalmıştır. Hali hazırdaki modele gerçek zamanlı işlem eklentisi yazılması, ROS altyapısına geçirilmesi, hatalı verilerin düzeltilmesi ya da filtrenmesi gibi katkılarla algılama modülünden planlama modülüne uçtan uca, gerçek zamanlı ve hataya dayanıklı bir yapı kurulmuştur. Geliştirilen uygulama şehir içi otonom araçlar dışında sağlık hizmetleri, tarımsal alanlar yada otobüs/uçak terminalleri gibi birçok uygulama alanında kullanılabilir. Gelecek çalışmalarda kullanılan modele evrişimli uzun kısa süreli bellek (Convolutional LSTM) eklenmesi ve bu modelin TensorRT kullanılarak hızlandırılması planlanmıştır.

#### 5. SONUÇLAR

Davranışsal tahminleme alanında benzer metotlar kısmından da görüleceği üzere birçok model çalışması mevcuttur ve hali hazırda birçok çalışma yapılmaktadır. Bu çalışmalardan bir çoğu eğitildikleri verisetlerinde başarılı sonuçlar verseler de şehir içi gibi yoğun ortamlarda çalışma hızları ve başarımları düşmektedir. Daha karmaşık verisetleri oluşturularak ve iyi model yapıları geliştirilerek daha başarılı sonuçlar alınabilir.

Bu çalışmada model olarak Trajectron++ kullanılsa da uçtan-uca, gerçek zamanlı, ROS tabanlı, çoklu sınıflandırma yapabilen bir uygulama bulunmamaktadır. Çalışma bu bakımdan yenilikçidir. Uygulama eklenen veriyi filtreleme, düzeltme, geçmişli tut/bırak yapısı ile daha verimli hale getirilmiştir.

#### KAYNAKLAR

- [1] T. Salzmann, B. Ivanovic, P. Chakravarty, and M. Pavone, "Trajectron++: Dynamically-feasible trajectory forecasting with heterogeneous data," in European Conference on Computer Vision. Springer, 2020, pp. 683–700. [https://doi.org/10.1007/978-3-030-58523-5\\_40](https://doi.org/10.1007/978-3-030-58523-5_40).
- [2] Y. Huang, J. Du, Z. Yang, Z. Zhou, L. Zhang, and H. Chen, "A survey on trajectory-prediction methods for autonomous driving," IEEE Transactions on Intelligent Vehicles, 2022.
- [3] M. Gulzar, Y. Muhammad, and N. Muhammad, "A survey on motion prediction of pedestrians and vehicles for autonomous driving," IEEE Access, 2021.
- [4] C. F. Lin and A. G. Ulsoy, "Vehicle dynamics and external disturbance estimation for vehicle path

- prediction," IEEE Transactions on Control Systems Technology, vol. 8, no. 3, pp. 508–518, 2000.
- [5] R. Pepy, A. Lambert, and H. Mounier, "Reducing navigation errors by planning with realistic vehicle model," in Intelligent Vehicles Symposium, 2006.
- [6] N. Kaempchen, B. Schiele, and K. Dietmayer, "Situation assessment of an autonomous emergency brake for arbitrary vehicle-to-vehicle collision scenarios," IEEE Transactions on Intelligent Transportation Systems, vol. 10, no. 4, pp. 678–687, 2009.
- [7] P. Lytrivis, G. Thomaidis, and A. Amditis, "Cooperative path prediction in vehicular environments," in Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on, 2008.
- [8] C. Schöller, V. Aravantinos, F. Lay, and A. Knoll, "What the constant velocity model can teach us about pedestrian motion prediction," IEEE Robot. Autom. Lett., vol. 5, no. 2, pp. 1696–1703, Apr. 2020.
- [9] I. Batkovic, M. Zanon, N. Lubbe, and P. Falcone, "A computationally efficient model for pedestrian motion prediction," in Proc. Eur. Control Conf. (ECC), Jun. 2018, pp. 374–379.
- [10] E. Coelingh, A. Eidehall, and M. Bengtsson, "Collision warning with full auto brake and pedestrian detection—A practical example of automatic emergency braking," in Proc. 13th Int. IEEE Conf. Intell. Transp. Syst., Sep. 2010, pp. 155–160.
