



İSKENDERUN TEKNİK

ÜNİVERSİTESİ

MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**KAZA ANALİZLERİNDE REGRESYON
YÖNTEMLERİ İLE YAPAY ZEKA
TEKNİKLERİNİN
KARŞILAŞTIRILMASI**

Hatice ALKILIÇ

İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI

HAZİRAN 2019



**KAZA ANALİZLERİNDE REGRESYON YÖNTEMLERİ İLE YAPAY ZEKÂ
TEKNİKLERİNİN KARŞILAŞTIRILMASI**

Hatice ALKILIÇ

**YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2019

Hatice ALKILIÇ tarafından hazırlanan “KAZA ANALİZLERİNDE REGRESYON YÖNTEMLERİ İLE YAPAY ZEKÂ TEKNİKLERİNİN KARŞILAŞTIRILMASI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Ömer Faruk CANSIZ
İnşaat Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.



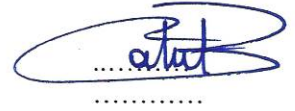
Başkan: Prof. Dr. Umur Korkut SEVİM
İnşaat Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.



Üye: Prof. Dr. Fatih ÜNEŞ
İnşaat Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.



Üye: Prof. Dr. Cahit BİLİM
İnşaat Mühendisliği Anabilim Dalı, Mersin Üniversitesi
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.



Tez Savunma Tarihi: 10/06/2019

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Prof. Dr. Tolga DEPCİ
Mühendislik ve Fen Bilimleri Enstitüsü Müdürü



ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Yükseköğretim Kuruluna gönderilen kopya ile tarafından Mühendislik ve Fen Bilimleri Enstitüsü'ne verilen basılı ve/veya elektronik kopyaların birebir aynı olduğunu,
- 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

Hatice ALKILIÇ

10/06/2019

KAZA ANALİZLERİNDE REGRESYON YÖNTEMLERİ İLE YAPAY ZEKÂ
TEKNİKLERİNİN KARŞILAŞTIRILMASI
(Yüksek Lisans Tezi)

Hatice ALKILIÇ

İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2019

ÖZET

Trafik kazalarının sayısının tahmin edilmesi ulaştırma politikalarının geliştirilmesine yön veren önemli çalışmalarındandır. Makro düzeyde karayollarında meydana gelen kaza sayısı üzerinde etkili olan birçok değişken mevcuttur. Bu çalışmada, nüfus, taşıt sayısı, sürücü sayısı, taşıt-kilometre makro değişkenleri bağımsız değişken olarak düşünülmektedir. Bu makro değişkenler kullanılarak tahmin edilen yıllık kaza sayısı, ölüm sayısı ve yaralı sayısı bağımlı değişkendir. Bu çalışmada kullanılan veriler ABD eyaletlerine ait 1988-2016 yıllarına ait verilerdir. Bu çalışmada çok değişkenli regresyon yöntemleri ile oluşturulan tahmin modeli, logaritmik regresyon, yapay sinir ağları (YSA) ve Bulanık Mantık (BM) ile karşılaştırılmaktadır. Çok değişkenli lineer regresyon modelinin, lineer, interaction, quadratic ve purequadratic türleri uygulanmaktadır. Modeller arası karşılaştırmalar korelasyon katsayısı (R), yüzde hataların ortalaması (YHO) ve hataların karesinin ortalaması (HKO) ile yapılmaktadır. Kaza sayısı tahmini için yapılan analizler sonucunda çok değişkenli lineer regresyon yöntemlerinden, lineer regresyon modelinin R değeri 0,8577, YHO değeri %4,8027, HKO değeri 14501376454,2255 olarak hesaplanmaktadır. İnteraction regresyon modelinin R değeri 0,9692, YHO değeri %2,0864, HKO değeri 3326475148,8991 olarak hesaplanmaktadır. Purequadratic regresyon modelinin R değeri 0,9672, YHO değeri %2,1795, HKO değeri 3540099887,9246 olarak hesaplanmaktadır. Quadratic regresyon modelinin R değeri 0,9889, YHO değeri %1,4379, HKO değeri 1214042257,7187 olarak hesaplanmaktadır. Logaritmik regresyon modeli sonucu elde edilen R değeri 0,8502, YHO değeri %4,8007 ve HKO değeri 15243601485,0837 olarak hesaplanmaktadır. YSA analiz sonucu elde edilen R değeri 0,9816, YHO değeri %1,6463 ve HKO değeri ise 2152002423,0350 olarak hesaplanmaktadır. BM analiz sonucu elde edilen R değeri 0,8869, YHO değeri %5,7766 ve HKO değeri ise 16956785090,7348 olarak hesaplanmaktadır. Yaralı sayısı tahmini için yapılan analizler sonucunda, lineer regresyon modelinin R değeri 0,9390, YHO değeri %4,5540, HKO değeri 21634202561,6271 olarak hesaplanmaktadır. İnteraction regresyon modelinin R değeri 0,9934, YHO değeri %1,4955, HKO değeri 2420035918,9591 olarak hesaplanmaktadır. Purequadratic regresyon modelinin R değeri 0,9925, YHO değeri %1,6821, HKO değeri 5340363074,3138 olarak hesaplanmaktadır. Quadratic regresyon modelinin R değeri 0,9951, YHO değeri %0,6148, HKO değeri 600590065,7349 olarak hesaplanmaktadır. Logaritmik regresyon modeli sonucu elde edilen R değeri 0,9481, YHO değeri %4,1322 ve HKO değeri 18549631727,8743 olarak hesaplanmaktadır. YSA analiz sonucu elde edilen R değeri 0,9860, YHO değeri %2,4522 ve HKO değeri 6268315631,2724 olarak hesaplanmaktadır. BM analiz sonucu elde edilen R değeri 0,9518, YHO değeri %5,0739 ve HKO değeri 26260831083,4280 olarak hesaplanmaktadır. Ölüm sayısı tahmini için yapılan analizler sonucunda, lineer regresyon modelinin R değeri 0,9971, YHO değeri %0,6600, HKO değeri 99919,4830 olarak hesaplanmaktadır. İnteraction regresyon modelinin R değeri 0,9994, YHO değeri %0,2926, HKO değeri 19416,1569 olarak hesaplanmaktadır. Purequadratic regresyon modelinin R değeri 0,9993, YHO değeri %0,3437, HKO değeri 25040,2321 olarak hesaplanmaktadır. Quadratic regresyon modelinin R değeri 0,9996, YHO değeri %0,2071, HKO

deęeri 13087,7865 olarak hesaplanmaktadır. Logaritmik regresyon modeli sonucu elde edilen R deęeri 0,9972, YHO deęeri %0,6375 ve HKO deęeri 96023,6160 olarak hesaplanmaktadır. YSA analiz sonucu elde edilen R deęeri 0,9972, YHO deęeri %0,3949 ve HKO deęeri 98718,9991 olarak hesaplanmaktadır. BM analiz sonucu elde edilen R deęeri 0,9437, YHO deęeri %4,4421 ve HKO deęeri 4737707,4473 olarak hesaplanmaktadır. Yapılan analizler sonucunda kaza, yaralı ve ölüm sayılarının tahmininde en iyi sonuçları veren model quadratic regresyon modeli olarak bulunmaktadır.

Anahtar Kelimeler : Kaza Sayısı, Yaralı Sayısı, Ölüm Sayısı, Logaritmik Regresyon, Çok Deęişkenli Lineer Regresyon, YSA, Bulanık Mantık
Sayfa Sayısı : 58
Danışman : Dr. Öğr. Üyesi Ömer Faruk CANSIZ

COMPARISON OF REGRESSION METHODS AND ARTIFICIAL INTELLIGENCE
TECHNIQUES IN ACCIDENT ANALYSIS
(M. Sc. Thesis)

Hatice ALKILIÇ


ISKENDERUN TECHNICAL UNIVERSITY
ENGINEERING AND SCIENCE INSTITUTE

June 2019

ABSTRACT

Estimating the number of traffic accidents is one of the important studies that guide the development of transportation policies. At the macro level, there are many variables that affect the number of road accidents. In this study, population, number of vehicles, number of drivers, vehicle-kilometers which are the macro variables, are considered as independent variables. The number of accidents, the number of deaths, and the number of injureds, which are dependent variable,s are estimated by using these macro variables. The data used in this study are from the years 1988-2016 of the US states. In the study, the prediction model generated by multivariate regression methods is compared with logarithmic regression, artificial neural networks (ANN) and Fuzzy Logic (FL). Linear, interaction, quadratic and purequadratic types of multivariate linear regression model are applied. Comparisons between the models are made with the correlation coefficient (R), the mean of the percentage errors (MPE) and the mean square of the errors (MSE). As a result of the analyzes conducted for the estimation of the number of accidents, the R value of the linear regression model is 0.8577, the MPE value is 4.8027% and the MSE value is 14501376454,2255. Interaction regression model R value is 0.9692, MPE value is 2.0864%, MSE value is calculated as 3326475148,8991. Purequadratic regression model R value is 0.9672, MPE value is 2.1795%, MSE value is calculated as 3540099887,9246. The R value of the quadratic regression model is 0.9889, the MPE value is 1.4379% and the MSE value is 1214042257,7187. R value obtained as a result of logarithmic regression model is calculated as 0.8502, MPE value is 4,8007% and MSE value is calculated as 15243601485,0837. R value obtained from ANN analysis is calculated as 0.9816, MPE value is calculated as 1.6463% and MSE value is calculated as 2152002423,0350. The R value obtained by the FL analysis is 0.8869, the MPE value is 5.7766% and the MSE value is calculated as 16956785090.7348. As a result of the analyzes conducted for estimating the number of injured, R value of linear regression model is calculated as 0.9390, MPE value is 4.5540% and MSE value is calculated as 21634202561,6271. The R value of the interaction regression model is 0.9934, the MPE value is 1.4955%, the MSE value is calculated as 2420035918,9591. Purequadratic regression model R value is 0.9925, MPE value is 1.6821%, MSE value is calculated as 5340363074,3138. The R value of the Quadratic regression model is calculated as 0.9951, the MPE value is 0.6148% and the MSE value is 600590065,7349. R value obtained as a result of logarithmic regression model is calculated as 0.9481, MPE value is calculated as 4,1322% and MSE value is calculated as 18549631727,8743. The R value obtained from ANN analysis is calculated as 0.9860, MPE value is calculated as 2.4522% and MSE value is calculated as 6268315631,2724. The R value obtained by FL analysis is calculated as 0.9518, MPE value is 5.0739% and MSE value is calculated as 26260831083,4280. As a result of the analyzes made for the estimation of the number of deaths, the R value of the linear regression model was calculated as 0.9971, the MPE value was 0.66600% and the MSE value was calculated as 99919.4830. Interaction regression model R value is 0.9994, MPE value is 0.2926%, MSE value is calculated as 19416,1569. Purequadratic regression model R value is 0.9993, MPE value is 0.3437%, MSE value is calculated as 25040,2321. The R value of

the quadratic regression model is 0.9996, the MPE value is 0.2071%, and the MSE value is 13087.7865. R value obtained as a result of logarithmic regression model is calculated as 0.9972, MPE value is 0.6375% and MSE value is calculated as 96023,6160. R value obtained from ANN analysis is calculated as 0.9972, MPE value is calculated as 0.3949% and MSE value is calculated as 98718,9991. The R value obtained by the FL analysis is 0.9437, the MPE value is 4.4421% and the MSE value is 4737707,4473. As a result of the analyzes, the model which gives the best results in the estimation of accident, injured and death numbers was found as quadratic regression model.



