



**DERİN ÖĞRENME METOTLARIYLA TRAFİK KAZALARI TESPİT
ÇALIŞMASI**

Mustafa CAYMAZ

**YÜKSEK LİSANS TEZİ
ELEKTRONİK BİLGİSAYAR EĞİTİMİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ**

AĞUSTOS 2022

ETİK BEYAN

Gazi Üniversitesi Bilişim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Mustafa CAYMAZ

...../...../.....

DERİN ÖĞRENME METOTLARIYLA TRAFİK KAZALARI TESPİT ÇALIŞMASI
(Yüksek Lisans Tezi)

Mustafa CAYMAZ

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ

Ağustos 2022

ÖZET

Günümüzde nüfusun artmasıyla beraber trafikteki araç sayısı da artmaktadır. Bu artış ile paralel olarak trafik kazalarında da artış gözlenmektedir. Teknolojinin gelişmesiyle beraber derin öğrenme üzerinde birçok başarı sağlanmıştır. GPU'ların gelişmesiyle beraber derin öğrenmede büyük veri hesaplamaları daha kolay hale gelmiştir. Ülkemizde trafik kazalarının tahmini ve analizi için birçok çalışma bulunmaktadır. Bu çalışmalar genellikle yüksek lisans ve doktora tezi kapsamındadır. Yapılan çalışmaların çoğunda sadece analiz yaparak kazaların oluş yerleri, zamanları incelenmiştir. Yaş ve cinsiyete göre yapılan çalışmalar da mevcuttur. Kaza tahmini için yapılan çalışmalarda ise az sayıda veri ile çalışma yapılmıştır. Bu çalışma çok sayıda veri ile derin öğrenme algoritmaları kullanarak kaza tahmini yapmayı amaçlamaktadır. Türkiye'de meydana gelen iki milyona yakın kaza verisi üzerinde çalışılmıştır. Bu veriler anlamlı hale getirilip özellik çıkarımı yapılmıştır. Özellikler analiz edilerek hangi özelliğin derin öğrenme için daha önemli olduğu bulunmuştur. Daha sonra birçok derin öğrenme metodu ile veri eğitilerek tahminde bulunulmuştur. Bu metotlar birbiriyle karşılaştırılmıştır. Modelin başarı oranı %87 olarak elde edilmiştir. Elde edilen model kullanılarak bir mobil uygulama geliştirilmiştir. Literatürdeki tahmin çalışmalarında kaza sonucundaki ölü, yaralı sayıları tahmin edilmeye çalışılmıştır. Bazı çalışmalarda ise olası kaza kara noktalarını tahmin etmeye yönelik çalışmalar yapılmıştır. Bu tez çalışmasında, sürücünün güzergâh üzerindeki kaza noktaları tahmin edilmeye çalışılmıştır. Diğer çalışmalardan farklı olarak kaza tahminini sürücünün kişisel bilgileri, yol ve hava durumu bilgilerine göre güzergâh üzerinde anlık olarak tahmin edilmeye çalışılmıştır. Böylelikle yolculuk sırasında sürücünün daha dikkatli olması gereken bölgeler bildirilmiştir. Güzergâh üzerindeki olası kaza noktalarının sürücüye önceden bildirilmesinin kaza sayılarını azaltılması düşünülmektedir.

Bilim Kodu : 92431

Anahtar Kelimeler : Derin öğrenme, trafik kazaları

Sayfa Adedi : 50

Danışman : Doç. Dr. İbrahim Alper DOĞRU

DETERMINATION OF TRAFFIC ACCIDENTS BY DEEP LEARNING METHODS

(M. Sc. Thesis)

Mustafa CAYMAZ

GAZİ UNIVERSITY

INFORMATICS INSTITUTE

August 2022

ABSTRACT

Today, with the increase in the population, the number of vehicles in traffic is also increasing. In parallel with this, an addition is observed in traffic accidents. With the development of technology, many successes have been achieved in deep learning. With the development of GPUs, extensive data calculations in deep learning have become more manageable. There are many studies for predicting and analyzing traffic accidents in our country. These studies are generally within the scope of ma and doctoral thesis. In most of the studies, the places and times of the accidents were examined only by analyzing. There are also studies based on age and gender. Studies conducted for accident estimation have a small amount of data. This study aims to predict accidents using deep learning algorithms with extensive data. It has been studied on the data of nearly two million accidents in Türkiye. These data were made meaningful, and feature extraction was done. Analyzing the features was found which features are more important for deep learning. Then, predictions were made by training the data with many deep learning methods. These methods are compared with each other. The success rate of the model was 87%. A mobile application was developed using the obtained model. In the estimation studies in the literature, the number of dead and injured because of the accident has been tried to be estimated. Some studies have been carried out to predict possible accident black spots. In this thesis, the accident points of the driver on the route were attempted to be estimated. Unlike other studies, the accident forecast was tried to be estimated instantly on the route according to the driver's personal information, road, and weather information. Thus, the areas where the driver should be more careful during the journey are reported. It is thought to reduce the number of accidents by informing the driver of possible accident points on the route in advance.

Science Code : 92431

Key Words : Deep learning, traffic accidents

Page Number : 50

Supervisor : Assoc. Dr. İbrahim Alper DOĞRU

TEŐEKKÖR

Bu tez alıőmasında bana olan desteklerinden dolayı sevgili eőim Ayőegöl CAYMAZ ve tez danıőmanım Do. Dr. İbrahim Alper DOĐRU'ya sonsuz teőekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI	7
3. MATERYAL VE YÖNTEM	19
3.1. Derin Öğrenme (Deep Learning).....	19
3.2. UKVHA (Uzun Kısa Vadeli Hafıza Ağları).....	20
3.3. Trafik Kazalarının Önlenmesinde Yapay Sinir Ağı Modeli.....	21
3.3.1. Veri seti.....	21
3.4. Veri İşleme.....	28
3.4.1. Aykırı değerleri temizleme.....	30
3.4.2. Özellik listesinin çıkarılması	30
3.4.3. Kayıp verilen temizlenmesi.....	30
3.4.4. İl seçimi	30
3.4.5. Konum bilgilerinin işlenmesi	30
3.4.6. Makine öğrenme algoritmaları ile kaza şiddetini tahmin etme.....	34
3.5. Mobil Uygulama.....	36

	Sayfa
4. ARAŐTIRMA BULGULARI	43
4. SONUÇ VE ÖNERİLER.....	43
KAYNAKLAR.....	45
ÖZGEÇMİŐ.....	50



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Yıllara göre kaza, ölü ve yaralı sayıları	1
Çizelge 1.2. Trafiğe kayıtlı ve trafik kazasına karışan taşıtlar.....	3
Çizelge 2.1. Yapılan çalışmaların karşılaştırılması	15
Çizelge 3.1. Veri seti özellikleri ve açıklamaları	21



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Trafik kazalarına neden olan kusurlar	3
Şekil 1.2. Ölümlü yaralanmalı kazaya neden olan sürücü kusurları	4
Şekil 3.1. UKVHA yapısı	21
Şekil 3.2. Cinsiyete göre kaza sayıları	23
Şekil 3.3. Gün durumuna göre kaza sayıları	24
Şekil 3.4. Ankara kaza noktaları	25
Şekil 3.5. Türkiye kaza noktaları	25
Şekil 3.6. Sürücü eğitim durumuna göre kaza sayıları	26
Şekil 3.7. Aylara göre kaza sayıları	26
Şekil 3.8. Yerleşim yerine göre kaza sayıları	27
Şekil 3.9. Kaza sayısı ile hava durumu karşılaştırması.....	28
Şekil 3.10. Veri işleme akış diyagramı	29
Şekil 3.11. Kaza konum bölgeleri algoritması.....	31
Şekil 3.12. Kaza konum bölgeleri.....	32
Şekil 3.13. Kaza konum bölgeleri filtreleme	32
Şekil 3.14. Ankara ili kaza konum bölgeleri filtreleme	33
Şekil 3.15. Filtreleme algoritması.....	34
Şekil 3.16. Makine öğrenimlerinin birbirleriyle karşılaştırılması.....	35
Şekil 3.17. Modelin doğruluk puanı	35
Şekil 3.18. Epoch doğruluk.....	36
Şekil 3.19. Uygulama çalışma şeması.....	38
Şekil 3.20. Uygulama akış diyagramı	39
Şekil 3.21. Uygulama ısı haritası	40

Şekil 3.22. Uygulama güzergâh ekranları..... 40



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar

Açıklamalar

BSA	Bayes Sinir Ağı
GYSA	Geri Yayılım Sinir Ağı
CBS	Coğrafi Bilgi Sistemleri
DÖ	Derin Öğrenme
GA	Genetik Algoritma
OMS	Ortalama Mutlak Sapma
OMYH	Ortalama Mutlak Yüzde Hata
ML	Makine Öğrenmesi
NB	Negatif Binom
SBM	Sigorta Bilgi Merkezi
UKVHA	Uzun Kısa Vadeli Hafıza Ağları
YOGT	Yıllık Ortalama Günlük Trafik
YSA	Yapay Sinir Ağları

1. GİRİŞ

Kaza kavramı herhangi bir zamanda ortaya çıkan, can ve mal kaybı ile sonuçlanan kötü olaylardır. Kazalar meydana gelmeden alınacak önlemlerle kaçınılabılır ve korunabilir bir olay olarak da tanımlanmaktadır [1].

Dünya genelinde trafik kazalarının sayısının azaltılması amaçlanmıştır. Bunun için tüm dünyada ve Türkiye’de birçok çalışmalar yapılmaktadır. Bu çalışmalarda kazaya neden olan etkenler belirlenmeye çalışılmakta ve ona göre önlemler önerilmektedir. Kazalara neden olan faktörlerin doğru tespit edilebilmesi sorunun çözümünü de kolaylaştıracaktır [2].

Dünyada nüfus hızlıca artmaktadır. Nüfus artışına paralel olarak araç sayısı da artmıştır. Yapılan araştırmalar ülkemizde bu artışlarla birlikte ölümlü ve yaralanmalı trafik kazalarının meydana gelme olasılığının arttığını göstermiştir. Türkiye İstatistik Kurumu’nun 2022 yılında yayınladığı istatistiklere göre; 2021 yılında 998 390’i maddi hasarlı, 187 963’si ölümlü veya yaralanmalı olmak üzere 1 186 353 trafik kazası meydana gelmiş, bu kazalarda 5 362 kişi yaşamını yitirmiş, 274 615 kişi yaralanmıştır [3].

Çizelge 1.1. Yıllara göre kaza, ölü ve yaralı sayıları [3]

Yıl	Toplam kaza sayısı	Maddi hasarlı kaza sayısı	Ölümlü, yaralanmalı kaza sayısı	Ölü sayısı	Yaralı sayısı
2012	1 296 634	1 143 082	153 552	3 750	268 079
2013	1 207 354	1 046 048	161 306	3 685	274 829
2014	1 199 010	1 030 498	168 512	3 524	285 059
2015	1 313 359	1 130 348	183 011	7 530	304 421
2016	1 182 491	997 363	185 128	7 300	303 812
2017	1 202 716	1 020 047	182 669	7 427	300 383
2018	1 229 364	1 042 832	186 532	6 675	307 071
2019	1 168 144	993 248	174 896	5 473	283 234

Çizelge 1.1. (devam) Yıllara göre kaza, ölü ve yaralı sayıları [3]

2020	983 808	833 533	150 275	4 866	226 266
2021	1 186 353	998 390	187 963	5 362	274 615

Çizelge 1.1.'de Türkiye'de 2021 yılında, 2020 yılına göre toplam kaza sayısı %20,6 arttığı gözlenmektedir. Bunun nedeni olarak 2019 yılının Covid-19 salgını etkinde geçmesindedir. Kazaların önceden tespiti mümkün değildir fakat derin öğrenme algoritmaları ile elde edilen bilgiler ile kaza risk tahmin etmek mümkün görülmektedir. Bu çalışmada, Türkiye'de meydana gelen trafik kazalarının derin öğrenme ile analiz ve tahminlerinin yapılması planlanmıştır. Çalışmada 2013-2020 yılları arasında meydana gelen yaklaşık 1,5 milyon trafik kazası verisi ele alınmıştır. T.C. Karayolları Trafik Kanunu'ndaki trafik kazası tanımı şu şekildedir: "Karayolları üzerinde hareket halinde olan, bir veya birden fazla aracın karıştığı ölüm, yaralanma veya maddi zararlı sonuçlanan olaya trafik kazası denir". Ulusal ya da uluslararası tanımlamaların hepsinde kazanın tanımı şu şekildedir: "Gerçekleşmesi önceden bilinmeyen, tahmin edilmeyen veya planlanmayan bir zamanda meydana gelen, can ve mal kaybına sebep olan olaya kaza denir". Trafik kazalarını meydana getiren faktörler belirlenir, önlemler alınır biliniyor ise kazalardan korunabileceği veya kaçınılabileceği sonucu ortaya çıkmaktadır.


Birleşmiş Milletler Örgütü 179 ülke ile "yol güvenliği ve çevre" alanında önlemler almak konusunda 19-20 Kasım 2009 tarihinde Moskova'da "Küresel Yol Güvenliği Bakanlar Konferansı" düzenledi. Konferans sonunda gelecek on yıllık eylem planının bildirgesi katılanlar tarafından kabul edildi. Toplantıda önlem alınması gereken trafik kaza nedenleri öncelik sırasına göre şöyle tespit edildi [4].

- Hız
- Emniyet kemeri
- Cep ve araç telefonu
- Alkol
- Kask
- İlk yardım

Çizelge 1.2. Trafiğe kayıtlı ve trafik kazasına karışan taşıtlar [5]

Yıl	Kayıtlı taşıt sayısı	Trafik kazasına karışan taşıt sayısı
2012	17 033 413	210 609
2013	17 939 447	251 729
2014	18 828 721	264 936
2015	19 994 472	290 072
2016	21 090 424	295 727
2017	22 218 945	294 515
2018	22 865 921	300 704
2019	23 156 975	280 700
2020	24 144 857	243 125

Çizelge 1.2.'e göre 2020 yılında trafiğe kayıtlı araçların %1'i trafik kazasına karışmaktadır. Yıllara göre trafik kazasına karışan araç sayısının trafiğe kayıtlı araç sayısına göre oranı %1 ile %1,5 arası değişmektedir.