- [11] N. Kaempchen, K. Weiss, M. Schaefer, and K. C. J. Dietmayer, "IMM object tracking for high dynamic driving maneuvers," in Proc. IEEE Intell. Vehicles Symp., Jun. 2004, pp. 825–830.
- [12] P. Lytrivis, G. Thomaidis, and A. Amditis, "Cooperative path prediction in vehicular environments," in Proc. 11th Int. IEEE Conf. Intell. Transp. Syst., Oct. 2008, pp. 803–808.
- [13] M. Brannstrom, E. Coelingh, and J. Sjöberg, "Model-based threat assessment for avoiding arbitrary vehicle collisions," IEEE Transactions on Intelligent Transportation Systems, vol. 11, no. 3, pp. 658–669, 2010.
- [14] R. Miller and Q. Huang, "An adaptive peer-to-peer collision warning system," in IEEE Vehicular Technology Conference, 2002.
- [15] J. Hillenbrand, A. M. Spieker, and K. Kroschel, "A multilevel collision mitigation approach—its situation assessment, decision making, and performance tradeoffs," IEEE Transactions on Intelligent Transportation Systems, vol. 7, pp. 528–540, 2006.
- [16] S. Ammoun and F. Nashashibi, "Real time trajectory prediction for collision risk estimation between vehicles," in Intelligent Computer Communication and Processing, 2009. ICCP 2009. IEEE 5th International Conference on, 2009.
- [17] T. Bätz, K. Watson, and J. Beyerer, "Recognition of dangerous situations within a cooperative group of vehicles," in Intelligent Vehicles Symposium, 2009.
- [18] A. Møgelmoose, M. M. Trivedi, and T. B. Moeslund, "Trajectory analysis and prediction for improved pedestrian safety: Integrated framework and evaluations," in Proc. IEEE Intell. Vehicles Symp. (IV), Jun. 2015, pp. 330–335.

- [19] A. Elnagar, "Prediction of moving objects in dynamic environments using Kalman filters," in Proc. IEEE Int. Symp. Comput. Intell. Robot. Autom., Jul./Aug. 2001, pp. 414–419.
- [20] G. Xie, H. Gao, L. Qian, B. Huang, K. Li, and J. Wang, "Vehicle trajectory prediction by integrating physics- and maneuver-based approaches using interactive multiple models," IEEE Trans. Ind. Electron., vol. 65, no. 7, pp. 5999–6008, Jul. 2018.
- [21] N. Kaempchen, K. Weiss, M. Schaefer, and K. C. J. Dietmayer, "Imm object tracking for high dynamic driving maneuvers," in Intelligent Vehicles Symposium, 2004.
- [22] B. Jin, J. Bo, S. Tao, H. Liu, and G. Liu, "Switched kalman filter-interacting multiple model algorithm based on optimal autoregressive model for manoeuvring target tracking," Iet Radar Sonar & Navigation, vol. 9, no. 2, pp. 199–209, 2015.
- [23] H. Dyckmanns, R. Matthaei, M. Maurer, B. Lichte, and D. Stuker, "Object tracking in urban intersections based on active use of a priori knowledge: Active interacting multi model filter," in Intelligent Vehicles Symposium, 2011.
- [24] Zhang, Ruifeng, Cao, Libo, Tan, Jianjie, Bao, and Shan, "A method for connected vehicle trajectory prediction and collision warning algorithm based on v2v communication," International journal of crashworthiness, 2017.
- [25] V. Lefkopoulos, M. Menner, A. Domahidi, and M. N. Zeilinger, "Interaction-aware motion prediction for autonomous driving: A multiple model kalman filtering scheme," IEEE Robotics and Automation Letters, vol. 6, no. 1, pp. 80–87, 2021.
- [26] M. Althoff and A. Mergel, "Comparison of markov chain abstraction and monte carlo simulation for the safety assessment of autonomous cars," IEEE Transactions on Intelligent Transportation Systems, vol. 12, no. 4, pp. 1237–1247, 2011.