Key Words : Number of Accidents, Number of Injured, Number of Deaths, Logarithmic Regression, Multivariate Linear Regression, ANN, Fuzzy Logic
Page Number : 58
Supervisor : Assist. Prof. Dr. Ömer Faruk CANSIZ

TEŐEKKÜR

Yüksek Linsans tez konusunun belirlenmesinde, araştırılması ve yazımı sırasında sahip olduđu bilgi birikimi ve tecrübesi ile çalışmayı yönlendiren ve her türlü yardımı esirgemeyen saygıdeđer danışman hocam Dr.Öğr.Üyesi Ömer Faruk CANSIZ'a Ceng AYGÜN'e sonsuz saygı ve teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ÇİZELGELERİN LİSTESİ.....	xi
ŞEKİLLERİN LİSTESİ.....	xii
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
1.1. Karayollarında Kaza Analizleri.....	1
1.2. Karayollarında Kaza Analizlerinin Ve Sonuçlarının Tahmin Edilmesi.....	1
1.2.1. Çok değişkenli lineer regresyon ile tahmin edilmesi	2
1.2.2. Yapay sinir ağları ile tahmin edilmesi.....	2
1.2.3. Bulanık mantık ile tahmin edilmesi.....	3
2. ÖNCEKİ ÇALIŞMALAR.....	4
3. MATERYAL VE YÖNTEM	27
3.1. Karayollarında Kaza Sayısı	27
3.2. Karayollarında Ölüm Sayısı	28
3.3. Karayollarında Yaralı Sayısı	29
3.4. Çok Değişkenli Lineer Regresyon İle tahmin Edilmesi.....	30
3.5. Yapay Sinir Ağları İle Tahmin Edilmesi.....	31
3.6. Bulanık Mantık İle Tahmin Edilmesi.....	32
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	35
4.1. Çok Değişkenli Lineer Regresyon İle Kaza Sayısının Tahmin Edilmesi	35

4.2. Çok Değişkenli Lineer Regresyon İle Ölüm Sayısının Tahmin Edilmesi	36
4.3. Çok Değişkenli Lineer Regresyon İle Yaralı Sayısının Tahmin Edilmesi	38
4.4. Yapay Sinir Ağları İle Kaza Sayısının Tahmin Edilmesi	40
4.5. Yapay Sinir Ağları İle Ölüm Sayısının Tahmin Edilmesi	41
4.6. Yapay Sinir Ağları İle Yaralı Sayısının Tahmin Edilmesi	42
4.7. Bulanık Mantık İle Kaza Sayısının Tahmin Edilmesi	44
4.8. Bulanık Mantık İle Ölüm Sayısının Tahmin Edilmesi	45
4.9. Bulanık Mantık İle Yaralı Sayısının Tahmin Edilmesi	46
4.10. Kaza Sayısı Tahminlerinin Karşılaştırılması	48
4.11. Ölüm Sayısı Tahminlerinin Karşılaştırılması	48
4.12. Yaralı Sayısı Tahminlerinin Karşılaştırılması	49
5. SONUÇLAR VE ÖNERİLER	50
KAYNAKLAR	52
ÖZGEÇMİŞ	56
DİZİN	57

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Amerikan karayolları idaresi (fhwa) kaza sayısı verileri	27
Çizelge 3.2. Amerikan karayolları idaresi (fhwa) ölüm sayısı verileri	28
Çizelge 3.3. Amerikan karayolları idaresi (fhwa) yaralı sayısı verileri.....	29
Çizelge 4.1. Kaza sayısı tahmini için çok değişkenli lineer regresyon modellerinin karşılaştırılması	36
Çizelge 4.2. Ölüm sayısı tahmini için çok değişkenli lineer regresyon modellerinin karşılaştırılması	38
Çizelge 4.3. Yaralı sayısı tahmini için çok değişkenli lineer regresyon modellerinin karşılaştırılması	39
Çizelge 4.4. Kaza sayısı tahmini için modellerin karşılaştırılması.....	48
Çizelge 4.5. Ölüm sayısı tahmini için modellerin karşılaştırılması.....	49
Çizelge 4.6. Yaralı sayısı tahmini için modellerin karşılaştırılması.....	49

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. SMGRT formüllerindeki değişkenlerin gösterimi.....	34
Şekil 4.1. Kaza sayısı tahmini için yapay sinir ağları model görünümü.....	40
Şekil 4.2. Kaza sayısı tahmini için yapay sinir ağları modelinin performans ve eğitim grafiği görünümü	40
Şekil 4.3. Kaza sayısı tahmini için yapay sinir ağları modelinin regresyon katsayısı	41
Şekil 4.4. Ölüm sayısı tahmini için yapay sinir ağları model görünümü.....	41
Şekil 4.5. Ölüm sayısı tahmini için yapay sinir ağları modelinin performans ve eğitim grafiği görünümü	42
Şekil 4.6. Ölüm sayısı tahmini için yapay sinir ağları modelinin regresyon katsayısı grafiği.....	42
Şekil 4.7. Yaralı sayısı tahmini için yapay sinir ağları model görünümü.....	43
Şekil 4.8. Yaralı sayısı tahmini için yapay sinir ağları modelinin performans ve eğitim grafiği görünümü	43
Şekil 4.9. Yaralı sayısı tahmini için yapay sinir ağları modelinin regresyon katsayısı grafiği.....	43
Şekil 4.10. Kaza sayısı tahmini için bulanık mantık model ve üyelik fonksiyonların görünümü.....	44
Şekil 4.11. Kaza sayısı tahmini için bulanık mantık modelinin kural tablosu.....	44
Şekil 4.12. Kaza sayısı tahmini için bulanık mantık modelinin saçılım grafiği	45
Şekil 4.13. Ölüm sayısı tahmini için bulanık mantık model ve üyelik fonksiyonların görünümü	45
Şekil 4.14. Ölüm sayısı tahmini için bulanık mantık modelinin kural tablosu.....	46
Şekil 4.15. Ölüm sayısı tahmini için bulanık mantık modelinin saçılım grafiği	46
Şekil 4.16. Yaralı sayısı tahmini için bulanık mantık model ve üyelik fonksiyonların görünümü	47
Şekil 4.17. Yaralı sayısı tahmini için bulanık mantık modelinin kural tablosu.....	47
Şekil 4.18. Yaralı sayısı tahmini için bulanık mantık modelinin saçılım grafiği	47

SİMGELER VE KISALTMALAR

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

Kısaltmalar	Açıklamalar
KGM	Karayolları Genel Müdürlüğü
BM	Bulanık Mantık
YSA	Yapay Sinir Ağları
ABD	Amerika Birleşik Devletleri
AHP	Analitik Hiyerarşi Prosesi
ANFIS	Nöro Bulanık Çıkarım Sistemi
CBS	Coğrafi Bilgi Sistemleri
FWHA	Federal Karayolları İdaresi
LM	Levenberg Marquardt
HKO	Hataların Karelerinin Ortalaması
R	Korelasyon Katsayısı
YHO	Yüzde Hataların Ortalaması

1. GİRİŞ

Türkiye’de yük ve yolcu taşımacılığında karayolları yoğun olarak kullanılmaktadır. Dünyada karayollarının taşımacılık payı çok yüksek olmasa da, ülkemizde çok büyük değerlere sahiptir. Kaza riski en yüksek taşımacılık türü olan karayollarının ülkemizde çok büyük paya sahip olması istenilmeyen bir durumdur. Karayollarının daha çok tercih edilmesi trafikteki taşıt sayısını arttırmakta ve taşıt sayısının artmasıyla meydana gelen kaza sayısı artmaktadır.

Tüm dünya için çok önemli bir problem olan bu kazalar çoğu zaman can kaybı ve yaralanmalarla sonuçlanmaktadır. Meydana gelen trafik kazalarının sayısını azaltmak ve dolayısıyla yaralanmaları ve ölümleri önlemek için kazalara neden olan faktörleri iyi bilmek ve iyi analiz etmek gerekmektedir. Çünkü ancak kazaya neden olan etkiler bilinip azaltılabilirse meydana gelen kaza sayısı da dolaylı olarak azaltılmış olmaktadır.

Karayollarında meydana gelen trafik kazalarına sebep olan birçok etken olmakla beraber bu çalışma kapsamında, sürücü sayısı, taşıt sayısı, taşıt-km, ve nüfusun etkisi araştırılmaktadır. Bu unsurların kazaları ne ölçüde etkilediği ve önceden tahmin edilirse nasıl önüne geçilebileceği araştırılmaktadır.

1.1. Karayollarında Kaza Analizleri

Dünyada ölüm sebepleri arasında trafik kazaları ön sırada yer almaktadır. Trafik kazaları sonucunda maddi hasarlı kazalar, yaralanmalı kazalar ve ölümlü kazalar meydana gelmektedir. Trafik kazalarının azaltılması hem canların kurtulmasına hem sakatlıkların engellenmesine hem de maddi kayıpların önlenmesine yardımcı olmaktadır. Bu amaçla birçok kaza analizi yapılmaktadır. Literatürde kazaların oluş sebeplerinden kavşak tasarımlarına kadar birçok konu trafik kazalarının daha iyi anlaşılması için incelenmektedir. Bizim bu çalışmamız gibi olan yayınlarda da makro değişkenler kullanılarak trafik kazalarının tahminleri yapılmaktadır.