Şekil 1.1. Trafik kazalarına neden olan kusurlar [5]

Şekil 1.1.'den anlaşıldığı gibi trafik kazalarına neden olan kusurların büyük bir oranı sürücü kusurlarıdır.

Trafik kazaları oluş nedenleri sadece sürücüye hatalarından oluşmamaktadır. İsveç'te

“Vizyon Sıfır” (Vision Zero) adı verilen politika yaklaşımı önerilmektedir. Bu yaklaşımla, trafik kazalarındaki sorumluluk sürücü, karayolu ve trafik sisteminin tüm unsurları arasında paylaştırılmıştır. Uzun mesafe sürücüleri, kazaların yolların teknik ve fiziki kusurlarından kaynaklandığını öne sürmektedirler.



Şekil 1.2. Ölümlü yaralanmalı kazaya neden olan sürücü kusurları [5]

Şekil 1.2.’de ölümlü yaralanmalı kazaya neden olan sürücü kusurları gösterilmiştir. Sürücü kusurlarının %37’si araç hızını yol, hava ve trafiğin gerektirdiği şartlara uydurmamaktır. Sürücünün araç hızını dış etmenlere uyduramaması kaza sebepleri arasında önemli bir yer almaktadır.

Bu çalışmada, derin öğrenmeye dayalı bir trafik kaza olasılık tespit modelini geliştirilmeye çalışılmaktadır. Geliştirilen model ile bir mobil uygulama geliştirilerek sürücünün güzergâh üzerindeki olası kaza bölgeleri hakkında bilgi edinmesi amaçlanmaktadır.

İkinci bölümde, literatürde yapılan çalışmalar incelenmektedir ve en çok kullanılan yöntemler hakkında bilgi verilmektedir. Üçüncü bölümde materyal ve yöntemden bahsedilmektedir. Derin öğrenme yöntemleri ve veri seti hakkında bilgi verilmektedir. Verilerin anlamlı hale getirilirken yapılan çalışmalardan bahsedilmektedir. Elde edilen bulgular değerlendirilmektedir ve modelin başarısı hesaplanmaktadır. Dördüncü bölümde geliştirilen mobil uygulama yöntemi hakkında bilgi verilmektedir.

Bu çalışmanın ana katkıları şu şekilde sıralanmaktadır;

- Türkiye'deki kaza kara noktalarının belirlenmesi
- Kaza tahminini mobil uygulamaya dönüştürülmesi
- Derin eğitim setindeki kaza konumlarını segmentlere ayırarak başarımın daha yüksek hale getirilmesi
- Kaza konum bilgilerini gruplanması



2. LİTERATÜR TARAMASI

Trafik kazalarının analizi ve tahminleri ile ilgili dünyada birçok çalışma yapılmıştır. Aşağıda bu tez ve makale çalışmalarından bazıları sunulmuştur:

Doğan (2007) tarafından yapılan tez çalışmasında; Türkiye’de trafik kaza sonucu tahmin etmek için geliştirilen modeller anlatılmıştır. Türkiye’de 1986-2006 yılları arası meydana gelen trafik kazaları verileri kullanılmıştır. Nüfus ve motorlu araç sayıları bilgilerini kullanarak, regresyon analizi, Yapay Sinir Ağları (YSA), GA (Genetik Algoritma) metotları kullanılmıştır. Türkiye’nin bazı illerinde (Adana, Ankara, Antalya, Bursa, İçel, İstanbul, İzmir ve Konya) meydana gelebilecek trafik kazalarının sayısının tahmin etmeye çalışılmıştır. Tahmin edilen bu kazalar sonucunda oluşacak yaralı ve ölü sayıları çıkarımı yapılmıştır [6].

Kibar (2008) tarafından yapılan tez çalışmasında; Türkiye’de meydana gelen kazaların frekansının Doğrusal Regresyon, Poisson ve Negatif Binom Regresyonu gibi çeşitli istatistiksel metotlar yardımıyla analiz etmiştir. Elde ettiği modelden yola çıkarak, yol üzerindeki yaya geçitlerinin sayısını azaltarak, bunları üst veya alt geçitler haline getirerek meydana gelecek kazaların azalacağını savunmuştur [7].

Mirasyedi (2006) tarafından yapılan tez çalışmasında; sayısal olmayan değişkenlerin kazalar sonucu oluşan ölü ve yaralı sayılarına olan etkileri araştırılmıştır. Bu değişkenlerden özellikle mevsimlerin trafik kazalarına etkileri araştırılmıştır. Ülkemizde gelişen bazı sosyal faktörlerin etkisi de araştırılmıştır. Ülkemizdeki 1978-2003 yılları arasındaki trafik kaza istatistiklerinden faydalanılmıştır. Çoklu regresyon analizleri ile modeller geliştirilmiştir [8].

Çodur (2012) tarafından yapılan tez çalışmasında; Erzurum ili için 2005-2010 yılları arasında meydana gelen trafik kazalarının tespit tutanakları ve yolların geometrik özellikleri ile veri tabanı oluşturulmuştur. Veri tabanından elde edilen verilerle, YSA ve Genelleştirilmiş Doğrusal Regresyon Analizi ile karşılaştırılmıştır. Düşey kurp sayısı, Yıllık Ortalama Günlük Trafik (YOGT), yatay kurp sayısı ve yol kesim kilometresi trafik kazalarının oluşumunda anlamlı değişkenler olarak bulunmuştur [9].

Yıldırım (2014) tarafından yapılan tez çalışmasında; Ankara ili örneğinde trafik kazaları YSA modeli oluşturularak incelenmiştir. Modelin eğitim ve test süreçlerinden sonra %95’in üzerinde bir doğrulama oranına sahip olduğunu söylemiştir [10].

Parıldar (2014) tarafından yapılan tez çalışmasında; kaza tespit tutanakları ile kaza verileri derlenmiştir. Karar ağacı algoritmaları kullanılmıştır. Ölümlü kazalara etki eden faktörler belirlenmeye çalışılmıştır. CHAID algoritmasının en yüksek doğruluğa sahip olduğunu söylemişlerdir. CHAID algoritmasının kazaya etki eden faktörleri tespit etme problemlerine uygulanması önerilmiştir [11].

Bolakar (2014) tarafından yapılan tez çalışmasında; Erzurum ili özelinde gerçekleşen trafik kazalarına etki eden faktörler incelenmiştir. Bu etkenler; ilçe bilgileri, kayıtlı taşıt sayısı, yol özellikleri, trafik kapasitesi, endüstri kuruluşlarının sayısı, kentleşme seviyesi, trafik hacimleri, kazazede bilgileri, kaza zamanı, mevsim, kazaya karışan araç tipi ve benzeri gibi faktörlerin trafik kazaları üzerindeki etkileri yapay sinir ağları ve çok değişkenli istatistik yöntemleri kullanılarak incelenmiştir. Çalışma sonucunda şehir merkezlerinde ölüm oranlarının düşük olduğunu tespit etmiştir. Bunun sebebinin; şehir içerisinde yolların durumunun iyi olması, şehir merkezindeki kişilerin gelir seviyelerinin ilçelerdeki diğer bireylere göre daha yüksek olması, kullanılan araçların yeni araçlar olması ve kazaların acil yardım merkezlerine mesafesinin daha az olmasıyla ilişkili olduğunu belirlemiştir. Ayrıca kırsal kesimlerde yaşayan insanların trafik kurallarına uyma bilincinin daha az olduğunu söylemiştir. Emniyet kemeri kullanılmamasının ölüm oranının artırdığını savunmuştur [12].

Bekin (2018) tarafından yapılan tez çalışmasında; veri olarak Pendik bölgesinde Eylül 2017 yılından sonra gerçekleşmiş kaza bilgileri kullanılmıştır. Sigortacılık sektörü firmalarından elde edilen verileri ile ivme ve hız bilgileri, sürücünün görünüş verileri ve duygusal analiz verilerinin kazaya risk oluşturma açısından hesaplamıştır. Hava durumu gibi çevresel faktörler kazaların gruplandırma ile Makine Öğrenmesi (MÖ) ile trafik kazası olma olasılıklarını ortaya koymuştur [13].

Kaya (2015) tarafından yapılan tez çalışmasında; SBM (Sigorta Bilgi Merkezi) tarafından sağlanan 5000 adet maddi hasarlı trafik kazası verisi kullanılmıştır. Verilere makine öğrenmesi teknikleri uygulanarak kaza riskini hesaplanmıştır. Etkileşimli dinamik bir web sitesi geliştirilmiştir. Bu web sitesi ile kaza riski tahmini gerçekleştirilmiştir. Geliştirilen uygulama ile aracın konumu, hava durumu ve makine öğrenmesinden elde edilen kaz olma olasılığı bilgilerine dayanarak güzergâh üzerinde sürücünün kaçınması gereken yollar gösterilmiştir [14].

Çiçek (2014) tarafından yapılan tez çalışmasında; Erzurum ili özelinde trafik kazalarının analizleri gerçekleştirilmiştir. Erzurum ilinin coğrafi özellikleri ile orada yaşayan insanların

trafik davranış özellikleri incelenmiştir. Erzurum şehir içi trafik kazalarının bir veya bazı tesadüfî değişkenlere ya da rastgele kriterlere bağlı olmadığını, birden çok kriterlere bağlı olduğunu söylemiştir [15].

Özgün (2015) tarafından yapılan tez çalışmasında; Emniyet Genel Müdürlüğü'nün 2013 yılı verilerine göre Gaziantep ilinin ölümlü kazalar sıralamasında 10.ncu sırada olduğunu söylemiştir. Gaziantep ili özelinde Coğrafi Bilgi Sistemleri (CBS)'nin desteğiyle kazalar analiz edilmiştir. Yapılan analizler sonucunda kaza kara noktaları tespit edilmiştir. Bu kaza kara noktaları genelde kavşaklarda olduğunu belirlemiştir [16].

Dedeoğlu (2016) tarafından yapılan tez çalışmasında; Kahramanmaraş İli şehir merkezinde meydana gelen kazalar incelenmiştir. CBS kullanılarak trafik kazalarının en yoğun olduğu bölgeler ve kaza noktaları tespit edilmiştir [17].

Dereli (2016) tarafından yapılan tez çalışmasında; Karayolları Genel Müdürlüğü tarafından sağlanan 2005-2013 yıllarını kapsayan trafik kaza verileri kullanılmıştır. Veri seti olarak 2408 adet devlet yolu kullanılmıştır. Devlet yollarının birer km'lik alt bölümlere ayrılmıştır. Birçok makine öğrenme yöntemi kullanılmıştır. Ampirik Bayes yönteminin daha iyi sonuçlar verdiği görülmüştür [18].

Çalımcı (2016) tarafından yapılan tez çalışmasında; trafik kazalarının araştırılmasında bilgisayarların kullanımı konusu üzerinden detaylı olarak ele alınmıştır. İstatistiklerden faydalanılarak ülkemizde meydana gelen trafik kazalarına incelenmiş ve kazaların yeniden canlandırılması yapılmıştır [19].

Taha (2017) tarafından yapılan tez çalışmasında; 2013-2017 dönemi boyunca Kuzey Irak Bölgesinde trafik kazası vakaları, yaralanmalar ve ölümler üzerine tahmin yapılmasını amaçlamıştır. Yaptığı çalışmadaki tahmin değerine göre, trafik kazası ve yaralanma vakaları mevsimsel değişimle birlikte azalmaya devam edeceğini öngörmektedir [20].

Özkoç (2019) tarafından yapılan tez çalışmasında; kaza tutanaklarındaki suiistimalleri tespit etmek için karar destek sistemi (Decision Support Systems) ile bir uygulama geliştirmiştir. Kaza yapan araç ve kişi bilgileri sisteme girilerek bir ağ grafiği şeklinde çizdirilmiştir. Çizilen bu ağ grafiği ile daha önceki kazalar karşılaştırılmakta ve bir suiistimalin olup olmadığı tespit edilmeye çalışılmıştır [21].

Önder (2019) tarafından yapılan tez çalışmasında; CBS ile 2017 yılı içerisindeki İstanbul

illinde gerçekleşen trafik kazalarını incelemiştir. Bu incelemeyi aylara, günün saatlerine, hava durumuna, yol tipine, kavşak tipine, geçit türüne gibi etmenlere göre incelemiştir. İstatistik yaklaşım ile incelenen bu veriler CBS yazılımları ile görselleştirilmiştir [22].

Kılıçarslan (2019) tarafından yapılan tez çalışmasında; YSA ile trafik kazaları gerçekleşmeden erken uyarı verecek sistem geliştirme amaçlamıştır. Trafik kazalarını ve kazazede sayısını etkileyen değişkenlerin incelenmesi amaçlanmıştır. İnceleme için beş farklı senaryo oluşturulmuştur. Belirlenen parametrelerin kazazede sayısına etkisi incelenmiştir. Gün durumu, hava durumu ve yaya yolunun durumu kaza oluşma riskine en yüksek düzeyde tahmin ettiği sonucu elde etmiştir [23].

Bolat (2019) tarafından yapılan tez çalışmasında; Kayseri ili şehir merkezinde 2016-2018 yılları arası meydana gelen kazalar Veri Madenciliği adımları (temizleme, bütünleştirme, veri seçimi ve veri dönüştürme) işlemleri yapılmıştır. YSA ile trafik kazalar üzerinde tahminle çalışması yapılmıştır. Kazanın meydana geldiği ay, saat, ilçe, mahalle, araç sayısı, araç türleri, sürücü kusurları, yaya kusurları, kaza oluş nedeni girdi olarak kullanılmıştır. YSA eğitiminde kazada meydana gelen ölü ve yaralı sayısı çıktı verisi olarak tahmin edilmiştir. Oluşturulan algoritmaların tamamına yakınında %99 doğruluk oranı sonucuna ulaşılmıştır [24].

Delen, sharda ve Bessonov (2006) tarafından yapılan çalışmada; bir trafik kazasında sürücülerin ve yolcuların ölüm veya yaralanma ihtimalinin anlaşılmasının mümkün olduğu savunulmuştur. Bu çalışma, yaralanma şiddeti ile çarpışma arasındaki doğrusal olmayan ilişkiyi yapay sinir ağları ile modellemiştir. Emniyet kemeri kullanımı, alkol veya uyuşturucu kullanımı, kişilerin yaşı ve cinsiyeti, hava koşulları ve kaza zamanının kazanın sonucu üzerinde önemli bir etkisi olduğunu göstermişlerdir [25].