- [27] D. A. V. Govea and T. Fraichard, "Motion prediction for moving objects: a statistical approach," in IEEE International Conference on Robotics & Automation, 2004.
- [28] C. Hermes, C. Wohler, K. Schenk, and F. Kummert, "Long-term vehicle motion prediction," in Intelligent Vehicles Symposium, 2010.
- [29] H. Mandalia and D. Salvucci, "Using support vector machines for lane-change detection," Proceedings of the Human Factors and Ergonomics Society Annual Meeting, vol. 49, 09 2005.
- [30] J. Joseph, F. Doshi-Velez, A. S. Huang, and N. Roy, "A bayesian nonparametric approach to modeling motion patterns," Autonomous Robots, vol. 31, no. 4, pp. 383–400, 2011.
- [31] Q. Tran and J. Firl, "Online maneuver recognition and multimodal trajectory prediction for intersection assistance using non-parametric regression," in 2014 IEEE intelligent vehicles symposium proceedings. IEEE, 2014, pp. 918–923.
- [32] C. Laugier, I. E. Paromtchik, M. Perrollaz, M. Yong, J.-D. Yoder, C. Tay, K. Mekhnacha, and A. Nègre, "Probabilistic analysis of dynamic scenes and collision risks assessment to improve driving safety," IEEE Intelligent Transportation Systems Magazine, vol. 3, no. 4, pp. 4–19, 2011.
- [33] Y. Guo, V. V. Kalidindi, M. Arief, W. Wang, J. Zhu, H. Peng, and D. Zhao, "Modeling multi-vehicle interaction scenarios using gaussian random field," in 2019 IEEE Intelligent Transportation Systems Conference (ITSC), 2019, pp. 3974–3980.
- [34] J. Joseph, F. Doshi velez, and N. Roy, "A bayesian nonparametric approach to modeling mobility patterns." 01 2010.
- [35] P. Trautman and A. Krause, "Unfreezing the robot: Navigation in dense, interacting crowds," in 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2010, pp. 797–803.
- [36] P. Kumar, M. Perrollaz, S. Lefevre, and C. Laugier, "Learning-based approach for online lane change intention prediction," in IEEE Intelligent Vehicles Symposium, 2013.
- [37] G. Aoude and J. How, "Using support vector machines and bayesian filtering for classifying agent intentions at road intersections," 09 2009.
- [38] Z. Fang and A. M. López, "Is the pedestrian going to cross? Answering by 2D pose estimation," in Proc. IEEE Intell. Vehicles Symp. (IV), Jun. 2018, pp. 1271–1276.
- [39] G. S. Aoude, B. D. Luders, K. K. H. Lee, D. S. Levine, and J. P. How, "Threat assessment design for driver assistance system at intersections," in 13th International IEEE Conference on Intelligent Transportation Systems, 2010, pp. 1855–1862.
- [40] S. Gams, M.-O. Killijian, and M. Nunez del Prado Cortez, "Next place prediction using mobility markov chains," 04 2012.
- [41] Q. Deng and D. Söfker, "Improved driving behaviors prediction based on fuzzy logic-hidden markov model (fl-hmm)," in 2018 IEEE Intelligent Vehicles Symposium (IV), 2018, pp. 2003–2008.
- [42] H. Berndt, J. Emmert, and K. Dietmayer, "Continuous driver intention recognition with hidden markov models," in International IEEE Conference on Intelligent Transportation Systems, 2008.
- [43] S. Qiao, D. Shen, X. Wang, N. Han, and W. Zhu, "A self-adaptive parameter selection trajectory prediction approach via hidden markov models," IEEE Transactions on Intelligent Transportation Systems, vol. 16, no. 1, pp. 284–296, 2015.
- [44] Y. Wang, C. Wang, W. Zhao, and C. Xu, "Decision-making and planning method for autonomous vehicles based on motivation and risk assessment," IEEE Transactions on Vehicular Technology, vol. 70, no. 1, pp. 107–120, 2021.
- [45] N. Deo, A. Rangesh, and M. M. Trivedi, "How would surround vehicles move? a unified framework for maneuver classification and motion prediction," IEEE Transactions on Intelligent Vehicles, pp. 129–140, 2018.