1.2. Karayollarında Kaza Analizlerinin ve Sonuçlarının Tahmin Edilmesi

Ülkelerin ulaştırma politikalarını geliştirmesinde en çok dikkat edilmesi gereken konulardan birisi de güvenlidir. Taşımacılıkta güvenliğin sağlanması için ulaştırmanın bütün türlerinde kaza sebepleri detaylı bir şekilde incelenmelidir. Güvenlik ile ilgili geliştirilen ulaştırma

politikalarının sebep-sonuç yönünden incelenmesi doğru yolda olup olmadığını göstermektedir. Geliştirilen ulaştırma politikalarının iyi sonuçlara ulaşip ulaşmadığı tahmin metodlarının kullanılması ile ortaya çıkarılabilmektedir. Bu çalışmada ulaştırma politikalarına yön vermek amacıyla kaza sayısının yıllara göre tahmin edilmesini sağlayan yöntemlerin incelenmesi yapılmaktadır.

1.2.1. Çok değişkenli lineer regresyon ile tahmin edilmesi

Regresyon Analizi, istatistik biliminin çok temel ilgi alanlarından bir tanesidir. Bir rastgele değişkenin davranışının model kullanarak tahminlenmesidir. Değişkenler arasındaki ilişkinin büyüklüğünü ölçmek için kullanılır. Regresyon yöntemleri ulaştırmada birçok alanda kullanılmaktadır. Özellikle trafik kazalarında regresyon yöntemleri kullanılarak birçok başarılı tahmin yapılmaktadır. İlk önceleri logaritmik regresyon ile başarılı modeller bulunurken daha sonra çok değişkenli lineer regresyon yöntemleri ile çok daha başarılı regresyon modelleri oluşturulmaktadır. Çok değişkenli lineer regresyonun lineer, interaction, quadratic ve purequadratic regresyon türleri vardır. Genel olarak interaction ve quadratic türleri trafik kazalarının tahmininde başarılı sonuçlara ulaşmaktadır.

1.2.2. Yapay sinir ağları ile tahmin edilmesi

Yapay Sinir Ağları (Artificial Neural Networks–YSA) teknolojisi bilgisayar dünyasında insan beyninin ve sinir sisteminin davranışlarını taklit etme esası üzerine kurulmuş yeni bir bilgi işleme yaklaşımıdır. İnsan beyninin en temel özelliği olan öğrenme fonksiyonunu gerçekleştiren bilgisayar sistemleridir. YSA, örneklerden olaylar arasındaki ilişkileri öğrenerek daha sonra hiç görmediği örnekler hakkında öğrendikleri bilgileri kullanarak karar veren sistemlerdir. Tıpkı insanlar gibi örneklerden öğrenir. YSA, olaylar arasındaki ilişkileri belirli bir algoritmaya dayanarak çözmek yerine, o ilişkiyi gösteren örnekleri incelemek suretiyle çözümler üretmeyi sağlarlar. YSA kendisine tanımlanan bir şekli, daha önce öğrendikleri ile mukayese ederek aradaki benzerlikleri ortaya koyma ve eksik şekilleri tanımlama, benzer şekilleri oluşturma veya şekilleri belirli sınıflara ayırma özelliklerine sahiptir. İyi eğitilmiş, genelleme kapasitesi yüksek bir sinir ağı kendisine tanımlanan veriler eksik olsa bile karar verme işlemine devam edebilir.

1.2.3. Bulanık mantık ile tahmin edilmesi

Bulanık mantığın temelini bulanık kümeler oluşturmaktadır. Klasik küme teorisinde bir eleman kümenin ya elemanıdır ya da değildir. Matematiksel olarak ifade edilmek istense, eleman küme ise olan üyelik ilişkisi yönünden kümenin içinde ise 1 değil ise 0 olarak kabul edilmektedir. Yani herşey ya 0 ya da 1 mantığı yatmaktadır. Bulanık küme teorisi ise klasik küme teorisinin genişletilmiş halidir. Bulanık küme mantığında her elemanın bir üyelik derecesi bulunmaktadır. Bu üyelik dereceleri 0-1 arasında herhangi bir değeri alabilmektedir. Bu anlamda, belirsizliklerin değerlendirilmesinde sağlam ve anlamlı seçenekler sunmasının yanı sıra, belirsizliklerin anlamlı bir şekilde temsil edilebilmesini sağlamaktadır. Genel olarak araştırılan bir olaydaki belirsizlikleri istatistiksel veya matematiksel yöntemler ile olayla ilgili kabuller yapılarak modeller kurulmaktadır. Ancak rastgele olmayan belirsizlik durumları için, istatistiksel veya matematiksel yöntemlerin kullanılması uygun olmamak ile birlikte yetersiz kalmaktadır. Bu tür rastgele olmayan belirsizlik durumları bulanık olarak modellenmesi gerekmektedir. Bu çalışmamızda kaza, ölüm ve yaralı analizleri tahmininde bulanık mantık modellemesi uygulanmaktadır. Bunun sebebi kazaların oluşmasında birçok parametrelerin bulunması ve çoğu parametrelerin sayısal verilere dökülememesinden dolayıdır.

2. ÖNCEKİ ÇALIŞMALAR

Agarwal ve arkadaşları (2016), trafik olaylarını tespit etmek için dalgacık tabanlı bir özellik çıkarımı olan lojistik regresyon kullanan bir hibrid modelini araştırmaktadır. Sonuç yalnızca sınırlı sayıda değer alabildiğinde lojistik bir regresyon modeli uygundur. Trafik olayının tespiti için, olayın varlığı veya yokluğu bir değer ile sınırlı tutulmaktadır. Bu çalışmada kullanılan lojistik regresyon modeli, binom yanıtı ve logit link fonksiyonlu genelleştirilmiş bir doğrusal modeldir (GLM). Bu yazıda, trafik olaylarının tespiti için lojistik regresyon ve dalgacık tabanlı özellik çıkarımı kullanmak için bir çerçeve sunulmaktadır. Ön işleme verilerinin, olay algılama modellerinin performansı üzerindeki etkisini araştırmaktadır. Bu çalışmanın sonuçları, dalgacık tabanlı özellik çıkarımı ile birlikte lojistik regresyonun, olay tespit oranı ve ihtiyaca göre yanlış alarm oranını dengelemek suretiyle olay tespiti için etkili bir şekilde kullanılabileceğini göstermektedir. Ham veri üzerindeki lojistik regresyon %14,5 yanlış alarm oranıyla maksimum % 95,4 tespit oranı ile sonuçlanmıştır. Oysa hibrid model, %6,5 yanlış alarm pahasına % 98,78 maksimum tespit oranına ulaşmıştır. Sonuçlar, önerilen yaklaşımın pratik ve verimli olduğunu göstermektedir. Önerilen teknik, gelecekteki gelişmeler ile trafik olaylarının tespiti için etkili bir araç olarak kullanılmaktadır.

Toprak ve arkadaşları (2017), bulanık modellemede, üyelik fonksiyonları ve bulanık kuralların uygun bir şekilde belirlenmesi, denemeyanılma sürecinin kısa tutulabilmesi ve modelin başarısı açısından birinci derecede önemlidir. Gerek üyelik fonksiyonlarının belirlenmesine gerek kuralların atanmasına ilişkin literatürde çeşitli yaklaşımlara rastlamak mümkündür (Genetik Algoritma, Yapay Sinir Ağları, Kalman Filtresi, çeşitli istatistiksel ve grafiksel yaklaşımlar gibi). Fakat bu algoritmalar genellikle, üyelik fonksiyonları ve bulanık kuralların belirlenmesi için ayrı ayrı geliştirilmiştir. Bu yöntemlerin bir kısmı ayrıca paket programları ve geniş zaman ve işlem hacmini gerektirirken bir kısmı ise deneme-yanılma yönteminden tümü ile kurtaracak kadar iyi sonuç verememektedir. Bu çalışmada ise hem üyelik fonksiyonlarının (üçgen/trapez) belirlenmesinde hem de bulanık kuralların atanmasında sentroid durulaştırma yöntemi ile kullanılabilecek SMRGT adında literatürde yeni olan bir yaklaşımın iki pratik uygulaması sunulmaktadır. Uygulama sonucunda, yöntemin başarılı olduğu görülmüştür.

Ali ve arkadaşları (2012), bu makale kaza özelliklerini sunmakta ve karayolu güvenliği yönetimini ele almaktadır. Makalede tartışılan önemli konular, öngörü ve güvenlik önlemlerini

içermektedir. Trafik kazası kayıplarını karşılaştırmalı olarak tahmin etmek için Yapay Sinir Ağı (YSA) ve regresyon teknikleri uygulanmaktadır. Her iki yaklaşım da 1991'den 2009'a kadar olan nüfus, kayıtlı araç sayısı ve diğer ilgili faktörlerle ilgili tarihsel verileri kullanarak kaza kayıplarını modellemiştir. Kaydedilen verilerle yapılan tahminlerin karşılaştırılması olumlu olmaktadır. 2010- 2014 yılları arasındaki tahminler, aynı öngörü değişkenleri için tahmin edilen değerler kullanılarak belirlenmiştir. YSA tahminleri, tahminler ve gözlemlenen veriler arasında %1,84' lük bir maksimum fark ile verilere en iyi uyumu sağlamaktadır. Çalışma, YSA' nın kaza kazalarının analizi ve tahmini için güçlü bir araç sağladığını göstermektedir. Kazaların ana nedenleri, sürüklenme, davranışlar, filo ve koşullar, karayolu ağı arızaları, hız sınırı ihlali, emniyet kemeri kullanımının ihmali ve trafik yasalarının uygulanmamasına bağlanmaktadır.