Xie, Lord ve Zhang (2007) tarafından yazılan makalede; Bayes sinir ağı (BSA) modellerinin trafik kazalarını öngörmek için uygulanmasını değerlendirmiştir. Bu hedefi gerçekleştirmek için, Teksas'tan toplanan kaza verileri ile bir model gerçekleştirmiştir. Yapılan çalışmada geri yayılım sinir ağı (GYSA), BSA ve negatif binom (NB) regresyon olmak üzere üç tip model karşılaştırılmıştır. Genel olarak her iki yapay sinir ağı modelinin veri tahmini açısından NB regresyon modelinden daha iyi performans sergilediğini göstermişlerdir [26].

Rodríguez, Jattin ve Soracipa (2020) tarafından yapılan çalışmada; Kolombiya'daki trafik kazalarının neden olduğu ölüm oranlarının zamansal davranışını analiz etme ve tahmin etme

yeteneğini doğrulamıştır. Olasılık teorisi bağlamında, rastgele yürüyüş (Random Walk) olguyu matematiksel olarak tahmin ettiğini savunmuşlardır [27].

Li, Abdel-Aty ve Yuan (2020) tarafından yazılan makalede; gerçek zamanlı kaza tahminin genellikle otoyollar üzerinde gerçekleştiğini söylemişlerdir. Fakat yaptıkları bu çalışmada otoyollardan ziyade kentsel arterler üzerinde gerçekleştirmişlerdir. Yapılan çalışmada, arterler üzerinde gerçek zamanlı çarpışma riski tahmini için uzun kısa süreli bellek-evrişimli sinir ağı (UKVHA-CNN) modelini önermişlerdir. Bu modelin, trafik akış özelliklerini, sinyal zamanlaması ve hava koşulları gibi çeşitli özelliklerden öğrenebildiğini göstermişlerdir. UKVHA ile uzun vadeli bağımlılığı yakaladığını, CNN ise zamanla değişmeyen özellikleri ayıkladığını iddia etmişlerdir. UKVHA-CNN'nin diğer yöntemlerden çok daha yüksek AUC değerine sahip olduğunu söylemişlerdir [28].

Parsa, Movahedi, Taghipour, Derrible ve Mohammadian (2020) yaptığı çalışmada; trafik, ağ, demografik, arazi kullanımı ve hava durumu özelliklerinden oluşan bir dizi gerçek zamanlı veri kullanarak kaza oluşumunu tespit etmek için eXtreme Gradient Boosting (XGBoost) kullanmışlardır. Veriler Aralık 2016 ile Aralık 2017 arasında Chicago metropol otoyollarından toplanmıştır ve 244 trafik kazası ve 6073 kaza olmayan vakayı içermektedir. Özellikle bir kazadan 5 dakika önce ve 5 dakika arasındaki hız farkının, kazaların meydana gelmesi üzerinde nispeten daha fazla etkisi olduğu bulunmuştur [29].

Amin (2020) yazdığı makalede; yaşlı kadın ve erkek sürücülerin trafik kazalarını etkileyen faktörleri modellemek için Genelleştirilmiş Delta Kuralı (GDR) öğrenme algoritmalı Backpropagation-Yapay Sinir Ağı (BP-YSA) uygulamıştır. 2006-2016 yılları arasında Birleşik Krallık'ın West Midlands bölgesinde toplam 95.092 kaza kaydı incelenmiştir. Yolculuk amacını, aydınlatma koşullarını, yaya geçidini, karmaşık yol geometrisini, aşırı hava durumunu ve zaman şiddetini yaşlı sürücü kazalarının en önemli faktörleri olduğunu saptamıştır [30].

Mokhtarimousavi, Anderson, Azizinamini ve Hadi (2020) yaptığı çalışmada; yaya kazalarının yaralanma şiddeti ile ilişkili faktörleri haftanın günlerine göre araştırmışlardır. Hafta içi ve hafta sonu kazaları için ayrı yaralanma şiddeti modelleri geliştirilmişlerdir. Bu geliştirdikleri modelin (WOA-ANN) diğer YSA modellerine göre daha iyi sonuç aldığını söylemişlerdir [31].

George ve Santra (2020) yazdığı makalede; trafik hızı tahmini, akıllı şehirlerde daha iyi bir ulaşım sistemi elde etmek için önemli olduğunu söylemişlerdir. Doğru trafik hızı tahmini,

anormal trafik koşulları, trafik olayları, inşaat veya olaylardan kaynaklanan şerit kapanmaları ve trafik sıkışıklığı gibi birçok bağlamsal faktörden etkilendiğini söylemişlerdir. Bu sorunların üstesinden gelmek için, uzun vadeli trafik hızı tahmini için bulanık optimize edilmiş uzun kısa süreli bellek (FOLSTM) sinir ağı adı verilen yeni bir yöntem önermişlerdir. FOLSTM tekniği, hesaplama zekâsı, makine öğrenimi ve metaheuristik tekniklerden oluşan ve makroskobik trafik anahtar parametreleri için hızı tahmin edebilen hibrit bir yöntemdir [32].

Moosavi, Samavatian, Nandi, Parthasarathy ve Ramnath (2019) yaptıkları çalışmada; iki yıl boyunca ABD için toplanan ülke ölçeğinde trafik ve hava durumu veri kümesini kullanmışlardır. Uzun vadeli tıkanıklık, kar, yağmur, sis, şiddetli soğuk ve akış olaylarının trafik akışı üzerinde en önemli gecikme etkisine neden olduğunu bulmuşlardır [33].

Abdelwahab ve Abdel-Aty (2001) yaptıkları çalışmada; kaza etmenleri arasındaki ilişki incelemiştir. Sürücü yaralanma şiddeti ile sürücü, araç, yol ve çevre özellikleri incelemiştir. Çok katmanlı algılayıcı (ÇKA) ve bulanık uyarlanabilir rezonans teorisi (ART) sinir ağlarının kullanımı araştırılmıştır. Analiz, sinyalizasyon kavşaklarında meydana gelen iki araçlı kazalara odaklanmıştır. Sonuç olarak kırsal kavşakların sürücünün yaralanma ciddiyeti açısından kentsel kavşaklardan daha tehlikeli olduğunu göstermişlerdir. Ayrıca, kadın sürücülerin erkek sürücülere göre ciddi bir yaralanma yaşama olasılığı daha yüksek olduğunu göstermişlerdir. Hız oranı, yaralanma şiddeti olasılığını artırdığını söylemişlerdir [34].

Boulieri, Liverani, de Hoogh, ve Blangiardo (2017) yazdığı makalede; mekânsal ve zamansal korelasyonlar ile karayolu trafik kazalarının şiddet seviyeleri arasındaki bağımlılıkları araştırmışlardır. Yaptıkları çalışmada, 2005-2013 dönemi boyunca İngiltere'de meydana gelen trafik kazası verilerini analiz etmişlerdir. Londra için kaza sıcak noktalarını tespit etmişlerdir [35].

Do, Taherifar ve Vu (2019) yazdıkları makalede; kısa vadeli trafik durumu tahmininin farklı yönleri için farklı YSA türlerinin nasıl kullanıldığını göstermek için ayrıntılı bir tartışma sunmuşlardır. Karmaşık ulaşım ağlarındaki dinamik doğayı ele almak için özellikle derin mimariler kullanan YSA modellerinin ek uygulamaları için olası daha ileri araştırma yönleri önermişlerdir [36].

Liu, Liu, Wu, Han ve Guan (2019) yaptıkları çalışmada; trafik kazalarındaki travmatik beyin yaralanmalarını sınıflandırmak için K-en yakın komşu kullanılmışlardır [37].

Twala (2014) yazdığı makalede; çok sayıda araştırmacı çok çeşitli tahmin teknikleri ile kaza tahminini sunduğunu söylemektedir. Bu yöntemlerin çoğu istatistiksel çalışmalara dayandığını, ancak genellikle tahmin sonuçlarının görüşlerini açıklayamadığını savunmaktadır. Benzer veriye dayalı bir yöntem olan gri ilişkisel analize dayalı bir sınıflandırıcı kullanılarak, zayıf veri kalitesi verilen kazaların tahmininin iyileştirilebileceği önermiştir. Gri ilişkisel sınıflandırıcıyı yapay sinir ağları, sınıflandırma ve regresyon ağaçları, k-en yakın komşu, doğrusal diskriminant analizi, saf Bayes sınıflandırıcısı, algoritma yarı optimal ve destek vektör makineleri dahil olmak üzere diğer son teknoloji sınıflandırıcılarla değerlendirmiştir. Gri ilişkisel sınıflandırıcı algoritmasının trafik kazası öngörme doğruluğu açısından verimliliğini ve sağlamlığını göstermek için deneysel sonuçlar sunmuştur [38].

Zhang, Waller ve Jiang (2020) yaptıkları çalışmada; literatürde bir dizi topluluk makine öğrenme (EML) yöntemine dayanan trafik kazası sıklığını analiz etmek için bir modelleme çerçevesi sunan ilk çalışması olduğunu söylemişlerdir [39].

Li, Sheng, Du, Wang ve Ran (2020) tarafından yazılan makalede; trafik sıkışıklığını hafifletmek için trafik kazalarının sürelerinin tahmin edilmesi önerilmiştir. Önerilen model üç makine öğrenimi modelden daha iyi sonuç gösterdiğini söylemişlerdir [40].

Liu, Wu, Wen, Xiao ve Chen (2022) tarafından yazılan makalede; trafik akış tahmininde trafik kazalarının etkisi ele alınmıştır. Trafik akışı tahmini için bir gri evrimsel sinir ağı tahmin modeli önermişlerdir. Önerilen bu model Çin'deki ve Çin dışındaki iki otoyolun trafik akış verilerine uygulanmış ve modelin tahmin performansını performanslı olduğunu göstermişlerdir [41].

Zheng, Chai, Katos ve Walton (2021) tarafından ele alınan bu yazıda, kısa vadeli trafik akışı tahmini sorununu ele almak için yeni bir topluluk modeli önermişlerdir. Los Angeles ve Londra'daki iki farklı yol tipinde (doğrusal ve kavşaklar) incelemişlerdir. Önerdikleri model, lineer ve kavşak yolları için sırasıyla ortalama %96,14 ve %95,53 doğruluk elde etmiştir [42].

Song, Li, Ma, Wang, Qu, ve Wang (2018) tarafından yazılan bu makalede, tarihsel veriler ile verilen günlük trafik akışı tahmin problemini ele almayı amaçlamışlardır. Makalelerinde,

hedef günü, haftanın günü ve hava durumu gibi faktörler ile uygun tarih gün gruplarıyla eşleştirme yoluna gidilmiştir. Seattle merkezli bir otoyolda bir döngü dedektöründen alınan 1 yıllık verilerle çalışma yürütülmüştür. Kullandıkları yöntemin trafik akışı tahmin problemi için girdi verisi seçimini öneren ilk çalışma olduğunu iddia etmişlerdir. Önerdikleri yöntem, bir trafik kazası gibi beklenmedik bir durumda trafik akışını doğru bir şekilde tahmin edememiştir [43].

Shaik, Islam ve Hossain (2021) tarafında yazılan makalede, karayolu çarpışma yaralanmalarının ciddiyet tahmini için evrimsel sinir ağını incelemişlerdir. Yazdıkları bu makalede model girdi parametresini, bağımsız değişkeni, çeşitli performans değerlendirme yöntemlerini özetlemişlerdir [44].

Moosavi, Samavatian, Parthasarathy, Teodorescu ve Ramnath (2019) tarafından hazırlanan makalede, veri setlerinin küçük ölçekli ve sınırlı kapsama sahip olmasının trafik kaza analizi ve tahmini için zorluklara neden olduğunu söylemişlerdir. Bu zorlukların üstesinden gelmek için, elde edilmesi kolay, seyrek verileri kullanarak gerçek zamanlı trafik kazası tahmini için yeni bir çözüm önermişlerdir. Gerçek zamanlı kaza tahmini için trafik bilgisi, zaman ve ilgi noktaları verilerinin etkisini göstermişlerdir [45].

Briz-Redón, Iftimi, ve Montes (2022) tarafından yazılan makalede, Valencia (İspanya) karayolu ağı genelinde trafik kazası meydana gelme riski, lojistik regresyon modelleri aracılığıyla modellenmiştir. Elde ettikleri sonuçlara göre, mekânsal-zamansal bağımlılığın dahil edilmesinin modellerin tahmin yeteneğini geliştirdiğini göstermişlerdir [46].

Ma, Mei, ve Cuomo (2021) tarafından yazılan makalede, korunmasız yol kullanıcılarının karayolu trafiği ortamında en yüksek riske maruz kaldıkları savunulmuştur. Yazdıkları bu makalede, trafik kazalarının yaralanma şiddetini tahmin etmek için yığınlanmış seyrek otomatik kodlayıcı olarak adlandırılan bir derin öğrenme modelini önermişlerdir [47].