- [46] S. Zhang, Y. Zhi, R. He, and J. Li, "Research on traffic vehicle behavior prediction method based on game theory and hmm," IEEE Access, vol. 8, pp. 30 210–30 222, 2020.
- [47] J. Martinsson, N. Mohammadiha, and A. Schliep, "Clustering vehicle maneuver trajectories using



- mixtures of hidden Markov models,” in Proc. 21st Int. Conf. Intell. Transp. Syst. (ITSC), Nov. 2018, pp. 3698–3705.
- [48] T. Gindele, S. Brechtel, and R. Dillmann, “Learning driver behavior models from traffic observations for decision making and planning,” *Intelligent Transportation Systems Magazine, IEEE*, vol. 7, no. 1, pp. 69–79, 2015
- [49] M. Schreier, V. Willert, and J. Adamy, “An integrated approach to maneuver-based trajectory prediction and criticality assessment in arbitrary road environments,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 10, pp. 2751–2766, 2016
- [50] M. Bahram, A. Lawitzky, J. Friedrichs, M. Aeberhard, and D. Wollherr, “A game-theoretic approach to replanning-aware interactive scene prediction and planning,” *IEEE Transactions on Vehicular Technology*, vol. 65, no. 6, pp. 3981–3992, 2015
- [51] G. He, X. Li, Y. Lv, B. Gao, and H. Chen, “Probabilistic intention prediction and trajectory generation based on dynamic bayesian networks,” in 2019 Chinese Automation Congress (CAC), 2019
- [52] J. Li, B. Dai, X. Li, X. Xu, and D. Liu, “A dynamic bayesian network for vehicle maneuver prediction in highway driving scenarios: Framework and verification,” *Electronics*, vol. 8, no. 1, pp. 40–, 2019
- [53] Y. Li, X. Y. Lu, J. Wang, and K. Li, “Pedestrian trajectory prediction combining probabilistic reasoning and sequence learning,” *IEEE Transactions on Intelligent Vehicles*, vol. 5, no. 3, pp. 461–474, 2020
- [54] L. Ballan, F. Castaldo, A. Alahi, F. Palmieri, and S. Savarese, “Knowledge transfer for scene-specific motion prediction,” in Proc. Eur. Conf. Comput. Vis. Cham, Switzerland: Springer, 2016, pp. 697–713.
- [55] T. Gindele, S. Brechtel, and R. Dillmann, “A probabilistic model for estimating driver behaviors and vehicle trajectories in traffic environments,” in Proc. 13th Int. IEEE Conf. Intell. Transp. Syst., Sep. 2010, pp. 1625–1631
- [56] C. Tang and R. R. Salakhutdinov, “Multiple futures prediction,” *Advances in Neural Information Processing Systems*, vol. 32, pp. 15 424–15 434, 2019
- [57] T. Phan-Minh, E. C. Grigore, F. A. Boulton, O. Beijbom, and E. M. Wolff, “Covernet: Multimodal behavior prediction using trajectory sets,” in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020, pp. 14 074–14 083
- [58] T. Gilles, S. Sabatini, D. Tsishkou, B. Stanciulescu, and F. Moutarde, “Home: Heatmap output for future motion estimation,” in 2021 IEEE International Intelligent Transportation Systems Conference (ITSC). IEEE, 2021, pp. 500–507
- [59] M. Ye, T. Cao, and Q. Chen, “Tpcn: Temporal point cloud networks for motion forecasting,” in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021, pp. 11 318–11 327
- [60] N. Lee, W. Choi, P. Vernaza, C. B. Choy, P. H. Torr, and M. Chandraker, “Desire: Distant future prediction in dynamic scenes with interacting agents,” in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017, pp. 336–345
- [61] N. Deo and M. M. Trivedi, “Convolutional social pooling for vehicle trajectory prediction,” in 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2018
- [62] K. Messaoud, N. Deo, M. M. Trivedi, and F. Nashashibi, “Trajectory prediction for autonomous driving based on multi-head attention with joint agent-map representation,” in 2021 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2021, pp. 165–170