Alikhani ve arkadaşları (2013), veri madenciliği algoritmaları birçok sınıflandırma probleminde kullanılmaktadır. Bu yazıda, bu kazaların bir kısmı yol kazalarının ciddiyetini (zayıflar veya hasarlar) sınıflandırmak için kullanılmaktadır. Yapay Sinir Ağı (ANN) ve Uyarlanabilir Nöro Bulanık Çıkarım Sistemi (ANFIS) dâhil olmak üzere bu çalışmada bireysel sınıflandırma algoritmaları kullanılmaktadır. Belirtilen sınıflandırma algoritmaları, sorunların özelliklerinin ve alanlarının uygunluklarını etkilediği bazı özel avantaj ve dezavantajlara sahip duruma gelmektedir. Son yıllarda daha iyi sonuçlar elde etmek için Topluluk Modelleri üzerine birçok çalışma yapılmıştır. Bu yazıda, sınıflandırma doğruluğunu arttırmak için kümeleme yöntemleri olarak k-araçları ve Kendi Kendini Düzenleyen Haritalar (SOM) kullanılarak karma kümeleme sınıflandırma yöntemi fikri uyarlanmaktadır. Veri setleri üzerinde yapılan deneyler, kümeleme öncesi sınıflamanın doğruluğunu artırabileceğini göstermektedir.

Anarkooli ve arkadaşları (2017), devrilme kazaları, önemli sayıda ciddi yaralanma ve ölüme neden olmaktadır. Bu nedenle, ulaşım yetkilileri ve güvenlik araştırmacıları için büyük endişe konusu olmaktadır. Bu araştırmanın iki amacı vardır. İlk hedef, bazıları mevcut çalışmalarda nadiren bildirilen çeşitli faktörlerin, Malezya federal yollarında toplanan altı yıllık kaza verilerine dayanarak, tek araçlı (SV) devrilme kazalarının yaralanma ciddiyeti üzerindeki etkilerini araştırmaktır. Bu çalışmada rollover çökmelerinin neden olduğu yaralanma ciddiyetini analiz etmek için rastgele etkiler genelleştirilmiş bir sıralı probit (REGOP) modeli kullanılmıştır. İkinci amaç, rollover yaralanma ciddiyeti sonuçlarının modellenmesinde önerilen yaklaşım olan REGOP'un performansını incelemektir. Bu amaçla, bu çalışmada yaralanma şiddeti modellenmesindeki popülaritesi nedeniyle karma bir logit (MXL) modeli de kullanılmıştır. Devrilme kazalarının yaralanma şiddeti üzerindeki etkilerine ilişkin sonuçlar, ek

aydınlatma olmadan karanlık, yağışlı hava durumu, hafif kamyon araçları, ağır araçlar, uygun olmayan sollama, araç yaşı, trafik hacmi ve bileşimi, seyahat şeridi sayısı, hız limiti, dalgalı arazi, orta medyan varlığı ve güvenli olmayan yol kenarı koşulları, daha ağır SV geçiş kazaları ile pozitif ilişkilidir. Öte yandan, asfaltlanmamış omuz genişliği, alan tipi, sürücü kullanımı ve erişim noktalarının sayısı, devrilme kazalarında ölüm veya ağır yaralanma olasılığını azaltan (yani, KSI) önemli değişkenler olarak bulunur. Arazi kullanımı ve yan sürtünme önemli ve sadece hafif yaralanma kategorisi ile pozitif ilişkilidir. Bu bulgular, rollover kazalarının yaralanma şiddeti modellerini etkileyen nedenler ve faktörler hakkında değerli bilgiler sağlar ve böylece rollover kazalarının şiddetini azaltmak için etkili karşı önlemler geliştirilmesine yardımcı olabilir. Model karşılaştırma sonuçları, REGOP modelinin MXL modeline uygunluk önlemleri açısından daha iyi performans gösterdiğini ve ayrıca genelleştirilmiş sıralı probit ve rasgele etkiler sıralı probit (sıralı probit (probit) dahil olmak üzere sıralı probit modellerin diğer uzantılarından önemli ölçüde üstün olduğunu göstermektedir) REOP) modelleri. Sonuç olarak, bu araştırma gelecekteki araştırmalar için kaza yaralanmasının ciddiyetine odaklanan umut verici bir araç olarak REGOP'u ortaya koymaktadır.

Bertsimas ve arkadaşları (2019), servikal omurga yaralanmaları (CSI) genç pediatrik travma hastalarında önemli bir endişe kaynağıdır. Kaçırılan yaralanmaların sonuçları ve sözel olmayan hastalar için yaralanmanın önlenmesindeki zorluklar küçük çocukları görme eğilimine yol açmıştır. Görüntüleme, özellikle bilgisayarlı tomografi (BT) taramaları, radyasyona bağlı karsinogenezi içeren riskler sunar. Bu çalışmada, pediatrik CSI'yi öngörmek için oldukça kesin klinik karar kuralları geliştirmek için makine öğrenme yöntemlerinden yararlanılmaktadır. PEDSPINE I kayıt defteri, üç yaşın altındaki tüm travma hastalarında CSI'yi araştırmak için kullanılmıştır. Tahmini modeller, yaygın kullanılan diğer makine öğrenme yöntemlerinin yanı sıra, yüksek doğruluk ve yorumlanabilirlik sunan yeni bir makine öğrenme yaklaşımı olan Optimal Sınıflandırma Ağaçları kullanılarak oluşturulmuştur. Son Optimal Sınıflandırma Ağaçları modeli, genel Glasgow Koma Skoruna (GCS) ve hastanın yaşına göre yaralanmayı öngörmektedir. Bu model tam veri setinde % 93,3 duyarlılığa ve % 82,3 özgüllüğe sahiptir. Bu çalışma, gereksiz görüntülemeyi azaltırken yüksek yaralanma tespiti sağlayan bir karar kuralı geliştirmiştir. Pediatrik travma için klinik karar protokollerinin geliştirilmesinde makine öğrenmesinin değerini göstermektedir.

Chang (2005), poisson veya negatif binom regresyon modeli, uzun yıllar boyunca taşıt kaza sıklığını analiz etmek için kullanılmaktadır. Ancak, bu modeller bağımlı ve bağımsız

değişkenler arasında önceden tanımlanmış bir temel ilişkiye sahiptir. Bu varsayım ihlal edilirse, model kaza olasılığının hatalı tahmin edilmesine yol açabilmektedir. Buna karşılık, bağımlı ve bağımsız değişkenler arasında önceden tanımlanmış bir ilişki gerektirmeyen yapay sinir ağının (YSA), tahmin ve sınıflandırma problemleriyle başa çıkmada güçlü bir araç olduğu gösterilmektedir. Bu nedenle, bu çalışmada Tayvan'daki Ulusal Çevre Yolu 1 için 1997-1998 kaza verilerini analiz etmek için negatif bir binom regresyon modeli ve bir ANN modeli kullanılmaktadır. Negatif binom regresyon modeli ile ANN modeli arasındaki tahmin performansını karşılaştırarak, bu çalışma ANN'nin otoyol kaza sıklığını analiz etmek için tutarlı bir alternatif yöntem olduğunu göstermektedir.

Chang ve arkadaşları (2006), logit veya sipariş edilen probit / logit modelleri gibi istatistiksel regresyon modelleri, trafik kazalarının yaralanma ciddiyetini analiz etmek için yaygın olarak kullanılmaktadır. Bununla birlikte, çoğu regresyon modelinin kendi model varsayımları ve bağımlı ve bağımsız değişkenler arasında önceden tanımlanmış temel ilişkileri vardır. Bu varsayımlar ihlal edilirse, model hatalı yaralanma olasılığı tahminlerine neden olabilmektedir. En yaygın olarak uygulanan veri madenciliği tekniklerinden biri olan sınıflandırma ve regresyon ağacı (CART) işletme yönetimi, endüstri ve mühendislik alanlarında yaygın bir şekilde kullanılmaktadır. CART, hedef (bağımlı) değişken ve öngörücüler (bağımsız değişkenler) arasında önceden tanımlanmış bir ilişki gerektirmez ve özellikle tahmin ve sınıflandırma problemleriyle başa çıkmak için güçlü bir araç olduğu gösterilmektedir. Bu çalışma Tayvan Taipei'deki 2001 kaza verilerini kullanmaktadır. Yaralanma şiddeti ile sürücü ve araç özellikleri, otoyol ve çevre değişkenleri ve kaza değişkenleri arasındaki ilişkiyi belirlemek için bir CART modeli geliştirilmiştir. Sonuçlar, çarpışma şiddetiyle ilişkili en önemli değişkenin araç tipi olduğunu göstermektedir. Trafik kazalarında yayalar, motosiklet ve bisiklet sürücüleri, diğer araç sürücülerine göre daha yüksek yaralanma riskine sahiptir.

Toprak (2009), bu çalışmanın temel amacı, akış modellemesinde iki önemli sorunun cevabını araştırmaktır. İlk soru; belirli bir akış için açık bir kanalın enine kesitinin en uygun şekilde nasıl tasarlanacağıdır. İkinci soru ise; modelleme için bulanık yöntemin seçilmesi durumunda, üyelik fonksiyonlarının (MF'ler) ve bulanık kuralların (FR'ler) nasıl oluşturulacağı durumunda sistem en iyi sonuçları verir. İlk soru, uygun akış hızını kullanarak kazı ve ilgili masrafları en aza indirmek için cevaplandırılmıştır. En iyi cevabı sağlamak için araştırmacılar çeşitli yöntemler kullanırlar. İkinci hatayı, model hatasını en aza indirmek için cevaplandırılmıştır. Bu amaçla, literatürde araştırmacılar tarafından önerilen birçok algoritma vardır. Bu yazıda açık kanal akış

modellemesi için bulanık mantık yöntemi kullanılmıştır. Ayrıca, basit bir üyelik fonksiyonu ve bulanık kural üretme tekniği (SMRGT) tanıtılmış ve bulanık modelleme için kullanılmıştır. Her biri farklı kesitsel şekli olan iki bulanık model, bu çalışmada SMRGT'nin bir uygulaması olarak sunulmuştur. Karşılaştırma, çeşitli istatistiklere, ortalama mutlak göreceli hataya bağlıdır ve dağılım haritaları, bulanık modellerin açık kanal akış modellemesinde başarılı olduğunu ve SMRGT'nin MF (üyelik işlevi) ve FR (bulanık kural) üretimi için faydalı olduğunu göstermiştir.