Çizelge 2.1. Yapılan çalışmaların karşılaştırılması

Çalışma	Algoritma	Özellik	Veri Seti	Değerlendirme metriği	Başarı oranı
Doğan, E. (2007) [6]	YSA	Yıllara göre yaralı ve ölü sayısı	EGM, TÜİK	R^2	%99

Çizelge 2.1. (devam) Yapılan çalışmaların karşılaştırılması

Delen ve diğerleri (2006) [25]	ÇKA YSA	Yaralanma derecesi	National Automotive Sampling System General Estimates System	DOĞRULUK	%90
Xie ve diğerleri (2007) [26]	BSA	Trafik kaza sayısı	Texas, 122 kaza	OMS	%87
Rodríguez ve diğerleri (2020) [27]	Random Walk	Kazalarda n kaynaklı ölüm oranları	Kolombiya, 2004-2010	AUC	%86,6
Li ve diğerleri (2020) [28]	UKVHA-CNN	Gerçek zamanlı çarpışma riski	University of California Riverside Benchmark	AUC	%93
Parsa ve diğerleri (2020) [29]	eXtreme Gradient Boosting (XGBoost)	Gerçek zamanlı çarpışma tahmini	Chicago metropol otoyolları, 244 trafik kazası ve 6073 kaza olmayan vaka	DOĞRULUK	%99
Amin (2020) [30]	BP-ANN	Yaşlıların kaza yapmasını etkileyen faktörler	Birleşik Krallık, 2006-2016, 95 092 kaza kaydı	R ²	%98- %99
Mokhtari mousavi ve diğerleri (2020) [31]	WOA-ANN	Haftanın günlerine göre yaralanma şiddeti	Kaliforniya (HSIS), 2010-2014	DOĞRULUK	%72
George ve Santra (2020) [32]	FOLSTM	Trafik akış hızı	San Diego, Beijing	OMYH	%3,9

Çizelge 2.1. (devam) Yapılan çalışmaların karşılaştırılması

Abdelwahab ve diğerleri (2001) [34]	ÇKA	Sinyalize kavşaklarda sürücü yaralanma şiddeti	Central Florida 1997	DOĞRULUK	%65,6
Song ve diğerleri (2018) [43]	GMDH	Trafik akışı	DRIVENET	OMYH	%10
Li ve diğerleri (2020) [40]	DFRBMs	Trafik kazası süresi	HSIS ve PeMs	OMYH	%20
Liu ve diğerleri (2022) [41]	G-CNN	Trafik akışı	Hangzhou Viaduct	OMYH	%0.14
Zheng ve diğerleri (2021) [42]	ALLSCP	Kısa süreli trafik akışı	Los Angeles ve Londra	DOĞRULUK	%95
Moosavi ve diğerleri (2019) [45]	DAP	Kaza tahmini	US-Accidents	DOĞRULUK	%87
Bu çalışma	UKVHA	Güzergâh üzerindeki kaza kara noktaları	EGM	DOĞRULUK	%87

Çizelge 2.1.'de literatürde geçen bazı çalışmaların karşılaştırılması yapılmıştır. Trafik tahmin etmeye yönelik birçok çalışma yapılmıştır. Kaza oluş yeri ve kaza sonrası durumu tahmin eden birçok çalışma incelenmiştir. Bu çalışmaların başarı oranı yüksek olarak bulunmuştur. Özellikle trafik sıklığını tahmin etmeye yönelik yapılan çalışmalar yüksek başarı oranı göstermiştir. Gerçek zamanlı kaza tahmin çalışmalarının sonuçlarına bakıldığında bu alanda daha çok çalışmanın yapılması gerektiğini göstermiştir. Trafik kaza şiddeti tahmin çalışmalarında başarı oranları yüksek bulunmuştur. Derin öğrenme

üzerinde yapılan çalışmaların fazlalığı trafik kazalarının tahmini için ümit verici olmuştur. Bu da derin öğrenme çalışmalarının trafik ile ilgili konularda uygulanabilir olduğunu göstermiştir.





3. MATERYAL VE YÖNTEM

Yapay Sinir Ağları (YSA) insan beyninden esinlenmiştir. Ağı oluşturan her bir elemana yapay nöron adı verilmektedir. YSA çeşitli ağırlıklı bağlar sayesinde birbirine bağlanmış birçok yapay nörondan oluşmaktadır. Her biri kendi belleğine sahip basit işlemciler, YSA içerisinde bulunmaktadır. Bu işlemciler sayesinde nöronlar bir ağ yapısını oluşturacak şekilde bir araya gelmektedirler. Derin öğrenme YSA'nın bir alt sınıfıdır.

YSA hesaplama modellerinin temelleri McCulloch ve Pitts (1943) tarafından yapılan ‘‘Sinir Sisteminin İçinde Olan Fikirlerin Mantıksal Hesabı’’ başlıklı makaleye dayanmaktadır [48]. YSA çalışmaları çok farklı alanlarda gerçekleştirilmiştir. YSA ile sınıflandırma, tahmin, veri yorumlama, veri ilişkilendirme ve veri filtreleme işlemlerinde kullanılmıştır.

YSA kullanım alanları şunlardır;

- Hesaplamalı finans,
- Bilgisayarla görü ve görüntü işleme,
- Doğal dil işleme,
- Enerji üretimi,
- Otomotiv, havacılık ve üretim,
- Hesaplamalı biyoloji.

3.1. Derin Öğrenme (Deep Learning)

Derin öğrenme bir makine öğrenmesinin alt sınıfıdır. Derin öğrenme, birçok katman kullanır. Her ardışık katman, önceki katman ile ilişki içindedir. Önceki katmandaki çıktıyı sonraki katman girdi olarak alır [49].


Grafik işlemci birimlerinin (GPU) hesaplamalarda kullanılması ile büyük gelişmeler gerçekleşmiştir. Hesaplama hızı, yaklaşık 1000 kat artmıştır. "Derin Öğrenme" (deep learning) ifadesi ilk kez 2000 yılında Igor Aizenberg ve arkadaşları tarafından kullanılmıştır [50].

GPU'lardan önce derin ağların ön-eğitime (pre-training) ihtiyaç duymuştur. GPU hızlarının artmasıyla birlikte bu ihtiyaç giderilmiştir. GPU hızlarının artması aynı zamanda kripto para üretimi işlemlerinde kullanılması yolunu açmıştır. Bu nedenle grafik kartları günümüzde fiyatları giderek artmıştır.

3.2. UKVHA (Uzun Kısa Vadeli Hafıza Ağları)

RNN mimarilerinde daha önceki bilgileri kullanmaya dayalı bir yöntem geliştirilmiştir. Örneğin “Ağaç toprakta yetişir” cümlesinde “toprak” kelimesini tahmin edilebilmiştir. Bağlamlar arası mesafe arttığında RNN modelin eski bilgiyi kullanması oldukça zorlaşmıştır. Örneğin, “İngiltere’de büyüdüm Akıcı bir şekilde İngilizce konuşurum.” gibi bir yazıda “İngilizce” kelimesini tahmin ederken, bir dil adı olacağını düşünülebilir. Fakat “İngilizce” kelimesini tahmin etmek için, yazının başındaki yer bilgisini hafızada tutmak gerekmektedir. Teoride “uzun-vadeli bağımlılıklar” mümkün olmuştur. Fakat pratikte büyük problemlere neden olduğu görülmüştür [51]. Bu büyük problemleri çözmek için, uzun vadeli bağımlılıkları öğrenebilen Uzun Kısa Vadeli Bellek (Long Short Term Memory-UKVHA) ağları Hochreiter ve Schmidhuber tarafından 1997 yılında sunulmuştur [52].

UKVHA mimarisi 3 kapıdan oluşmaktadır. Bu kapılar giriş, unutma ve çıkış kapılarıdır. Diğer sahip olduğu birimler ise Blok girişi, Sabit Hata Döngüsü, çıkış aktivasyon fonksiyonu ve gözetleme (peephole) bağlantılarıdır [53]. Bloğun çıktısı bloğun girişine ve tüm kapılarına bağlanır. İlk geliştirilen mimaride gözetleme bağlantıları ve unutma kapısı bulunmamıştır. Unutma kapısı UKVHA’nın kendi durumunu sıfırlamak için kullanılmıştır [54], kesin zamanlamaları öğrenmeyi kolaylaştırmak için ise gözetleme bağlantıları eklenmiştir [55]. UKVHA mimarileri konuşma/metin işleme gibi dilsel ifadeleri işleme konularında oldukça iyi sonuçlar vermiştir.



Şekil 3.1. UKVHA yapısı [56]

Şekil 3.1. UKVHA yapısı gösterilmiştir.

3.3. Trafik Kazalarının Önlenmesinde Yapay Sinir Ağı Modeli

Türkiye’de 2013-2020 yılları arasında kapsayan bir trafik kazası veri kümesi kullanılmıştır. Veriler, iki veri setinin birleştirilmesinden oluşturulmuştur. İlk veri seti, kaza tutanaklarına geçen olay yeri fiziksel koşulları bilgilerinden meydana gelmektedir. İkinci veri seti, kazaya karışan sürücüler ile ilgili bilgilerden meydana gelmektedir. Veri setlerindeki Kaza Yılı ile Kaza Id bilgileri birleştirilerek id (kaza kimlik numarası) oluşturulmuştur. Böylelikle iki veri seti hatasız birleştirilmiştir [57].

3.3.1. Veri seti

Veri kümesi 1,554,299 (1,55 milyon) satır ve 72 sütun içermektedir. Çizelge 3.1.’de veri seti sütun açıklamaları verilmiştir.

Çizelge 3.1. Veri seti özellikleri ve açıklamaları

Özellik	Veri Tipi	Tekil Sayı
Kaza Yılı	int64	7
Kaza Ayı	int64	12
Kaza Günü	int64	31
Kaza Saat Dakika	object	1440
Kaza İli	int64	81
Boylam	float64	474513
Enlem	float64	308218
Kaza Tarihi	int64	2556
Kaza Konumu	object	2
Yol Tipi	object	4
Kaldırım	object	6

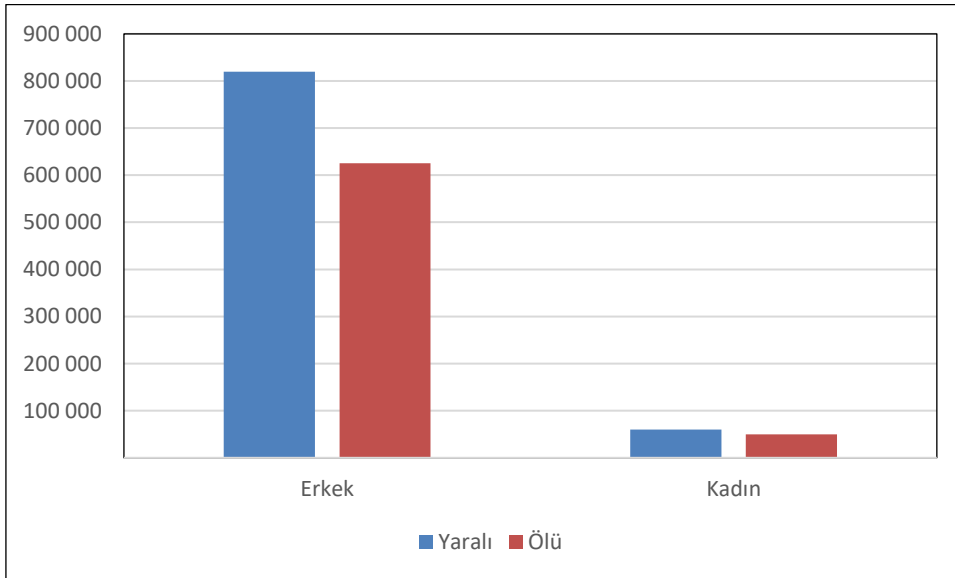
Çizelge 3.1. (devam) Veri seti özellikleri ve açıklamaları

Yol Sınıfı	object	26
Coğrafi Yatay	object	3
Coğrafi Dikey	object	4
Coğrafi Kavşak	object	8
Coğrafi Geçit	object	5
Coğrafi Diğer	object	8
Gün Durumu	object	3
Hava Durumu	object	10
Yol Yüzeyi	object	6
İlk Yardım	object	3
Kaza Oluş Türü	object	15
Kazaya Karışan Araç Sayısı	object	3
Çarpışma Bölgesi	object	24
Yol Hatası	object	8
Korkuluk	object	3
Kaldırım	object	3
Yaya Geçidi	object	3
Yol şeridi	object	3
Trafik İşareti	object	3
Trafik Lambası	object	3
Aydınlatma	object	3
Trafik Memuru	object	2
Görüşe Engel Cisim	object	2
Hasarlı Öge	object	2
Yol Çalışması	object	2
Ölü Sürücü	int64	4
Ölü Yolcu	int64	16
Ölü Yaya	int64	6
Yaralı Sürücü	int64	12
Yaralı Yolcu	int64	59
Yaralı Yaya	int64	16
Toplam Ölü	int64	16
Toplam Yaralı	int64	59
Ölümlü	int64	2
Yaralı	int64	2
Kaza Kimlik	int64	156846
geohash	object	83336
Periyot	object	494628
Araç Türü	object	19
Araç Kaza Sonrası Konumu	object	3
Araç Kullanım Amacı	object	7
Araç Hareketi	object	17
Araç Çarpma Bölgesi	object	15
Araç Kusuru 1	object	16

Çizelge 3.1. (devam) Veri seti özellikleri ve açıklamaları

Araç Kusuru 2	object	16
Araç Hasar Derecesi	object	6
Araç Yangını	object	3
Sürücü Yaşı	int64	99
Sürücü Cinsiyeti	object	2
Sürücü Ehliyeti	object	3
Sürücü Ehliyet Sınıfı	object	48
Sürücü Eğitim Durumu	object	6
Sürücü Alkol Ölçümü	object	3
Sürücü Alkol Değeri	object	12
Sürücü Durumu	object	5
Sürücü Emniyet Kemer	object	7
Sürücü Kaza Sonucu	object	4
Araç Kimlik	int64	260831
Sürücü Kusuru 1	object	36
Sürücü Kusuru 2	object	36
Kaza Şiddeti	int64	2


Bu çalışmada veri setindeki özellikler ve kaza sonucuna etkileri incelenmeye çalışılmıştır. Veri seti içinde kazaya karışan araç kimlik numarası bulunmaktadır. Bu özellik model eğitimi için anlamsız olduğundan veri seti içinden çıkartılmıştır.