- [63] Y. Liu, J. Zhang, L. Fang, Q. Jiang, and B. Zhou, “Multimodal motion prediction with stacked transformers,” in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021, pp. 7577–7586
- [64] J. Gao, C. Sun, H. Zhao, Y. Shen, D. Anguelov, C. Li, and C. Schmid, “Vectornet: Encoding hd maps and agent dynamics from vectorized representation,” in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020, pp. 11 525–11 533
- [65] J. Gu, C. Sun, and H. Zhao, “Densentn: End-to-end trajectory prediction from dense goal sets,” in Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021, pp. 15 303–15 312
- [66] Y. Wang, S. Zhao, R. Zhang, X. Cheng, and L. Yang, “Multi-vehicle collaborative learning for trajectory prediction with spatio-temporal tensor fusion,” *IEEE Transactions on Intelligent Transportation Systems*, vol. PP, no. 99, pp. 1–13, 2020
- [67] H. Song, D. Luan, W. Ding, M. Y. Wang, and Q. Chen, “Learning to predict vehicle trajectories with model-based planning,” arXiv preprint arXiv:2103.04027, 2021
- [68] E. Klein, M. Geist, B. Piot, and O. Pietquin, “Inverse reinforcement learning through structured classification,” in NIPS 2012, 2012, pp. 1–9
- [69] D. Silver, J. A. Bagnell, and A. Stentz, “Learning autonomous driving styles and maneuvers from expert demonstration,” in *Experimental Robotics*. Springer, 2013, pp. 371–386
- [70] B. D. Ziebart, A. L. Maas, J. A. Bagnell, A. K. Dey et al., “Maximum entropy inverse reinforcement learning.” in *Aaai*, vol. 8. Chicago, IL, USA, 2008, pp. 1433–1438
- [71] S. Sharifzadeh, I. Chiotellis, R. Triebel, and D. Cremers, “Learning to drive using inverse reinforcement learning and deep q-networks,” arXiv preprint arXiv:1612.03653, 2016
- [72] L. Sun, W. Zhan, and M. Tomizuka, “Probabilistic prediction of interactive driving behavior via hierarchical inverse reinforcement learning,” in 2018 21st International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2018, pp. 2111–2117
- [73] D. S. Gonzalez, O. Erkent, V. Romero-Cano, J. Dibangoye, and C. Laugier, “Modeling driver behavior from demonstrations in dynamic environments using spatiotemporal lattices,” in 2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018, pp. 3384–3390
- [74] D. Xu, Z. Ding, X. He, H. Zhao, M. Moze, F. Aioun, and F. Guillemard, “Learning from naturalistic driving data for human-like autonomous highway driving,” *IEEE Transactions on Intelligent Transportation Systems*, 2020

- [75] A. Kuefler, J. Morton, T. Wheeler, and M. Kochenderfer, "Imitating driver behavior with generative adversarial networks," in 2017 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2017, pp. 204–211
- [76] Y. Li, J. Song, and S. Ermon, "Infogail: Interpretable imitation learning from visual demonstrations," in Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017, pp. 3815–3825
- [77] R. Bhattacharyya, B. Wulfe, D. Phillips, A. Kuefler, J. Morton, R. Senanayake, and M. Kochenderfer, "Modeling human driving behaviour through generative adversarial imitation learning," arXiv preprint arXiv:2006.06412, 2020
- [78] S. Choi, J. Kim, and H. Yeo, "Trajgail: Generating urban vehicle trajectories using generative adversarial imitation learning," *Transportation Research Part C: Emerging Technologies*, vol. 128, p. 103091, 2021
- [79] T. Fernando, S. Denman, S. Sridharan, and C. Fookes, "Deep inverse reinforcement learning for behavior prediction in autonomous driving: Accurate forecasts of vehicle motion," *IEEE Signal Processing Magazine*, vol. 38, no. 1, pp. 87–96, 2020
- [80] C. You, J. Lu, D. Filev, and P. Tsiotras, "Advanced planning for autonomous vehicles using reinforcement learning and deep inverse reinforcement learning," *Robotics and Autonomous Systems*, vol. 114, pp. 1–18, 2019