Chen ve arkadaşları (2016), devrilme kazası, ölümcül yaralanmalara neden olan başlıca trafik kazası türlerinden biri olarak bilinmektedir. Devrilme kazalarını etkileyen faktörleri ve bunların sürücü yaralanma ciddiyeti sonuçları üzerindeki etkilerini araştırmak önemlidir. New Mexico'da toplanan iki yıllık kaza verisine dayanan rollover kazalarındaki sürücü yaralanma şiddeti modellerini araştırmak için destek vektör makinesi (SVM) modelleri kullanılmaktadır. Açıklayıcı değişkenlerin etkileri çarpışma ve çevresel bilgiler, araç özellikleri, sürücü demografik özellikleri ve davranış özellikleri açısından incelenmektedir. Önemli değişkenleri tanımlamak için bir sınıflandırma ve regresyon ağacı (CART) modeli kullanılmakta olup model performans değerlendirmesinde polinom ve Gauss yarıçapı temelli fonksiyon (RBF) çekirdekleri olan SVM modelleri kullanılmaktadır. SVM modellerinin makul tahmin performansı ürettiği ve polinom çekirdeğinin Gaussian RBF çekirdeğini geride bıraktığı gösterilmektedir. Değişken etki analizi, rahat sürüş ortamı koşulları, sürücü alkolü veya uyuşturucu kullanımı, emniyet kemeri kullanımı, seyahat şeridi sayısı, sürücü demografik özellikleri, çarpmalarda maksimum araç hasarları, çarpma süresi ve çarpma yerinin dahil olduğu faktörlerin, sürücünün yaralanmaya maruz kalmamasıyla ciddi şekilde ilişkili olduğu görülmektedir. Bu bulgular, devrilme çarpma nedenlerini ve çeşitli açıklayıcı faktörlerin sürücü yaralanma ciddiyeti kalıpları üzerindeki etkilerini daha iyi anlama konusunda bilgi sağlar.

Deka ve arkadaşları (2014), kaza haritalama algoritmasının amacı trafik kazalarını doğru yol bölümlerine oturtmaktır. Kazaların doğru bölümlere atanması, kaza sıcak noktalarının belirlenmesi, ağ düzeyinde risk haritalaması ve bölüm düzeyinde kaza riski modellemesi dâhil olmak üzere kaza araştırmalarında bazı önemli analizlerin sağlam bir şekilde yapılmasını kolaylaştırır. Bu yazının amacı, çoğu kaza veri tabanında gözlenen ortak değişkenlere dayanan yeni bir kaza haritası algoritması geliştirmektir. Buradaki zorluklar şunlardır: kaydedilen trafik kazası verilerinin ve altta yatan dijital yol ağı verilerindeki doğal belirsizlikleri dikkate alan bir yöntem geliştirmek, yanlışlıkların türünü ve oranını doğru bir şekilde belirlemek ve bir her türlü

kaza setine ve deęişen karmaşıklıkta ki yol ađına uyarlanabilen sađlam algoritma oluřturma ktır. Bu zorlukların üstesinden gelmek için, dođru yol segmentini tanımlamak için mesafeye dayalı bir desen eşleřtirme yaklařımı kullanılmıřtır. Bu algoritma, kaza verilerinde ve ađ verilerinde ortak olan özellik deđerlerini içeren vektörlere dayanmaktadır. Her özellik dođru yol bölümlerinin tanımlanmasına eşit olarak katkıda bulunmadığından, tek katmanlı algılayıcısını kullanan bir YSA yaklařımı, her bir özelliğin mesafe hesaplamasında ve dolayısıyla dođru bađlantı tanımlamasında göreceli öneminin öğrenilmesine yardımcı olmak için kullanılmıřtır. Geliřtirilen algoritmanın performansı, dođruluğun diđer yöntemlerden çok daha iyi olduđunu teyit eden İngiltere'deki bir referans kaza veri setine dayanarak deđerlendirilmiřtir.

Delen ve arkadaşları (2006), bir otomobil kazasında sürücülerin ve yolcuların ölüm veya yaralanma durumlarının anlaşılması, genel sürüş güvenliđi durumunun iyileřtirilmesine yardımcı olabilir. Bir otomobil kazası durumunda yolcuların artan yaralanma riskini etkileyen faktörler arasında, kiřinin demografik veya davranıř özellikleri, kaza meydana geldiđi andaki çevresel faktörler ve karayolu kořulları, aracın kendisinin teknik özellikleri bulunmaktadır. Bu çalıřma, yaralanma řiddeti seviyeleri ve kaza ile ilgili faktörler arasındaki potansiyel olarak dođrusal olmayan iliřkileri modellemek için bir dizi yapay sinir ađını kullanmaktadır. Daha sonra, farklı yaralanma řiddeti seviyelerine uygulandıklarında çarpıřma ile ilgili faktörlerin öncelikli önemini belirlemek için eđitilmiş sinir ađı modellerinde duyarlılık analizi yapılmaktadır. Bu süreçte, beř sınıflı tahmin sorunu, "dođru" kelimesini tanımlamak için gereken bilginin ayrıntı derecesini elde etmek için bir dizi ikili tahmin modeline ayrıştırılır. Kazayla ilgili faktörler ile farklı yaralanma řiddeti düzeyleri arasındaki sebep-sonuç iliřkileri araştırılmaktadır. Çođunlukla önceki çalıřmaların bulguları ile dođrulanmıř olan sonuçlar, deđerşen yaralanma řiddeti seviyelerinde çarpıřma faktörlerinin deđerşen önemine dair iç görü sađlar.

Depaire ve arkadaşları (2008), trafik kazası verileri çođu zaman heterojendir ve bu da belirli iliřkilerin gizli kalmasına neden olabilmektedir. Bu nedenle, trafik kazası analizi genellikle küçük bir trafik kazası alt kümesinde yapılır veya çeřitli trafik kazası türleri için birkaç model yapılır. Bu yazıda, kümelenme tekniđinin homojen trafik kazası türlerinin tanımlanmasındaki etkinliđini, örneğin gizli sınıf kümelemesini incelemektedir. İlk olarak, heterojen bir trafik kazası veri seti yedi trafik kazası türüne çevrilen yedi kümeye ayrılmıřtır. İkincisi, her küme için yaralanma analizi yapılmıřtır. Bu kümelenmeye dayalı analizlerin sonuçları, tam veri analizinin sonuçlarıyla karşılaştırılmıřtır. Bu, gizli sınıf kümelemesini bir ön analiz olarak

uygulamanın gizli ilişkileri ortaya çıkarabileceğini ve alan uzmanına veya trafik güvenliği araştırmacısına trafik kazalarını bölümlere ayırmada yardımcı olabileceğini göstermektedir.

Deublein ve arkadaşları (2013), trafik kazalarının oluşmasının öngörülmesi için yeni bir metodoloji sunulmaktadır. Metodoloji, üç istatistiksel yöntemin bir kombinasyonu ile kullanılmaktadır. Bu üç yöntem; yaralanma kazaları ve yaralı yol kullanıcılarının meydana gelme oranlarının gama ile güncellenmesi, çoklu bağımlı model yanıt değişkenleri ve etkileri arasındaki korelasyonları dikkate alarak hiyerarşik çok değişkenli Poisson-lognormal regresyon analizi ayrık kaza sayımı verilerinin fazla yayılması ve risk gösteren ve model cevap değişkenleri arasındaki doğrusallığı olmayanlar ve ayrıca farklı olan belirsizlik türlerini temsil etmek amacıyla Bayesian Probabilizmi Networks tarafından desteklenen veri madenciliği teknikleri ile uygulanan Bayesian çıkarım algoritmaları belirli modellerin geliştirilmesinde etkili olmaktadır. Metodoloji, Avusturya kırsal otoyol ağının verilerinin kullanıldığı bir örnek olay incelemesinde gösterilmektedir. Örnek olay incelemesinde, rastgele seçilen yol bölümlerinde, bir yaralanma meydana gelmesi beklenen kaza sayısını ve beklenen hafif, ağır ve ölümcül şekilde olmak üzere yol kullanıcılarının sayısını tahmin etmek üzere bir model üretmek için kullanılmaktadır. Ek olarak, metodoloji, iki Avusturya şehri arasındaki karayolu bağlantısındaki yaralanma kaza olaylarının görülme ihtimalinin artmasıyla birlikte yol bölümlerinin coğrafi referanslı tanımlaması için kullanılmaktadır. Önerilen metodolojinin, gerekli verilerin mevcut olması şartıyla, herhangi bir yol ağı ve yol kazalarının meydana geldiğini tahmin edip modeller geliştirmek için kullanılabileceği göstermektedir.

Durduran (2010), trafik kazalarının tahmini hayatımızdaki en önemli konulardan biridir. Trafik kazalarının tahmininde; gün, sıcaklık, nem, hava koşulları ve meydana gelen trafik kazalarının olduğu ay gibi önemli özellikleri çıkarmak için bir CBS platformu kullanılmaktadır. Bu çalışmada, çevresel vektöre bağlı risk faktörlerini belirleyen trafik kazalarını tahmin etmek için korelasyona dayalı özellik seçimi ve destek vektör makinesi (SVM) ve yapay sinir ağı (YSA) içeren sınıflandırma algoritmalarına dayalı bir karar verme sistemi (DMS) önerilmektedir. Coğrafi bilgi sistemleri (GIS) ile Konya-Afyonkarahisar karayolunda motorlu taşıt kazalarına bağlı (klimatolojik) koşullar, motorlu taşıt kazalarının yerleri, ArcGIS 9.0'daki dinamik bölümlendirme işlemi ile İlçe Trafik Ajansı tarafından kaydedilen trafik kazası raporlarından tespit edilmektedir. Bu DMS'de, ilk olarak, beş özellikli (ay, sıcaklık, nem, hava koşulları ve meydana gelen trafik kazalarının ayı), beş setli veri kümesi, veri kümesi boyutlarının sayısı, korelasyona dayalı özellik seçimi (CFS) kullanılarak 5'ten 1'e düşürülmektedir. CFS

yönteminde, beş özellik ile çıktı arasındaki korelasyon katsayıları (kazasız veya kazasız olanlar) hesaplanmış ve en yüksek korelasyon katsayısına sahip olan özellik seçilmiştir. İkinci olarak, bir özellikli trafik kazası vakaları, SVM ve ANN modelleri kullanılarak kazasız veya kaza sonucu olarak sınıflandırılmaktadır. Önerilen DMS, ANN sınıflandırıcısı ile%61,79'luk tahmin doğruluğunu elde etmiş ve RBF (radyal temel işlevi) çekirdeği ile SVM kullanarak% 67.42'lik tahmin doğruluğunu elde edilmiştir. Bu sonuçlar, önerilen DMS'nin gerçek trafik kazalarının tahmininde kullanılabilceğini göstermektedir.