Şekil 3.2. Cinsiyete göre kaza sayıları

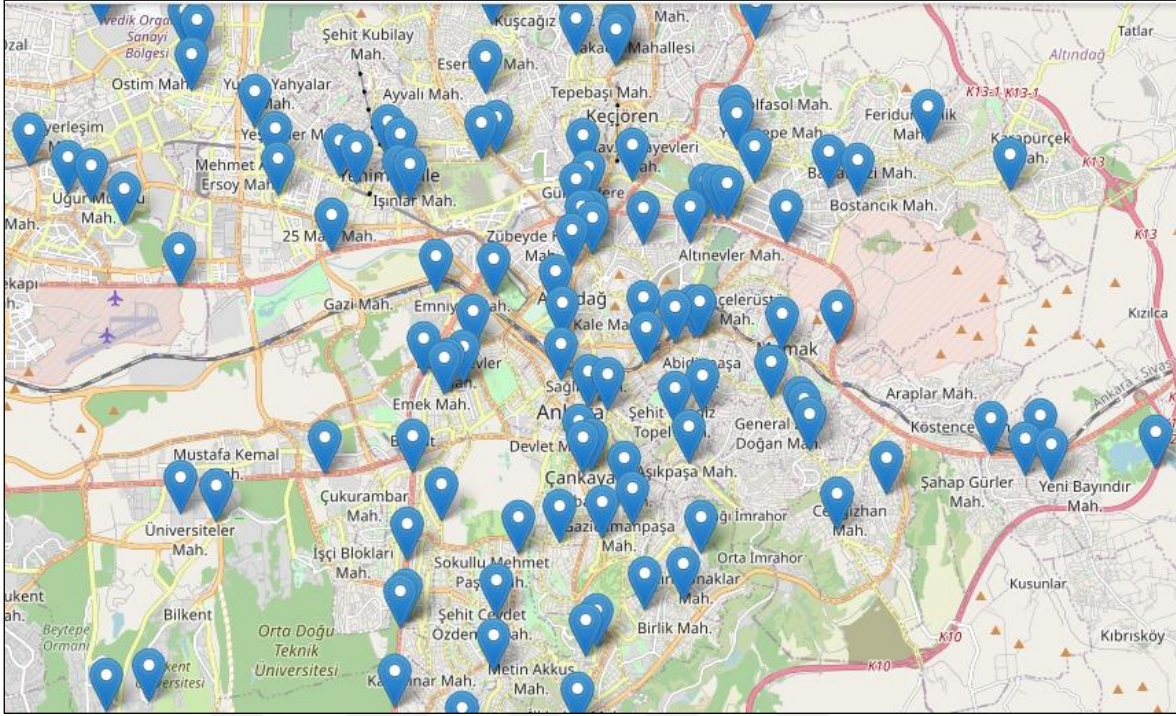
Şekil 3.2. cinsiyete göre kaza sayıları gösterilmiştir. Şekil 3.2.'e göre erkek sürücülerin %56'sı kaza sonu yaralı olarak kurtulmuşlardır. Erkek sürücülerde ölüm oranı %44 olarak gerçekleşmiştir. Kadın sürücülerde yaralı oranı %55, ölüm oranı ise %45 olarak gerçekleşmiştir. Toplam kazaların %92'sini erkek sürücüler gerçekleştirmiştir. Trafikteki

erkek oranını daha yüksek olması kazaya karışan erkek sayısının da yüksek olmasını sağlamıştır. Erkek ve kadınlarda ölüm, yaralanma oranları benzerlik göstermiştir. Bu da sürücünün cinsiyetinin kazalarda ölüm ve yaralanma sayılarını etkilemediğini göstermiştir.



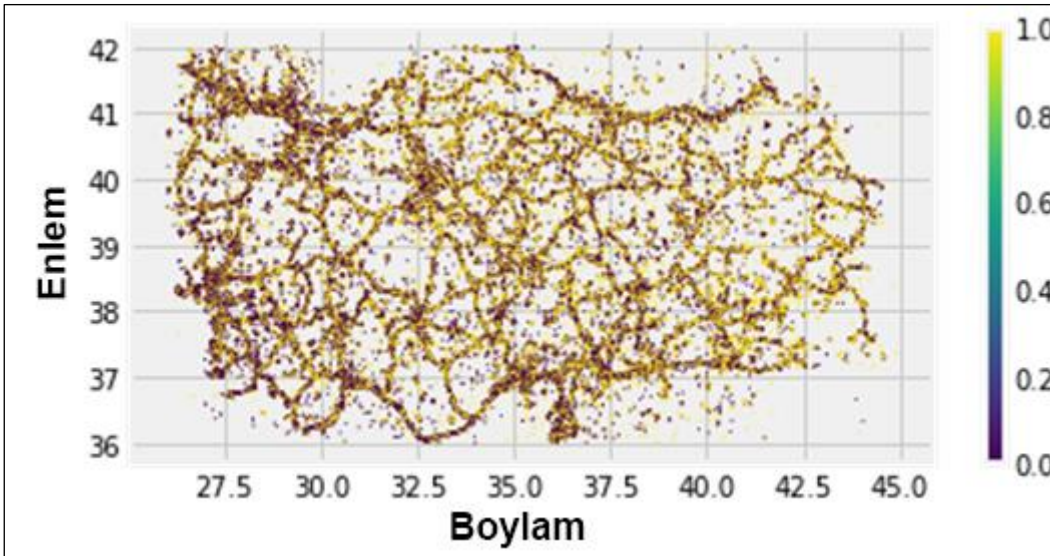
Şekil 3.3. Gün durumuna göre kaza sayıları

Şekil 3.3.'de gün durumuna göre kaza sayıları gösterilmiştir. Şekil 3.3.'de kazaların %68'sinin gündüz gerçekleştiği gösterilmiştir. Gece gerçekleşen kaza oranları %30, alacakaranlıkta ise %2 olarak gerçekleşmiştir. Toplam kaza sayılarının büyük oranını gündüz gerçekleşen kazalar oluşturmuştur. Gece ve alacakaranlıkta yaralı ve ölü oranları benzerlik göstermiştir. Gündüz gerçekleşen kazalarda yaralı kazaların sayısı daha yüksek olmuştur. Bu veriler kazaların görüş ile ilgili olmadığını göstermiştir.




Şekil 3.4. Ankara kaza noktaları

Şekil 3.4.'de Ankara kaza noktaları gösterilmiştir. Veri setindeki kaza noktaları harita üzerinde gösterildiğinde kazaların şehir merkezlerinde yoğunlaştığı görülmüştür. Şehir merkezindeki yollar genellikle daha geniş ve yol yüzeyleri daha az kusurludur. Bununla birlikte şehir merkezlerinde trafik yoğunluğu daha fazladır. Yol genişliği ve yol yüzey yapısının kazalara etkisinin trafik yoğunluğuna göre etkisinden daha az olduğu görülmüştür.




Şekil 3.5. Türkiye kaza noktaları

Şekil 3.5.'de Türkiye kaza noktaları gösterilmiştir. Tüm kaza noktaları bir şekil üzerinde gösterildiğinde anayol ve otoyollardan oluşan Türkiye haritası oluşmaktadır. Bu da bize kazaların daha çok anayol ve otoyollarda meydana geldiğini göstermiştir.



Şekil 3.6. Sürücü eğitim durumuna göre kaza sayıları


Şekil 3.6.'te yüksek öğrenim almamış sürücülerinin kaza oranlarının yüksek olduğu gösterilmiştir. Bu veriler eğitim seviyesinin kazalar ile ilişkili olabileceğini göstermiştir. Fakat toplum içindeki yüksek eğitim görmüş insanların sayısının az olduğu bilgisini unutulmamalıdır. Eğitim seviyesi ve kazalar ile ilgili daha ayrıntılı çalışmaların yapılması bu ilişkiyi ortaya koyacak bilgiler verebilecektir.



Şekil 3.7. Aylara göre kaza sayıları


Şekil 3.7.'de aylara göre kaza sayıları gösterilmiştir. Sonuçlara göre, kazaların çoğu yaz aylarında meydana gelmiştir. Ocak ve şubat aylarında en az kazalar gerçekleşirken, temmuz ve ağustos aylarında en fazla kazalar gerçekleşmiştir. Ülkemizde temmuz ve ağustos ayları sıcak ve yağışsız geçmektedir. Ocak ve şubat aylarında yağışlı olarak geçmektedir. Hava

durumdaki olumsuz durumların kaza sayılarında artışa neden olamadığı görülmüştür.



Şekil 3.8. Yerleşim yerine göre kaza sayıları

Şekil 3.8.'de Yerleşim yerine göre kaza sayıları gösterilmiştir. Yerleşim yerlerinde kazalar daha fazla gerçekleşmiştir. Buna karşılık yerleşim yeri dışındaki ölüm oranları daha fazla olmuştur. Yerleşim yerlerindeki trafik yoğunluğu yerleşim dışındaki trafik yoğunluğuna göre daha fazladır. Trafik yoğunluğu fazla olan yerlerde kaza ihtimalinin daha yüksek olduğu gösterilmiştir. Yerleşim yeri dışındaki ölüm oranlarının fazlalığı araç hızlarının daha yüksek olmasından kaynaklandığı düşünülmektedir. Veri setinde araç hız bilgisi bulunmamaktadır. Araç hızı ve kazalar ile ilgili araştırmaların yapılması bu ilişkiyi ortaya koyabilecektir.

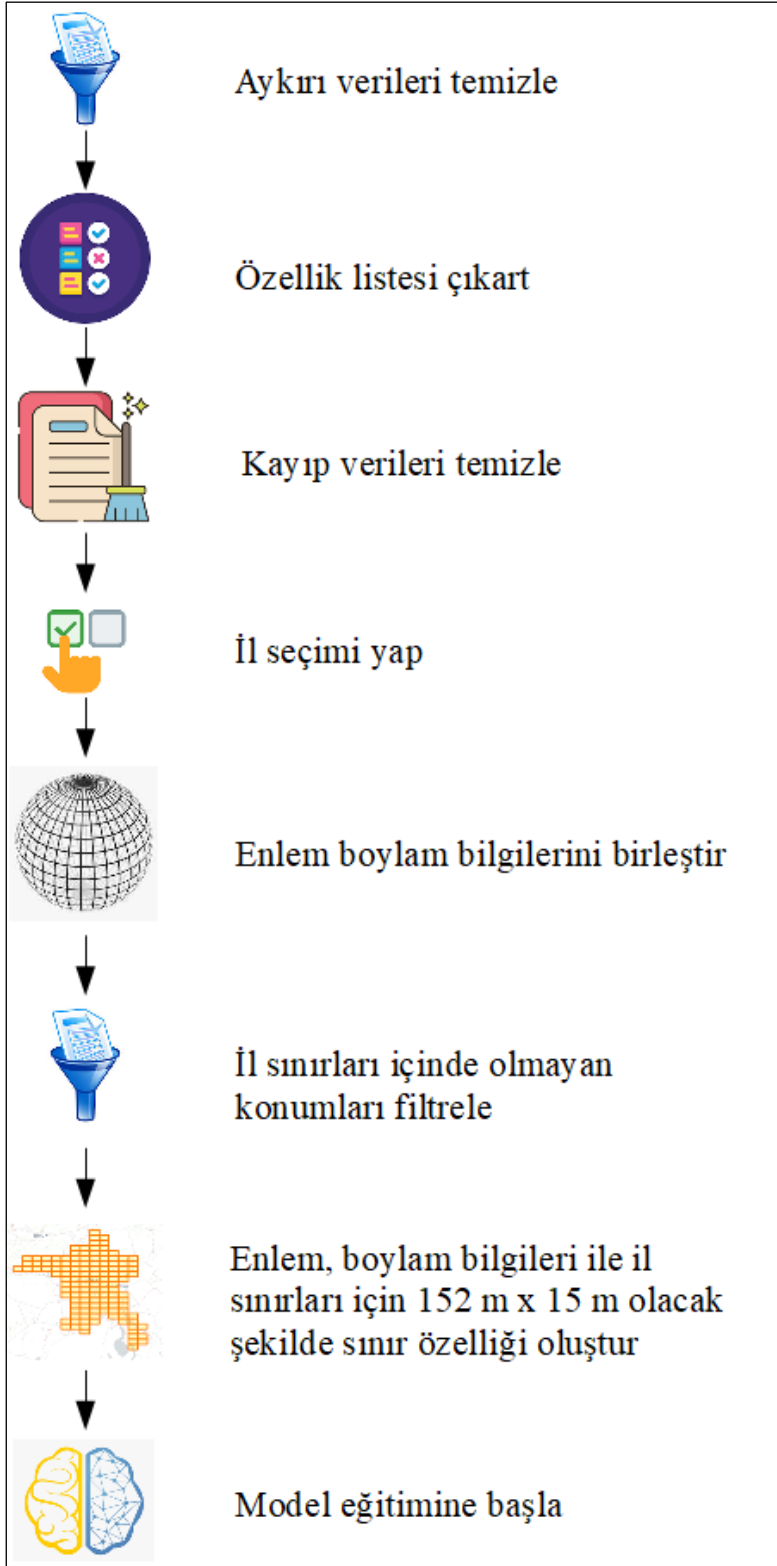


Şekil 3.9. Kaza sayısı ile hava durumu karşılaştırması

Şekil 3.9.'da kaza sayısı ile hava durumu karşılaştırması gösterilmiştir. Bu veri setine dayanarak, kazaların çoğu açık hava koşullarında meydana gelmiştir. Açık günlerin en yüksek yüzdesinin sürücülerin iyi hava koşullarında yola daha az dikkat etme eğiliminde olmasından kaynaklanabileceği düşünülmüştür (Şekil 3.9.). Kötü hava koşulları altındayken, insanlar sürüş sırasında daha dikkatli olabileceği, bu nedenle daha az kaza olabileceği tezi ortaya çıkmıştır.

3.4. Veri işleme

Kazaların derin öğrenme ile analizini yapmak için ilk önce verilerin ön işlemden geçmesi gerekmektedir. Veri seti içindeki özellikler incelenmiştir. Bu özelliklerden bazılarının hatalı, bazılarının eksik olduğu gözlenmiştir.



Şekil 3.10. Veri işleme akış diyagramı

Şekil 3.10.'da veri işleme akış diyagramı gösterilmiştir.

3.4.1. Aykırı deęerleri temizleme

Veri setinde bazı enlem ve boylam bilgileri Türkiye dıřı konumları göstermiřtir. Bu veriler yanlış olarak deęerlendirilerek veri setinden ıkarılmıřtır. Enlem ve boylam bilgileri kazanın olduęu yeri vermiřtir. Kaza noktası bilgisi geliřtirilecek model iin nemli olduęu dřnlmřtr. Bu nedenle aykırı olan veriler veri setinden temizlenmiřtir.

3.4.2. zellik listesinin ıkarılması

Makine ğrenimi iin 10 tane zellik nemli olarak belirlenmiřtir. Veri seti bu řekilde tekrardan dzenlenmiřtir. Bu zellikler Kaza Ayı, Yolun Tipi, Hava Durumu, Gn Durumu, Src Yařı, Src Cinsiyeti, Src Ehliyet Sınıfı, Src ğrenim Durumu, Tatil Durumu ve Kaza Konumu'dur. Farklı zellikler ıkartılarak farklı modeller de gerekleřtirilmiřtir. Fakat en iyi bařarımı bu 10 zellik vermiřtir.