- [81] M. Wulfmeier, D. Rao, D. Z. Wang, P. Ondruska, and I. Posner, "Large-scale cost function learning for path planning using deep inverse reinforcement learning," *The International Journal of Robotics Research*, vol. 36, no. 10, pp. 1073–1087, 2017
- [82] Q. Zou, H. Li, and R. Zhang, "Inverse reinforcement learning via neural network in driver behavior modeling," in 2018 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2018, pp. 1245–1250
- [83] Z. Zhu, N. Li, R. Sun, D. Xu, and H. Zhao, "Off-road autonomous vehicles traversability analysis and trajectory planning based on deep inverse reinforcement learning," in 2020 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2020, pp. 971–977
- [84] C. Jung and D. H. Shim, "Incorporating multi-context into the traversability map for urban autonomous driving using deep inverse reinforcement learning," *IEEE Robotics and Automation Letters*, vol. 6, no. 2, pp. 1662–1669, 2021
- [85] N. Deo and M. M. Trivedi, "Multi-modal trajectory prediction of surrounding vehicles with maneuver based lstms," in 2018 IEEE Intelligent Vehicles Symposium (IV), 2018, pp. 1179–1184.
- [86] K. Messaoud, I. Yahiaoui, A. Verroust-Blondet, and F. Nashashibi, "Attention based vehicle trajectory prediction," *IEEE Transactions on Intelligent Vehicles*, vol. 6, no. 1, pp. 175–185, 2020
- [87] "Grip++: Enhanced graph-based interaction-aware trajectory prediction for autonomous driving," arXiv preprint arXiv:1907.07792, 2019.
- [88] Z. Zhao, H. Fang, Z. Jin, and Q. Qiu, "Gisnet: Graph-based information sharing network for vehicle trajectory prediction," in 2020 International Joint Conference on Neural Networks (IJCNN). IEEE, 2020, pp. 1–7.
- [89] T. Zhao, Y. Xu, M. Monfort, W. Choi, C. Baker, Y. Zhao, Y. Wang, and Y. N. Wu, "Multi-agent tensor fusion for contextual trajectory prediction," in 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019.
- [90] K. Saleh, M. Hossny, and S. Nahavandi, "Long-term recurrent predictive model for intent prediction of pedestrians via inverse reinforcement learning," in 2018 Digital Image Computing: Techniques and Applications (DICTA). IEEE, 2018, pp. 1–8.
- [91] T. Fernando, S. Denman, S. Sridharan, and C. Fookes, "Neighbourhood context embeddings in deep inverse reinforcement learning for predicting pedestrian motion over long time horizons," in Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops, 2019, pp. 0–0.
- [92] M.-F. Chang, J. Lambert, P. Sangkloy, J. Singh, S. Bak, A. Hartnett, D. Wang, P. Carr, S. Lucey, D. Ramanan et al., "Argoverse: 3d tracking and forecasting with rich maps," in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019, pp. 8748–8757.
- [93] J. Mercat, T. Gilles, N. El Zoghby, G. Sandou, D. Beauvois, and G. P. Gil, "Multi-head attention for multi-modal joint vehicle motion forecasting," in 2020 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2020, pp. 9638–9644.
- [94] J. Ngiam, B. Caine, V. Vasudevan, Z. Zhang, H.-T. L. Chiang, J. Ling, R. Roelofs, A. Bewley, C. Liu, A. Venugopal et al., "Scene transformer: A unified multi-task model for behavior prediction and planning," in the International Conference on Learning Representations (ICLR), 2021.
- [95] M. Liang, B. Yang, R. Hu, Y. Chen, R. Liao, S. Feng, and R. Urtasun, "Learning lane graph representations for motion forecasting," in European Conference on Computer Vision. Springer, 2020, pp. 541–556.
- [96] W. Zeng, M. Liang, R. Liao, and R. Urtasun, "Lanercnn: Distributed representations for graph-centric motion forecasting," in 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2021, pp. 532–539.
- [97] <https://github.com/enyen/Deep-Trajectory-Prediction>