Garrido ve arkadaşları (2014), sipariş edilen probit modeli, birçok faktörün, trafik kazalarına karışan motorlu taşıt yolcularının karşılaştığı ciddiyetine katkısını incelemek için kullanılmaktadır. Tahmini sonuçlar, hafif araçlarda, iki yönlü yollarda ve kuru yol yüzeylerinde seyahat eden motorlu taşıt yolcularının, ağır vasıtalarda, tek yönlü yollarda ve ıslak yolda seyahat edenlere göre daha ağır yaralanmalara maruz kalma eğiliminde olduğunu göstermektedir. Ek olarak, sürücü koltuğu açıkça en güvenli oturma pozisyonudur, kentsel alanlar meralar alanlardan daha az ciddi kazalara neden olmuş gibi görünmektedir ve kadınların erkeklerden daha ciddi veya ölümcül yaralanmalara maruz kalma olasılığı daha yüksektir. Sonuçlar ve pratik uygulamalar. Çok değişkenli zaman serilerinin analizine dayanan sarhoş sürüş tespiti uygulanabilmekte ve etkilemektedir. Yaklaşımın sarhoş sürüş tespiti için etkileri bulunmaktadır.

Hashimoto ve arkadaşları (2016), Japonya'da trafik kazası sıklığı son yıllarda azalmaktadır. Bununla birlikte, konutlarda hala birçok kaza meydana gelmektedir. Yerleşim yerlerinde 30 km / s hız sınırını belirleyerek trafiği caydıran Bölge 30'da dahil olmak üzere alan genelinde trafik sakinleştirici önlemler uygulanmaktadır. Ancak, nesnel bir uygulama yöntemi oluşturulmamıştır. CBS verisi ile açıklanan trafik kazası yoğunluğu tahmini için bir modelin geliştirilmesi, bölge genelinde trafik sakinliğinin tercihli olarak nerede uygulanabileceğini belirterek tehlikeli alanların objektif ve kolay bir şekilde belirlenmesini sağlayabilmektedir. Bu çalışma trafik kazaları ile nüfus, yol faktörleri ve mekansal faktörler gibi şehir özellikleri arasındaki ilişkileri incelemiştir. Trafik kazası yoğunluğunu tahmin etmek için bir model geliştirilmektedir. İlişkileri etkin bir şekilde değerlendirmek için çekirdek yoğunluğu kestirimi (KDE) teknikleri kullanılmaktadır. Ayrıca, kaza yerleri, kaza tipleri ve veri tipleri birleştirilerek 16 model geliştirilmiştir. Bunları kullanarak, trafik kazası yoğunluğu tahmin modellerinin uygulanabilirliği incelenmiştir. Spearman sıra korelasyonu kullanılarak elde edilen sonuçlar, öngörülen sayı ile gerçek sayı arasındaki yüksek katsayıları göstermektedir. Model, şehirlerde

göreceli kaza riskini göstermektedir. Bu çalışmanın sonuçları, yeterli trafik kazası verisi olmasa bile, bölge genelinde trafik sakinleşmesinin uygulanabileceği alanların objektif olarak belirlenmesi için kullanılabilir.

Hojati ve arkadaşları (2014), trafik olayları, tıkanıklığa neden olan ve potansiyel olarak önemli gecikmeler sağlayan kilit unsurlardır. Olayların süresini etkileyen faktörlerin, etkili azaltma stratejilerinin uygulanabilmesi için anlaşılması önemlidir. Etkili faktörlerin etkilerini tanımlamak ve ölçmek için, 'bütünleşik bir veri tabanından' geçmiş verilere dayanarak toplam olay süresini incelemek için bir metodoloji önerilmektedir. Olay süresi modelleri, Güneydoğu Queensland, Avustralya ağında seçilen bir otoyol segmenti kullanılarak geliştirilmektedir. Modeller, olay süresinin bileşenleri olarak olay algılama ve geri kazanım süresini de içerir. Trafik olay süresini etkileyen çeşitli faktörlerin bir fonksiyonu olarak model olay süresine tehlike bazlı bir süre modelleme yaklaşımı uygulanmaktadır. Parametrik hızlandırılmış arıza süresi hayatta kalma modelleri, hem sabit hem de rastgele parametre spesifikasyonları ile açıklayıcı değişkenlerin bir fonksiyonu olarak heterojenliği yakalamak için geliştirilmektedir. Analiz, olay süresini etkileyen faktörlerin olay özelliklerini (şiddet, tip, yaralanma, tıbbi gereksinimler vb.), altyapı özelliklerini, günün saatini ve trafik özelliklerini içerdiğini ortaya koymaktadır. Sonuçlar, olay türü sürelerinin benzersiz bir şekilde farklı olduğunu ve dolayısıyla bunların etkin bir şekilde giderilmesi için farklı yanıtlar gerektirdiğini göstermektedir. Ayrıca, sonuçlar rasgele parametre modelleri tarafından yakalanan gözlemlenmemiş olay süresi heterojenliğinin varlığını vurgulayarak gelecekteki modelleme çabalarında ek faktörlerin göz önünde bulundurulması gerektiğini ortaya koymaktadır.

Huang H. ve arkadaşları (2019), iç gürültü, saf elektrikli taşıtlardaki (EV) yolcuların fizyolojik ve psikolojik algılarını büyük ölçüde etkilemektedir. EV iç ses kalitesini değerlendirmek için akustik tahmin modelleri ve akustik ölçümlerin gelişimini inceleyen çok sayıda çalışma bulunmaktadır. Bununla birlikte, mevcut araştırmalar aşağıdaki dört eksikliğe sahiptir. Bunlar; EV'lerin iç gürültüsü yalnızca genel yollarda incelenmiştir ve çok az sayıda EV örneği test edilmiştir, fiziksel akustik metrikler ve psikoakustik metrikler, EV'lerin iç gürültüsünün tüm özelliklerini kapsamlı bir şekilde yansıtmamaktadır, akustik tahmin modellerine eklenen özellikler manuel olarak çıkarılmakta ve seçilmekte, daha önce akustik teori ve deneyim bilgisine bağlamaktadır, ve iç gürültüyü değerlendirmek için kullanılan en yaygın akustik tahmin modelleri, sıg mimarilere sahip olmaktadır. Bu eksikliklerin üstesinden gelmek için, Laplacian skor derin inanç ağı (LS-DBN) adı verilen derin sinir ağlarına (DNN) dayanan yeni

bir akıllı akustik model ortaya konulmuştur. EV iç gürültüsünün ses kalitesini değerlendirmek için LS-DBN'yi kullanılmaktadır. Önerilen yöntemin etkinliğini doğrulamak için, EV'nin iç sesleri sekiz farklı yol yüzeyine kaydedilmekte ve karşılık gelen öznel değerlendirmeler yapılmaktadır. Ek olarak, gürültü özellikleri LS-DBN kullanılarak uyarlamalı olarak çıkarılmakta, uyarlamalı olarak çıkartılmış özellikler ve elle çıkartılmış özellikler karşılaştırılmaktadır. LS-DBN'nin performansı, geleneksel bir DBN ve bir geri yayılım sinir ağına (BPNN) karşı doğrulanmaktadır. Sonuçlar, önerilen LS-Dterm doğruluğunun ve kararlılığının ve bunun çok verimli olduğunu göstermektedir. Böylece, LS-DBN, EV'lerin iç ses kalitesini değerlendirirken iyi tahmin sonuçları elde edilmektedir.

Ihueze ve arkadaşları (2018), günümüzde dünyadaki en büyük sorunlardan biri yol trafik kazalarının ve yollarımızdaki ölümlerin oranıdır. Bu ölümlerin büyük çoğunluğu Nijerya dahil düşük ve orta gelirli ülkelerde ortaya çıkmaktadır. Bu çalışma, Nijerya'daki Anambra Eyaletindeki karayolu trafik kazalarını, otoregressive entegre hareketli ortalama (ARIMA) ve otoregressive entegre hareketli ortalama kullanarak açıklayıcı değişken (ARIMAX) modelleme teknikleri kullanarak devlette kaza sıklığını tahmin etmek için doğru öngörücü modeller geliştirmek amacıyla analiz edilmiştir. Sonuç, ARIMAX modelinin, performansları, düşük Bayesian bilgi kriteri, ortalama mutlak yüzde hatası, ortalama kare kare hatası kullanılarak karşılaştırıldığında oluşturulan ARIMA (1,1,1) modelinden daha iyi performans gösterdiğini göstermiştir. Bu çalışmanın bulguları, insan, araç ve çevre ile ilgili faktörlerin kaza veri setinin zaman serisi analizine dahil edilmesinin, sadece toplam çarpışma sayımını kullanmaktan daha güçlü bir öngörü modeli ürettiğini ortaya koymaktadır. Bu çalışma, karayolu trafik güvenliği konusundaki bilgi birikimine katkıda bulunur ve birçok insan, araç ve çevresel faktör kullanarak tahmin etmeye bir yaklaşım sağlar. Bu çalışmada uygulanan tavsiyeler Nijerya'da trafik kazalarının azaltılmasında yardımcı olacaktır.

Iranitalab ve arkadaşları (2017), çarpışma şiddeti tahmin modelleri, farklı kurumların, bilinmeyen bir şiddete sahip olduğu bildirilmiş bir çarpışmanın ciddiyetini veya gelecekte ortaya çıkması beklenen kazaların ciddiyetini tahmin etmesini sağlamaktadır. Bu yazının üç ana amacı vardır: İlki trafik kazalarının ciddiyetini tahmin etmede Multinomial Logit (MNL), En Yakın Komşu Sınıflandırması (NNC), Destek Vektör Makineleri (SVM) ve Random Forest (RF) dâhil olmak üzere dört istatistiksel ve makine öğrenme yönteminin performansının karşılaştırılmasıdır. İkinci olarak çarpma şiddeti tahmin yöntemlerinin karşılaştırılması için çarpma maliyetlerine dayalı bir yaklaşımın geliştirilmesidir. Son olarak ta K-ortalama

Kümeleme (KC) ve Latent Sınıf Kümeleme (LCC) içeren veri kümeleme yöntemlerinin çarpışma şiddeti tahmin modellerinin performansına etkilerinin araştırılmasıdır. 2012-2015, ABD, Nebraska'dan gelen çarpışma verileri kullanılmıştır. Veri seti eğitim / tahmin (2012-2014) ve validasyon (2015) alt gruplarına ayrılmıştır. Dört tahmin yöntemi, eğitim / tahmin veri seti kullanılarak eğitildi / tahmin edildi ve her bir çarpışma ciddiyeti seviyesi için doğru tahmin oranları, genel olarak doğru tahmin oranı ve validasyon veri seti için önerilen çarpışma maliyetine dayalı bir doğruluk ölçütü elde edildi.