3.4.3. Kayıp verilen temizlenmesi

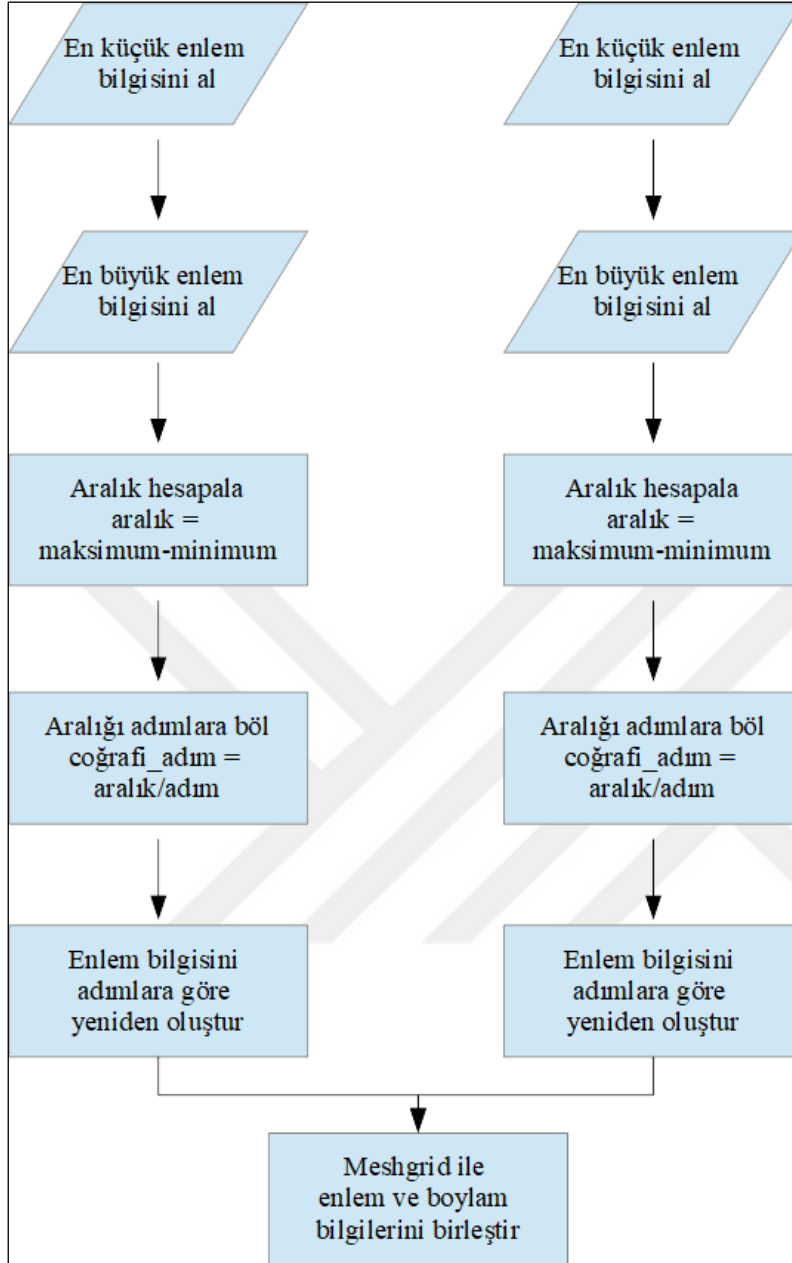
Veri seti ierisindeki veri bulunmayan satırlar temizlenmiřtir. Temizleme sonucunda 1,663,631 satır veri kalmıřtır. Trafik kaza tutanakları dzenlenirken veya sisteme girilirken bazı veriler girilmemiřtir. Bu da veri setindeki tutarlılıęı etkilemiřtir. Veri setinin model eęitimi iin yeterli olduęundan kayıp verilerin ortalama deęerlerle doldurulması yntemine gidilmemiřtir.

3.4.4. İl seimi

Sınırlı kaynaklardan dolayı makine ğrenmesinin gerekleřtirilmesi iin tm kayıtlar zerinde deęil de sadece belirli bir ilde gerekleřtirilmesi uygun grlmřtr. İl olarak Ankara seilmiřtir.


3.4.5. Konum bilgilerinin iřlenmesi

Veri seti iinde kaza konum bilgileri enlem ve boylam olarak verilmiřtir. Bazı kaza konum noktaları kazanın tam konumunu vermemiřtir. Aynı zamanda boylam ve enlem ikilisi veri seti iinde kaza bilgilerini tekil hale getirmiřtir. Birbirine ok yakın olan iki kaza noktası model eęitiminde farklı yerler algılanacaktır. Bu nedenle enlem ve boylam ikilisi bir araya getirilerek kaza blgesi verisi retilmiřtir.



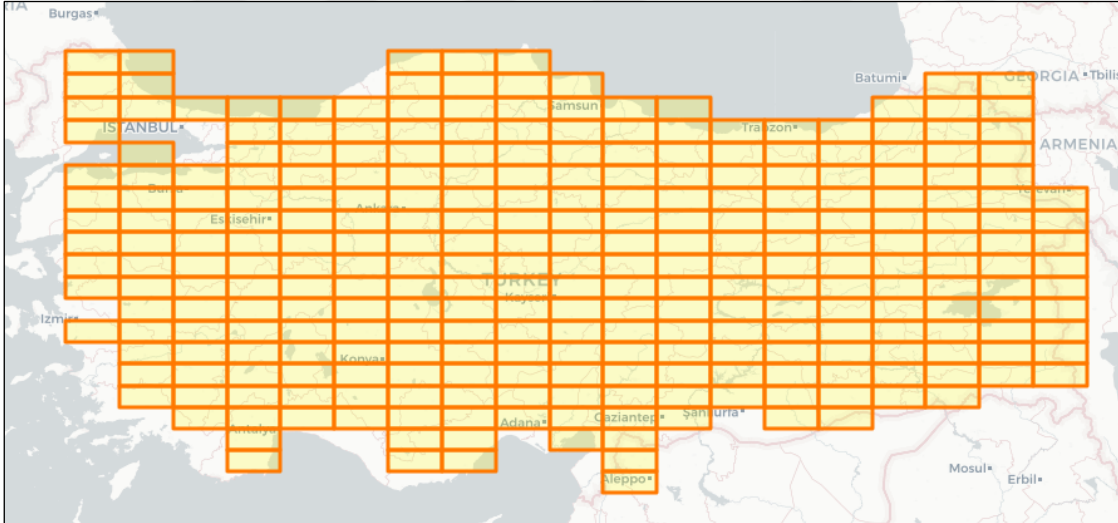
Şekil 3.11. Kaza konum bölgeleri algoritması

Şekil 3.11.'da Kaza konum bölgeleri algoritması gösterilmiştir. Veri seti içindeki kaza bölgeleri yakınlık derecesine göre gruplar halinde ele alınmıştır. Harita üzerindeki konumlar 152m x 152m olacak şekilde gruplandırılmıştır. MeshGrid fonksiyonu NumPy kütüphanesi içinde yer alan bir fonksiyondur. MeshGrid fonksiyonu parametre olarak aldığı x ve y vektörleri ile verilen alanı birleştirir.



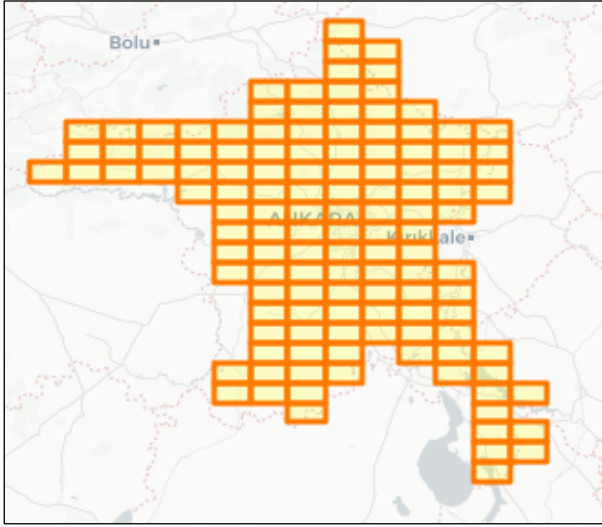
Şekil 3.12. Kaza konum bölgeleri

Şekil 3.12.'de kaza konum bölgeleri gösterilmiştir. Veri seti içindeki kaza bölgeleri yakınlık derecesine göre gruplar halinde ele alınmıştır. Harita üzerindeki konumlar 152m x 152m olacak şekilde gruplandırılmıştır.



Şekil 3.13. Kaza konum bölgeleri filtreleme

Şekil 3.13.'de kaza konum bölgeleri filtreleme gösterilmiştir. Kaza konum bölgelerinden bazıları Türkiye haritası dışındaki bölgeleri göstermiştir. Bu bölgelerin modelin eğitilmesinde zorluklara yol açacağı düşünülmüştür. Bu nedenle Türkiye haritası üzerinde yer almayan bölgeler filtrelenerek veri seti düzenlenmiştir.



Şekil 3.14. Ankara ili kaza konum bölgeleri filtreleme

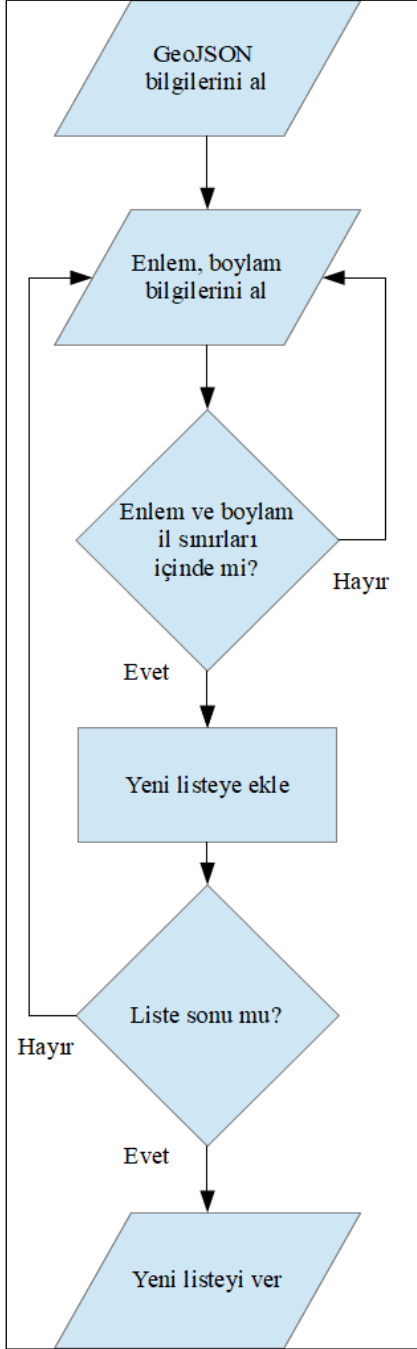
Şekil 3.14.'de Ankara ili kaza konum bölgeleri filtreleme gösterilmiştir. Uygulamanın Ankara ili üzerinde hazırlanması kaynakların kullanılması için faydalı olacağı düşünülmüştür. Bu nedenle Ankara ili üzerinde yer almayan bölgeler filtrelenerek veri seti düzenlenmiştir.

GeoJSON dosyası içine coğrafi konum bilgileri Javascript Object Notation (JSON) formatında kaydedilmiştir. Ankara iline ait sınır bilgileri bu geojson dosyasına yüklenmiştir. Böylelikle veri seti içinde yer alan Ankara iline ait kazalar konum bilgilerine bakılarak filtrelenmiştir. Örnek bir GeoJson dosya içeriği aşağıda gösterilmiştir.

```

“geojson”:{
  “type”:”Polygon”,
  “coordinates”:[[[[30.8361038,40.0978711],[30.8376802,40.0945734],
  [30.8410489,40.0927368],[30.8437006,40.0914889],[30.8445024,40.0877906],[30.
  8472489,40.0839163],
  .....]]
}

```




Şekil 3.15. Filtreleme algoritması

Şekil 3.15.'de filtreleme algoritması gösterilmiştir.


3.4.6. Makine öğrenme algoritmaları ile kaza şiddetini tahmin etme

Makine öğrenmelerinde Random Forest, Decision Trees, Logistic Regression ve K-Nearest Neighbors kullanılmıştır. Doğruluk başarımları Şekil 3.10.'de gösterilmiştir.




Şekil 3.16. Makine öğrenimlerinin birbirleriyle karşılaştırılması

Şekil 3.16.'da Makine öğrenimlerinin birbirleriyle karşılaştırılması gösterilmiştir. En iyi sonucun önerdiğimiz UKVHA modeli, daha sonra ise YSA algoritmasının aldığı bulunmuştur.



Şekil 3.17. Modelin doğruluk puanı

Şekil 3.17.'de modelin doğruluk puanı gösterilmiştir.



Şekil 3.18. Epoch doğruluk

Şekil 3.18.'de epoch doğruluk grafiği gösterilmiştir.

3.5. Mobil Uygulama

Kazaların tahmini için derin öğrenme modelinin kullanılacağı bir mobil uygulama gerçekleştirilmiştir. Bu uygulama ile araç sürücüsü güzergâh üzerindeki kaza riskinin yüksek olduğu konumları öğrenebilecektir. Günümüzde sürücülerin büyük bir çoğunluğunda mobil cihazlar bulunmaktadır. Araca yeni bir cihazın tasarlanması yerine mevcut mobil cihazların kullanılması daha pratik olacağı düşünülmüştür.