Kaplan ve arkadaşları (2012), son yıllarda dünya çapında otobüs güvenliği operasyonlarının iyileştirilmesine artan ilgiye tanık olmaktadır. Amerika Birleşik Devletleri'nde otobüsler göreceli olarak güvenli kabul edilirken, otobüs kazalarının sayısının göz ardı edilmemesi, 2011 yılı Motorlu Antrenör Geliştirilmiş Güvenlik Yasası'nın başlatılmasını tetiklemektedir. Bu çalışma, geliştirilmiş bir sıralı logit modelini tahmin ederek Amerika Birleşik Devletleri'nde otobüs kazası ciddiyetinin altında yatan risk faktörlerini araştırmaktadır. Analiz verileri, 2005–2009 yılları arasındaki Genel Tahminler Sistemi (GES) veri tabanından alınmaktadır. Kazaların artmasının sebepleri; 25 yaşın altındaki genç otobüs sürücüleri, 55 yaşın üzerindeki sürücüler ve en önemlisi 65 yaş üstü sürücüler, kadın sürücüler, çok yüksek (65 mil / saatin üzerinde) ve çok düşük (20 mil / saatin altında) hız sınırları, kavşaklarda, dikkatsiz ve riskli sürüş nedeniyle meydana gelmektedir.

Kashani ve arkadaşları (2011), iki şeritli, iki yollu yollar, dünyanın çoğu ülkesinde kırsal yolların büyük bir bölümünü oluşturmaktadır. Bu çalışma İran'daki bu yollarda kaza yaralanmasının ciddiyetini etkileyen faktörleri tanımlamaktadır. Veri madenciliğinin en yaygın yöntemlerinden biri olan sınıflandırma ve regresyon ağaçları (CART), 3 yıl boyunca İran'ın ana iki şeritli, iki yönlü kırsal yollarının trafik kaza verilerini analiz etmek için kullanılmıştır. Analiz prosedüründe, üç sınıflı tahmin sorunu, bir dizi ikili tahmin modeline ayrıştırıldı ve bu modelin tahminlerinin daha yüksek bir genel doğruluğuna yol açmıştır. Ek olarak, önceki çalışmaların bazılarında neredeyse % 0 olan ölüm sınıfının tahmin doğruluğu önemli ölçüde artmaktadır. Sonuçlar, uygun olmayan sollama ve emniyet kemeri kullanmamanın, yaralanmaların ciddiyetini etkileyen en önemli faktör olduğunu göstermektedir.

Kinoshita ve arkadaşları (2015), trafik sıkışıklığı kentsel ortamlarda sık sık meydana gelir ve her zaman trafik olaylarından kaynaklanmamaktadır. Bu yazıda, olayları kendiliğinden tikanıklıktan ayıran olağandışı olayları tespit ederek, araç verilerinden gelen trafik olaylarını

tespit etmek için basit bir yöntem önerilmektedir. İlk olarak, çeşitli yollara ilişkin trafik durumlarını tanımlamak için olasılıksal bir konu modeline dayanan bir trafik durumu modeli tanıtıyoruz. Model parametrelerini tahmin etmeye yönelik formüller türetilmiştir, böylece normal trafik modeli bir beklenti-maksimizasyon algoritması kullanılarak öğrenilebilir. Daha sonra, mevcut ve normal trafik durumları arasındaki farkları değerlendirmek için çeşitli sapma fonksiyonları ve gerçek zamanlı olarak yüksek sapma segmentlerini tespit eden akış algoritmaları öneriyoruz. 2010 ve 2011 yıllarında Tokyo'daki tüm Shuto Expressway sistemi için toplanan verilerle bir deney yaptık. Sonuçlar, yöntemimizin, anormal araç yörüngeleri ve daha olağan, yavaş hareket eden trafik düzenleri arasında başarılı bir şekilde ayırım yaptığını gösterdi.

Kwon ve arkadaşları (2015), ulaşım, modern yaşamın ayrılmaz bir parçası olmaya devam etmekte olup ve karayolu trafik güvenliğinin önemi göz ardı edilemez duruma gelmektedir. Son zamanlarda yapılan karayolu trafik güvenliği çalışmaları, trafik kazalarının ölümcül ve yaralanma seviyesini (şiddetini) etkileyen risk faktörlerinin analizine odaklanmaktadır. Uyuşturucu kullanımı gibi bazı risk faktörlerinin ciddiyeti etkilediği yaygın olarak bilinmekle birlikte, etkilerinin doğru bir şekilde modellenmesi hala açık bir araştırma ve tartışma konusudur. Ayrıca, keşfedilmeyi ve analiz edilmeyi bekleyen sayısız risk faktörü vardır. Umut verici bir yaklaşım olarak, geçmiş yıllarda toplanan trafik kazası verileri araştırılmaktadır. Bu çalışma, her kaza raporunun yaklaşık 100 veri alanı içerdiği 1973'ten bu yana Kaliforniya Karayolu Devriyesi (CHP) tarafından toplanan trafik kazası raporlarını incelemektedir. Bunlardan 2004 ile 2010 yılları arasında araba kazalarıyla en alakalı 25 alanı araştırılmakta olup iki sınıflandırma yöntemi, Naive Bayes sınıflandırıcısı ve karar ağacı sınıflandırıcısı kullanılmıştır. Veri alanlarının, yani risk faktörlerinin göreceli önemi, ortaya çıkan ciddiyet seviyesine göre açıklanmaktadır. Sınıflandırıcıların performansları birbirleriyle karşılaştırılmaktadır. Bu karşılaştırmalar için temel olarak ikili bir lojistik regresyon modeli kullanılmaktadır. Yüksek rütbeli risk faktörlerinden bazılarının birbirlerine çok güçlü bir şekilde bağımlı olduğu görülmekte olup önem derecesinin tahmin edilmesi veya modellenmesi konusundaki artan kazanımları nicel olarak değerlendirilmektedir. Analiz, verilerdeki risk faktörlerinin sadece bir kısmının ciddiyet seviyesine egemen olmakla birlikte en üst risk faktörleri arasındaki bağımlılığın doğru bir analiz için göz önünde bulundurulması zorunlu bir özellik olduğunu göstermektedir.

Li Y. ve arkadaşları (2018), trafik kazalarının önemli faktörlerinin belirlenmesi, uzun yıllardan beri ulaşım güvenliği araştırma topluluğunun temel sorunlarından biri olmuştur. Ölümcül yaralanma kazası, kaza senaryosu anında yer alan birden fazla değişkenden etkilenen kapsamlı bir sonuçtur. Bu makalenin ana fikri, çok amaçlı bir optimizasyon (MOP) açısından önemli faktörlerin belirlenmesi sürecini araştırmaktır. En uygun çözümleri etkin bir şekilde bulmak için, Baskın Olmayan Sıralama Genetik Algoritmasını (NSGA-II) Sinir Ağı (NN) mimarisıyla birleştiren veri odaklı bir model sunar. Bu makale ayrıca, her bir faktörün öneminin nicel değerlendirmesi için Faktör Önemi endeksini (Fs) de tanımlar. Washington Eyaletindeki üç ana eyaletler arası otoyoldan toplanan üç yıllık kaza kayıtlarına dayanarak, önerilen yöntem daha iyi bir ölümcül yaralanma kazasının tespiti için ilk beş önemli faktör; sürücü davranışı, araç eylemi olduğunu ortaya koymak, yol yüzey durumu, sürücü kısıtlama ve sürücü yaşıdır. Bu makaledeki yöntem ve sonuçlar, karayolu kazalarının yaralanma düzenine dair yeni bilgiler sağlar ve gelecekte yaralanma kazalarına ilişkin anlayışı, önlenmesini ve diğer uygulama çabalarını geliştirmek için kullanılabilir.

Li Z. ve arkadaşları (2015), çok değişkenli zaman serilerinin sınıflandırmasına dayanan sarhoş sürüş tespit problemini ele almaktadır. İlk olarak, Pekin Teknoloji Üniversitesi, Trafik Araştırma Merkezi'nde bulunan bir sürüş simülatöründeki bir testten sürüş performansı ölçümleri alındı. Sarhoş sürüşü tespit etmek için yanal pozisyon ve direksiyon açısı kullanılmıştır. İkincisi, özellikleri çıkarmak için çok değişkenli zaman serisi analizi yapılmıştır. Çok değişkenli zaman serilerini temsil etmek için parça parça doğrusal bir temsil kullanılmıştır. Çok değişkenli zaman serilerini ayırmak için aşağıdan yukarıya bir algoritma kullanıldı. Her bölümün eğimi ve zaman aralığı, sınıflandırma özellikleri olarak çıkarıldı. Üçüncü olarak, çıkarılan özelliklere göre sürücünün durumunu iki sınıfa (normal veya sarhoş) sınıflandırmak için bir destek vektör makinesi sınıflandırıcısı kullanılmıştır. Önerilen yaklaşım %80 doğruluk sağlamıştır.

Lin ve arkadaşları (2015), bu makale yeni bir Sık Kullanılan Desen ağacı (FP ağacı) tabanlı değişken seçim yöntemi önermektedir. Bu yöntem ilk olarak trafik kazası veri setindeki tüm sık kullanılan kalıpları tanımlayarak çalışmaktadır. Daha sonra, her sık kullanılan patern için, burada Görel Nesne Saflık Oranı (ROPR) olarak adlandırılan yeni bir metrik tanıtmaktadır. ROPR daha sonra kaza düzenini açıklamaya en fazla katkı yapan değişkenleri sıralamak ve seçmek için kullanılabilen her açıklayıcı değişkenin önem puanını hesaplamak için kullanılmaktadır. Önerilen değişken seçim yönteminin avantajlarını göstermek için, çalışma

Virginia eyaletinde 1-64 arası karayolu üzerinde toplanan kaza verilerine dayanan iki trafik kazası riski tahmin modeli geliştirmektedir. Sonuçlar, FP ağacına dayalı kaza riski tahmin modellerinin, tahmin modellerinin türüne (yani en yakın komşu veya Bayesian ağı), parametrelerinin ayarlarına ve veri tiplerine bakılmaksızın rastgele orman bazlı modellerden daha iyi performans gösterdiğini göstermektedir. Model eğitimi ve testi için kullanıldı. Bulunan en iyi model, % 38,16 yanlış alarm oranına sahipken kazaların % 61,11'ini tahmin edebilen FP ağaç tabanlı bir Bayesian ağ modelidir. Bu sonuçlar, literatürde bildirilen diğer kaza tahmin modelleri ile oldukça olumlu bir şekilde karşılaştırmaktadır.