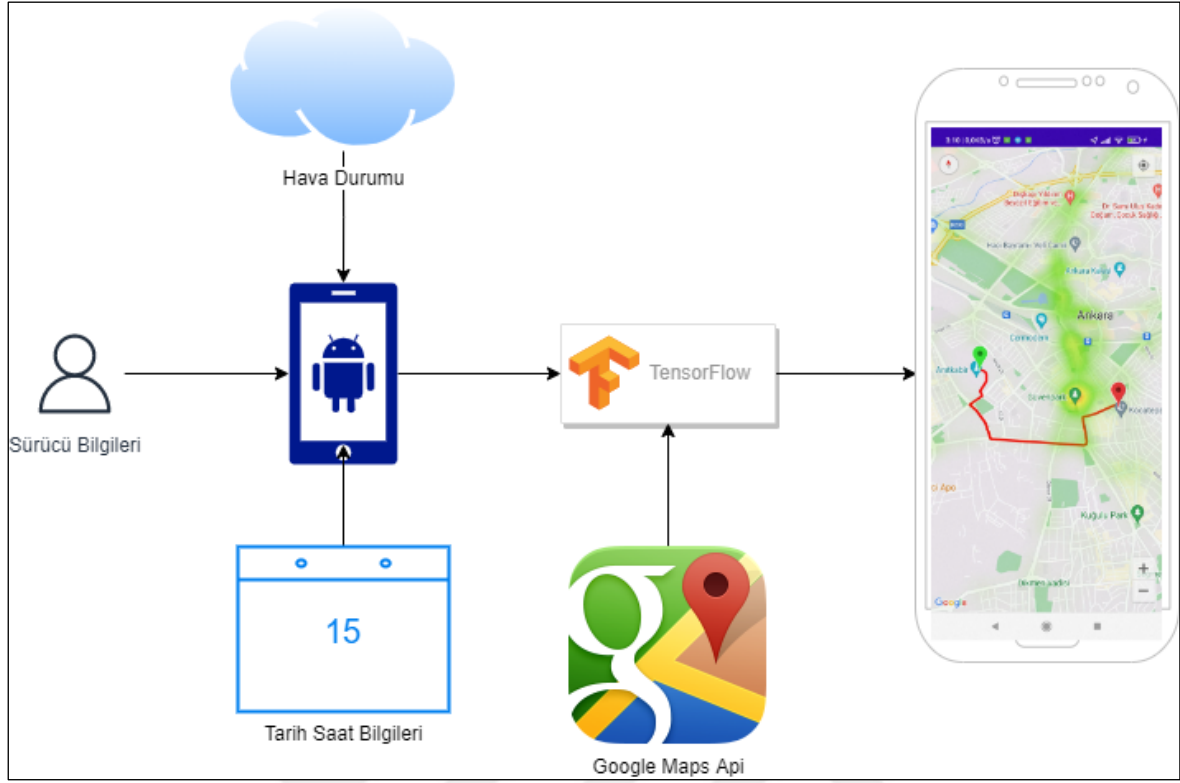
Derin öğrenme ile ilgili çalışma yapmak için birçok kütüphane geliştirilmiştir. En çok kullanılan kütüphanelerden biri Google firması tarafından geliştirilen TensorFlow kütüphanesidir. Açık kaynak kodlu ve esnek bir yapıya sahip olacak şekilde geliştirilmiştir. Python, Java, C++, C#, Javascript ve R gibi birçok dilleri desteklemektedir. TensorFlow kütüphanesinin yaygın olarak kullanılmasının nedenlerinden biri de mobil, web ve IoT platformlarında kullanılmasıdır.

Mobil cihazda derin öğrenme modeliyle bir tahmin gerçekleştirmek için TensorFlow Lite kullanılmıştır. TensorFlow Lite, geliştiricilerin modellerini mobil, gömülü ve uç cihazlarda

çalıştırmasına yardımcı olarak cihaz üzerinde makine öğrenimi sağlayan bir araç setidir[58]. Modelin mobil cihazda kullanılması için tflite uzantılı TensorFlow Lite modeline dönüştürülmesi gerçekleştirilmiştir.

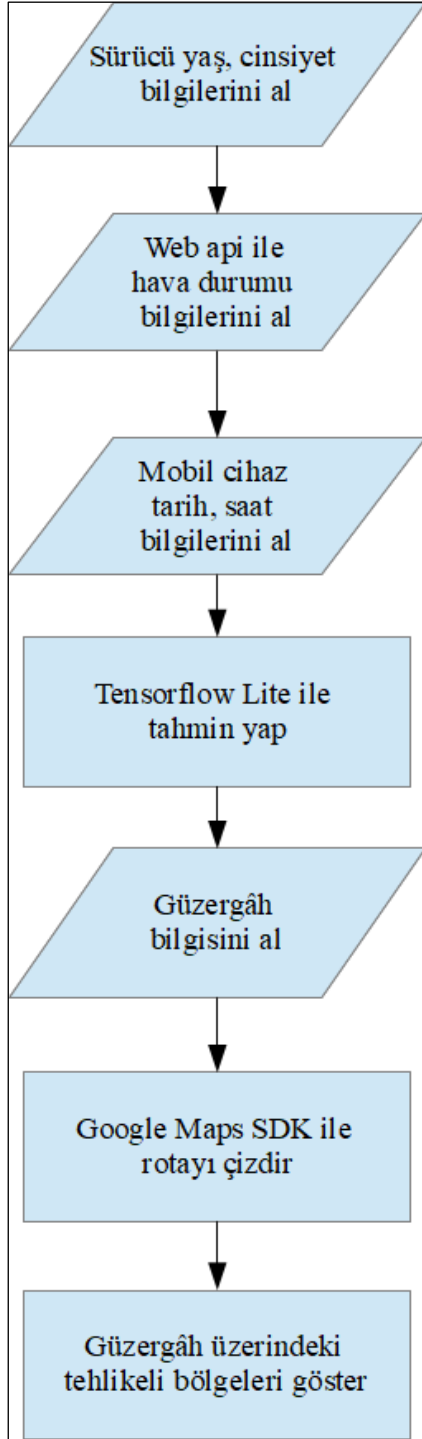
Modelin eğitim işlemi bulut tabanlı bir platform olan Google Colab üzerinde gerçekleştirilmiştir. Google Colab, derin öğrenme çalışmalarını bulut üzerindeki bilgisayarlar üzerinde gerçekleştirilmesini sağlayan programlama ortamıdır. Derin öğrenme çalışmalarını gerçekleştirmek için yüksek işleme kabiliyetine sahip grafik kartları gerekmektedir. Günümüzde oyun, derin öğrenme ve kripto para üretme işlemleri için işlem kapasitesi yüksek ekran kartlarına ihtiyaç duyulmaktadır. Bu ihtiyaçlardan dolayı ekran kartları fiyatları yüksektir. Google Colab, bu işlem yüksek gücüne sahip ekran kartlarını satın almadan bulut üzerinden çalıştırılmasını sağlayan bir hizmet sunmaktadır.

Google Maps en çok kullanılan harita navigasyon uygulamalarından biridir. Google firması geliştiricilerin Google Maps'i kullanmaları için SDK yayınlamaktadır. Bu çalışmada Google firmasının Google Maps SDK'sı kullanılmıştır. Google Maps SDK'sı mobil cihazlar içerisine Google haritaların kullanılmasını sağlayan bir SDK'dır. Google Maps SDK'sı ile mobil cihazlara harita eklenebilir, iki nokta arasında gidilecek güzergâh çıkartılabilir.



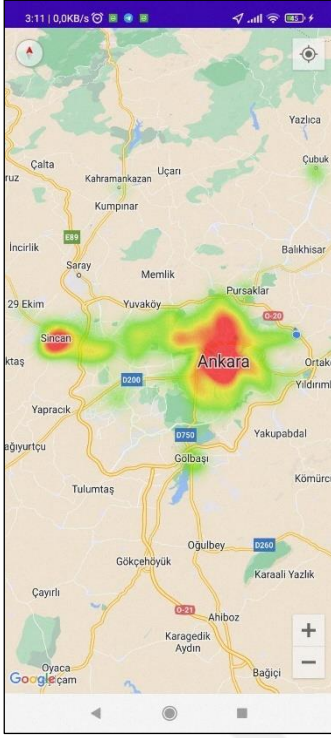
Şekil 3.19. Uygulama çalışma şeması

Şekil 3.19.'da uygulama çalışma şeması gösterilmiştir.



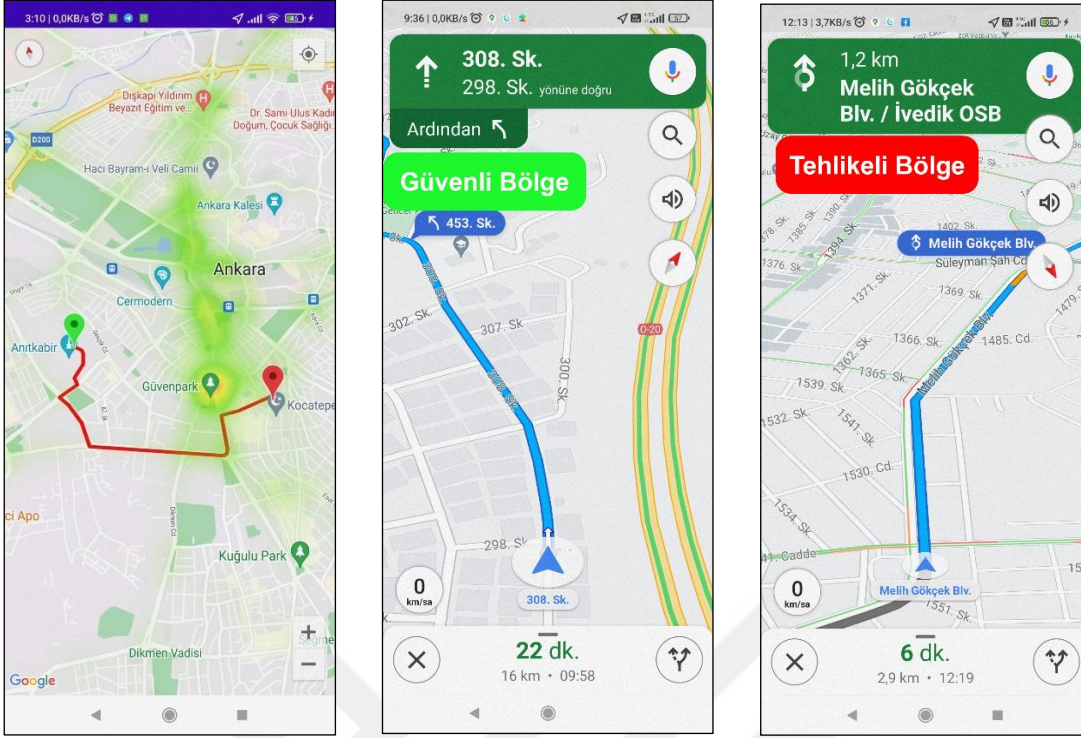
Şekil 3.20. Uygulama akış diyagramı

Şekil 3.20.'de uygulama akış diyagramı gösterilmiştir. Uygulama içinde sürücüye ait yaş, cinsiyet, öğrenim durumu ve ehliyet sınıfı bilgileri alınmıştır. Günün tarih saat bilgileri ile internet üzerinden hava durumu bilgileri toplanmıştır. Bu bilgiler TensorFlow Lite uygulamasına veri olarak gönderilmiştir. TensorFlow Lite, Google Maps Api'den gelen güzergâh bilgileri ile bir çıkarım gerçekleştirmiştir. Daha sonra bu çıkarıma göre güzergâh üzerindeki olası kaza kara noktalarını şiddetine göre göstermiştir.



Şekil 3.21. Uygulama ısı haritası

Şekil 3.21.'de Uygulama ısı haritası gösterilmiştir. Uygulama çalıştırıldığında sürücü kişisel bilgileri, hava durumu ve tarih saat bilgileri otomatik olarak uygulamaya yüklenmiştir. Mobil cihazın konumuna göre o andaki kaza risk haritası ısı haritası ile gösterilmiştir.



Şekil 3.22. Uygulama güzergâh ekranları

Şekil 3.22.'de uygulama güzergâh ekranları gösterilmiştir. Sürücünün gideceği konum seçildikten sonra Google Maps SDK'sı ile güzergâh çizdirilmiştir. Güzergâh üzerindeki kaza kara noktalarının ısı haritasıyla gösterilmesiyle sürücünün dikkatinin çekilmesi amaçlanmıştır. Güzergâh üzerindeki kırmızı bölgeler kaza riskinin yüksek olduğu yerleri göstermiştir.



5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında yapılan trafik kazalarını önlemek için Derin Öğrenme modelleri, gerçek kaza verileri kullanılarak, seyahat edilmesi planlanan bir güzergâh üzerindeki noktaların risk değerlendirmesini yapan bir yaklaşımdır. Türkiye’de meydana gelmiş yaklaşık 2 milyon kaza verisi kullanılmıştır. Bu veri seti hava durumu gibi çevresel faktörleri de içermektedir.

Veri seti üzerinde analizler yapılarak önemli özellikler bulunmuştur. Öğrenmeyi güçleştirecek veya hatalı sonuç verecek veriler temizlenmeye çalışılmıştır. Kazanın oluş zamanı kullanılarak dakika, saat, haftanın günü, ay, yıl özellikleri veri setine eklenmiştir. Tüm veriler yerine belirli bir il üzerindeki trafik kazaları olayları incelenmesi uygun görülmüştür.

Veri seti üzerindeki kategorik veriler kukla değişkenlere dönüştürülmüştür. Bu çalışmada çeşitli derin öğrenme modelleri kullanılarak karşılaştırılmaları yapılmıştır. Bunlar RF, DT, LR, K-NN ve UKVHA’dır. Sırasıyla doğruluk puanları 0,78; 0,67; 0,72; 0,81; 0,87 bulunmuştur. En iyi sonuçları K-NN ve UKVHA vermiştir.

Literatür çalışmalarından gözlemlendiği kadarıyla sadece tek bir öğrenme algoritmasına bağlı kalmayıp birçok öğrenme metodunun uygulandığı modeller yüksek başarı elde etmiştir. Yapılan analizlerden yola çıkılarak halk üzerindeki genel kanının aksine kazaların kötü hava koşullarında değil de görüşün açık olduğu iyi hava koşullarında gözlenmiştir. Trafiğin yoğun olduğu yerlerden çok trafiğin açık olduğu yerlerde kaza sayıları fazla olduğu gösterilmiştir. Kavşaklarda ve yaya geçitlerinde kaza oranları yüksek çıkartılmıştır. Aynı zamanda Emniyet Genel Müdürlüğü’nden elde edilen bilgilere göre kaza unsur oranları daha çok sürücü kaynaklı olduğu gösterilmiştir.

Bu verilerden yola çıkılarak trafikte en önemli unsurun dikkat olduğu ortaya çıkmaktadır. Sürücü, yolun ve hava durumunun iyi olmasına aldanarak dikkatini azaltmaktadır. Bu dikkatsizlik sonucu kazaların büyük bir çoğunluğu meydana gelmektedir.

Bu tez çalışması içinde yer alan literatür çalışmalarında trafik akış hızı, trafik sıkışıklığı, trafik kazası sonrası yaralanma şiddeti, yaralı/ölü sayısı, kazaya etki eden faktörler ve kaza kara noktaları üzerine çalışmalar yapılmıştır. Bu çalışmaların hepsi trafik kazalarının tahmini ve kazaların önlenmesi açısından çok önemlidir. Ama bu çalışmaların çoğu teoride kalıp, pratikte bir uygulamaya dönüşmemiştir. Bu tez çalışması derin öğrenme

yöntemlerini kullanarak teorik olarak kaza kara noktalarını belirlemiştir. Aynı zamanda bu tez çalışması mobil uygulama ile sürücünün güzergâhı üzerindeki dikkat etmesi gereken yolların gösterilmesiyle pratik bir uygulamaya dönüştürülmüştür.

İleride yapılacak çalışmalar için kaza kara noktaları tespitiyle beraber sürücünün sürüş özellikleri ve dikkat seviyesi ölçümü gibi değerlerin incelenmesi daha iyi sonuçlar çıkartacaktır. Mobil cihazlara, uyku/stres durumu, hız gibi bilgileri algılayacak sensörler bağlanması kaza tahminini daha iyi duruma getirecektir. Trafik kazalarına yönelik yapılan bu tür çalışmaların ülkemizde daha fazla yapılması trafik kazalarının azaltılması yönünde başarılar sağlanacaktır.



KAYNAKLAR

1. Kıran, S. Şemin, S. ve Ergör, A. (2001). "Kazalar ve toplum sağlığı yönünden önemi", *Sürekli Tıp Dergisi*, 10(2), 50-51.
2. Bilim, A. (2006). *Konya Şehir İçinde Meydana Gelen Kazaların Analizi ve Kritik Noktaların Belirlenmesi*, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimler Enstitüsü, Konya.
3. İnternet: Türkiye İstatistik Kurumu, Karayolu Trafik Kaza İstatistikleri.URL: <https://data.tuik.gov.tr/Bulten/Index?p=Karayolu-Trafik-Kaza-Istatistikleri-2021-45658>, Son Erişim Tarihi: 30.05.2022.
4. İnternet: Trafikte Sorumluluk Hareketi.URL: <http://trafikhareketi.org/raporlar.aspx>, Son Erişim Tarihi: 15.06.2020.
5. İnternet: Emniyet Genel Müdürlüğü Trafik Kaza İstatistikleri.URL: <http://trafik.gov.tr/istatistikler37>, Son Erişim Tarihi: 01.05.2022.
6. Doğan, E. (2007). *Regresyon analizi ve yapay zekâ yaklaşımı ile Türkiye ve seçilen bazı büyük illeri için trafik kaza tahmin modelleri*, Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale, 1-100.
7. Kibar, F. T. (2008). *Trafik kazaları ve Trabzon bölünmüş sahil yolu örneğinde kaza tahmin modelinin oluşturulması*, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.
8. Mirasyedi, F. (2006). *Mevsimlerin Türkiye'deki trafik kazalarına etkisinin incelenmesi ve kaza tahmin modelleri*, Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
9. Çodur, M. Y. (2012). *Trafik kaza tahmin modelleri: Erzurum ili çevre karayolları için uygulamalar*, Doktora Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum.
10. Yıldırım, U. (2014). *Ankara'da şehir içinde meydana gelen trafik kazalarının analizi, kritik noktaların belirlenmesi ve bir yapay sinir ağı ile modellenmesi*, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
11. Parıldar, O. (2014). *Trafik kazalarının sınıflandırılmasında karar ağacı kullanımı: Bodrum ilçesi örneği*, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
12. Bolakar, H. (2014). *Yapay sinir ağları ile trafik kazalarının modellenmesi: Erzurum ili örneği*, Yüksek Lisans Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum.
13. Bekin, M. E. (2018). *Trafik kazası olma olasılığının hesaplanması*, Yüksek Lisans Tezi, Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

14. Kaya, T. (2015). *Makine öğrenme yöntemleri ile trafik kazaları için risk tahmini yapabilen web tabanlı bir yazılım*, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara.
15. Çiçek, B. T. (2014). *Erzurum şehir içi trafik kazalarının analizi ve çözüm önerileri*, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimler Enstitüsü, Ankara.
16. Ögün, S. (2015). *Analysis of fatal and injury crashes by geographical information systems: A case study of Gaziantep*, M.Sc. Thesis, University of Gaziantep Graduate School Of Natural And Applied Sciences, Gaziantep.
17. Dedeoğlu, O. K. (2016). *Trafik kazalarının azaltılmasında kent bilgi sistemlerinden yararlanılması: Kahramanmaraş ili örneği*, Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
18. Dereli, M. A. (2016). *Trafik kaza kara noktalarının belirlenmesi için coğrafi bilgi sistemleri (CBS) destekli mekânsal istatistiksel metotlar ile bir model geliştirilmesi*, Bütünleşik Doktora Tezi, Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Afyon.
19. Çalınacı, H. (2016). *Trafik kaza araştırmalarında bilgisayar yazılımlarının kullanımı*, Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta.
20. Taha, R. T. (2017). *The study of traffic fatal crashes based on time series model*, M.Sc. Thesis, Van Yüzüncü Yıl University Institute Of Natural And Applied Sciences, Van.
21. Özkoç, A. K. (2019). *Trafik kazaları suiistimalleri tespiti için ağ bilimi temelli bir karar destek sistemi geliştirilmesi*, Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
22. Önder, Y. E. (2019). *İstanbul ilinde trafik kaza ve yoğunluk analizlerinin açık kaynak kodlu CBS yazılımları ile yapılması*, Yüksek Lisans Tezi, Gebze Üniversitesi Fen Bilimleri Enstitüsü, Gebze.
23. Kılıçarslan, S. (2019). *Trafik kazalarına yönelik erken uyarı sistemi*, Yüksek Lisans Tezi, Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
24. Bolat, H. (2019). *Kayseri il emniyet müdürlüğü trafik kaza verilerinin veri madenciliği yaklaşımları ile analizi*, Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
25. Delen, D., Sharda, R., & Bessonov, M. (2006). Identifying significant predictors of injury severity in traffic accidents using a series of artificial neural networks. *Accident Analysis & Prevention*, 38(3), 434-444.
26. Xie, Y., Lord, D., & Zhang, Y. (2007). Predicting motor vehicle collisions using Bayesian neural network models: An empirical analysis. *Accident Analysis & Prevention*, 39(5), 922-933.

27. Rodríguez, J., Jattin, J., & Soracipa, Y. (2020). Probabilistic temporal prediction of the deaths caused by traffic in Colombia. Mortality caused by traffic prediction. *Accident Analysis & Prevention*, 135, 105332.
28. Li, P., Abdel-Aty, M., & Yuan, J. (2020). Real-time crash risk prediction on arterials based on LSTM-CNN. *Accident Analysis & Prevention*, 135, 105371.
29. Parsa, A. B., Movahedi, A., Taghipour, H., Derrible, S., & Mohammadian, A. (Kouros). (2020). Toward safer highways, application of XGBoost and SHAP for real-time accident detection and feature analysis. *Accident Analysis & Prevention*, 136, 105405.
30. Amin, S. (2020). Backpropagation – Artificial Neural Network (BP-ANN): Understanding gender characteristics of older driver accidents in West Midlands of United Kingdom. *Safety Science*, 122, 104539.
31. Mokhtarimousavi, S., Anderson, J. C., Azizinamini, A., & Hadi, M. (2020). Factors affecting injury severity in vehicle-pedestrian crashes: A day-of-week analysis using random parameter ordered response models and Artificial Neural Networks. *International Journal of Transportation Science and Technology*, 9(2), 100-115.
32. George, S., & Santra, A. K. (2020). An improved long short-term memory networks with Takagi-Sugeno fuzzy for traffic speed prediction considering abnormal traffic situation. *Computational Intelligence*, coin.12291.
33. Moosavi, S., Samavatian, M. H., Nandi, A., Parthasarathy, S., & Ramnath, R. (2019). Short and Long-term Pattern Discovery Over Large-Scale Geo-Spatiotemporal Data. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2905-2913.
34. Abdelwahab, H. T., & Abdel-Aty, M. A. (2001). Development of Artificial Neural Network Models to Predict Driver Injury Severity in Traffic Accidents at Signalized Intersections. *Transportation Research Record: Journal of the Transportation Research Board*, 1746(1), 6-13.
35. Boulieri, A., Liverani, S., de Hoogh, K., & Blangiardo, M. (2017). A space-time multivariate Bayesian model to analyse road traffic accidents by severity. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 180(1), 119-139.
36. Do, L. N. N., Taherifar, N., & Vu, H. L. (2019). Survey of neural network-based models for short-term traffic state prediction. *WIREs Data Mining and Knowledge Discovery*, 9(1).
37. Liu, Q., Liu, J., Wu, X., Han, X., & Guan, F. (2019). Evaluation and prediction of diffuse axonal injury based on optimization strategy in vehicle collision accidents. *Structural and Multidisciplinary Optimization*, 60(4), 1491-1508.

38. Twala, B. (2014). Extracting grey relational systems from incomplete road traffic accidents data: The case of Gauteng Province in South Africa. *Expert Systems*, 31(3), 220-231.
39. Zhang, X., Waller, S. T., & Jiang, P. (2020). An ensemble machine learning-based modeling framework for analysis of traffic crash frequency. *Computer-Aided Civil and Infrastructure Engineering*, 35(3), 258-276.
40. Li, L., Sheng, X., Du, B., Wang, Y., & Ran, B. (2020). A deep fusion model based on restricted Boltzmann machines for traffic accident duration prediction. *Engineering Applications of Artificial Intelligence*, 93, 103686.
41. Liu, Y., Wu, C., Wen, J., Xiao, X., & Chen, Z. (2022). A Grey Convolutional Neural Network Model for Traffic Flow Prediction under Traffic Accidents. *Neurocomputing*, 500, 761–775
42. Zheng, G., Chai, W. K., Katos, V., & Walton, M. (2021). A joint temporal-spatial ensemble model for short-term traffic prediction. *Neurocomputing*, 457, 26-39.
43. Song, X., Li, W., Ma, D., Wang, D., Qu, L., & Wang, Y. (2018). A Match-Then-Predict Method for Daily Traffic Flow Forecasting Based on Group Method of Data Handling: A match-then-predict method for daily traffic flow forecasting based on group method of data handling. *Computer-Aided Civil and Infrastructure Engineering*, 33(11), 982-998.
44. Shaik, Md. E., Islam, Md. M., & Hossain, Q. S. (2021). A review on neural network techniques for the prediction of road traffic accident severity. *Asian Transport Studies*, 7, 100040.
45. Moosavi, S., Samavatian, M. H., Parthasarathy, S., Teodorescu, R., & Ramnath, R. (2019). Accident Risk Prediction based on Heterogeneous Sparse Data: New Dataset and Insights. *Proceedings of the 27th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 33-42.
46. Briz-Redón, Á., Iftimi, A., & Montes, F. (2022). Accounting for previous events to model and predict traffic accidents at the road segment level: A study in Valencia (Spain). *Physica A: Statistical Mechanics and Its Applications*, 585, 126416.
47. Ma, Z., Mei, G., & Cuomo, S. (2021). An analytic framework using deep learning for prediction of traffic accident injury severity based on contributing factors. *Accident Analysis & Prevention*, 160, 106322.
48. McCulloch, W. S., & Pitts, W. A. (1943). A logical calculus of the ideas immanent in nervous activity. *Buttetin of Mathematics and Biophysics*, 5, 115-133.
49. Deng, L., & Yu, D. (2014). Deep Learning: Methods and Applications. *Foundations and Trends® in Signal Processing*, 7(3-4), 197-387.

50. Aizenberg, I. N., Aizenberg, N. N., & Vandewalle, J. (2000). *Multi-Valued and Universal Binary Neurons*. Springer US, 25–80.
51. Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157-166.
52. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
53. Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222-2232.
54. Gers, F. A., Schmidhuber, J., & Cummins, F. (1999). Learning to forget: Continual prediction with LSTM. *1999 Ninth International Conference on Artificial Neural Networks ICANN 99. (Conf. Publ. No. 470)*, 2, 850-855 c.2.
55. Gers, F. A., & Schmidhuber, J. (2000). Recurrent nets that time and count. *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium*, 3, 189-194 c.3.
56. İnternet: LSTM.URL: <https://medium.com/@ishakdolek/lstm-d2c281b92aac>, Son Erişim Tarihi: 18.05.2022.
57. İnternet: Veri Talebi.URL: <http://www.trafik.gov.tr/veri-talebi>, Son Erişim Tarihi: 15.06.2020.
58. İnternet: TensorFlow Lite.URL: <https://www.tensorflow.org/lite/guide?hl=tr>, Son Erişim Tarihi: 15.06.2022.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : CAYMAZ, Mustafa
Uyruğu : T.C.

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	Gazi Üniversitesi / Bilişim Enstitüsü Elektronik Bilgisayar Eğt. A.B.D.	Devam ediyor
Lisans	Gazi Üniversitesi / Teknoloji Fakültesi Bilgisayar Mühendisliği	2020
Lisans	Gazi Üniversitesi / Teknik Eğitim Fakültesi Bilişim Sistemleri Öğretmenliği	2003
Lise	Şanlıurfa Anadolu Mes. Lisesi / Bilgisayar	1998

İş Deneyimi

Yıl	Yer	Görev
2003-Halen	Milli Eğitim Bakanlığı	Öğretmen

Yabancı Dil

İngilizce,

Yayınlar

Caymaz, M., Doğru, İ.A., & Toklu, S. (2021). "Deep Learning-Based Traffic Accidents Severity Forecast". *International Conference on Informatics and Computer Science (ICI-CS2021)*.



GAZİLİ OLMAK AYRICALIKTIR.