Liu ve arkadaşları (2018), bu yazıda, uygunluk incelemesine dayalı bir derecelendirme (tatmin edici, koşullu tatmin edici ve yetersiz) değil, bir çarpışma oranı seviyesini (yüksek, orta ve düşük) ele almaktadır. Üç farklı sınıflandırma modeli (Yapay Sinir Ağı, Sınıflandırma ve Regresyon Ağacı (CART) ve Destek Vektör Makinesi) ve üç ayrı değişken seçim yöntemi (Ampirik Kanıt, Çoklu Faktör Analizi) kullanarak her bir taşıyıcı için çarpma oranı seviyelerini tahmin etmenin otomatik bir yolunu göstermektedir, Garson algoritması). Öngörülen çarpışma oranı seviyeleri (yüksek, düşük), geçerli güvenlik derecelendirme yöntemine dayanarak belirlenen seviyelerle karşılaştırılmaktadır. Sonuçlar, CART'ın en iyi performansa sahip olmasıyla, çarpışma oranı seviyesinin uygulanabilir bir taşıyıcı güvenliği önlemi olarak uygulanabilirliğini göstermektedir.

Mannering ve arkadaşları (2014), bu makale, öncelikle karayolu kaza araştırmalarındaki metodolojik uygulamaların ve mevcut verilerin evrimini gözden geçirerek bu zorlukların ve fırsatların belirlenmesinde yol gösterici olmaktadır. Bu incelemeye dayanarak, gelecekteki metodolojik gelişmeler için verimli talimatlar tanımlanmış ve bu yönlendirmeleri tanımlarken yeni veri kaynaklarının oynayacağı rol ele alınmıştır. Gözlemlenmemiş heterojenlik, endojenlik, risk telafisi, mekansal ve zamansal korelasyonlar ve daha fazlası ile ilgili karmaşık meseleleri ele alan yeni metodolojilerin ve daha pek çoğunun, olasılık ve ciddiyeti etkileyen birçok faktöre ilişkin anlayışımızı önemli ölçüde genişletme potansiyeline sahip olduğu gösterilmiştir. kişisel kazalar) otoyol kazaları. Bu da, karayolu ile ilgili yaralanma ve ölümleri önemli ölçüde azaltabilecek daha etkili güvenlik önlemlerine yol açabilir.

Mannering ve arkadaşları (2016), karayolu kazaları, taşıt, yol özellikleri ve durumu, trafikle ilgili faktörler ve çevresel koşullar arasındaki karmaşık etkileşimlerin yanı sıra, dış uyaranlara çeşitli insan tepkilerini içeren karmaşık olaylardır. Ek olarak, taşıt tasarımı, darbe açıları, ilgili

insanların fizyolojik özellikleri ve diğer faktörlerle ilgili olarak enerji dağıtımında (bir kaza meydana geldiğinde) karışan karmaşıklıklar vardır. Böyle karmaşık bir süreçle, bir otoyol kazası olasılığını veya bunun sonucunda ortaya çıkan yaralanma ciddiyetini potansiyel olarak belirleyebilecek tüm verilere erişilemez. Bu tür önemli verilerin bulunmaması, önyargılı ve tutarsız parametre tahminlerine, hatalı çıkarımlara ve hatalı kaza tahminlerine yol açabilecek geleneksel istatistiksel analizler için ciddi şartname problemleri oluşturabilir. Bu makale, kaza verisi ve analizi bağlamında bu sorunun (tipik olarak gözlemlenmemiş heterojenlik olarak adlandırılır) ayrıntılı bir tartışmasını sunar. Bu gözlemlenmemiş heterojenliği ele almak için mevcut çeşitli istatistiksel yaklaşımlar, güçlü ve zayıf yönleriyle birlikte sunulmaktadır. Bu makale, gözlemlenmemiş heterojenliği ele alan gelecekteki metodolojik çalışmalar için temel konuların ve yönlerin bir özeti ile sona ermektedir.

Naurois ve arkadaşları (2017), bu çalışma, uyusukluğu tespit etmek için kullanılan standart bilgi kaynaklarının belirli bir uyusukluk seviyesine ne zaman ulaşılacağını öngörmeye kullanılıp kullanılmayacağını belirlemeyi amaçlamaktadır. Dahası, sürüş süresi ve katılımcı bilgileri gibi verilerin eklenmesinin uyusukluğun tespit edilmesinin ve tahmin edilmesinin doğruluğunu iyileştirip iyileştirmediğini araştırmaktadır. Yirmi bir katılımcı, uyku hali yaratması için optimize edilmiş koşullar altında 110 dakika boyunca bir araba simülatörü kullanılmıştır. Kalp atış hızı ve değişkenlik, solunum hızı, kafa ve göz kapağı hareketleri (göz kırpma süresi, sıklık ve PERCLOS) gibi fizyolojik ve davranışsal göstergeleri ölçtük ve şeritleme süresi, hız, direksiyon açısı, şerit üzerindeki konum gibi sürüş davranışını kaydettik. Bu bilgilerin farklı kombinasyonları, Sürücünün gerçek durumuna, yani Eğitilmiş Gözlemci Derecelendirmesi aracılığıyla video kayıtlarından tanımlandığı gibi temel gerçekliğe karşı test edilmiştir. Yapay sinir ağlarını kullanan iki model geliştirilmiş, biri her dakika uyusukluk derecesini tespit etmek için diğeri ise her dakika belirli bir uyusukluk seviyesine ulaşmak için gereken zamanı (orta derecede uyusuk) tahmin etmek için geliştirilmiştir. Hem algılama hem de öngörmedeki en iyi performans, davranış göstergeleri ve ek bilgilerle elde edilmektedir. Model, 0,22'lik ortalama bir kare hatası ile uyusukluk seviyesini tespit edebilmekte ve verilen bir uyusukluk seviyesinin 4,18 dakikalık bir ortalama kare hatası ile ne zaman ulaşılacağını tahmin edebilmektedir. Bu çalışma, bir sürüş simülatöründe uyusukluğa neden olan kontrollü ve çok monoton bir ortamda, sürücü bozulmasının dinamiklerini tahmin edebileceğini göstermektedir.

Ona ve arkadaşları (2011), bu makale, trafik kazalarını yaralanma ciddiyetine göre sınıflandırmak için Bayesian Networks (BNs) kullanma olasılığını göstermektedir. BN'ler ön

varsayımlara ihtiyaç duymadan tahminler yapabilir ve birbirleriyle ilişkili bileşenlerle karmaşık sistemlerin grafik gösterimlerini yapmak için kullanılır. Bu yazıda, İspanya'daki kırsal otoyollarda 1536 kaza ile ilgili bir analiz sunulmuştur; burada, söz konusu katkıda bulunan faktörleri temsil eden 18 değişken, kazaların ciddiyetini hafif yaralanıp öldürülen veya ağır şekilde yaralanan olarak sınıflandırmış 3 farklı BN oluşturmak için kullanılmıştır. Öldürülen veya ağır şekilde yaralanan bir kazayla ilişkilendirilen faktörleri en iyi tanımlayan değişkenler (kaza türü, sürücü yaşı, aydınlatma ve yaralanma sayısı) çıkarımla belirlendi.

Ona ve arkadaşları (2013), bu yazıda, Latent Sınıf Kümesi (LCC), 2005 ve 2008 yılları arasında Granada'da (İspanya) kırsal otoyollardaki 3229 kazalarının bölümlendirilmesinde ön bir araç olarak kullanılmaktadır. Her ikisi için kaza ciddiyeti, tüm veritabanı (EDB) ve daha önce LCC tarafından elde edilen kümeler. Bu kümelenmeye dayalı analizlerin sonuçları, tam veri analizinin sonuçlarıyla karşılaştırılmaktadır. Sonuçlar, her iki tekniğin bir arada kullanılmasının, verilerin daha önce bölümlere ayrılmadan elde edilemeyecek daha fazla bilgiyi ortaya çıkarması nedeniyle çok ilginç olduğunu göstermektedir. BN çıkarımı, öldürülen veya ağır şekilde yaralanan kazaları en iyi tanımlayan değişkenleri elde etmek için kullanılır. Kaza tipi ve görüş mesafesi analiz edilen tüm durumlarda tespit edilmiştir; zaman, işgalci veya yaş gibi diğer değişkenler EDB'de ve sadece bir kümede tanımlanır; katılan değişken araçlar, yaralanma sayısı, atmosferik faktörler, kaldırım işaretleri ve kaldırım genişliği yalnızca bir kümede tanımlanmaktadır.

Qin ve arkadaşları (2010), bu çalışmada, kuantil regresyon olarak bilinen bir regresyon tekniği kullanılmaktadır. Kuantil regresyon, farklı kuantillerdeki trendleri tahmin etme esnekliğini sunmaktadır. Özellikle heterojenite ile veri özetlemek için kullanışlıdır. Burada, ciddi güvenlik sorunlarıyla kesişme noktalarının belirlenmesi için uygulamayı düşünmekteyiz. Risk eğilimli kesişme noktalarının belirlenmesi için çeşitli klasik yaklaşımlar da kullanılmaktadır. Bulgularımız, diğer yöntemlere göre, kuantil regresyonun risk eğilimli konumlarına duyarlı ve çok daha rafine bir alt kümesini verdiği tespit etmektedir.

Sam ve arkadaşları (2018), bu çalışmada, 2011-2015 yılları arasındaki otobüs / minibüs kaza verilerini kullanarak Gana'daki otobüs / minibüs kaza şiddetini etkileyen faktörler incelenmiştir. Genelleştirilmiş sipariş logit modellerini kullanarak, otobüs / minibüs kazalarının ciddiyeti tahmin edilmiştir. Bulgularımız, hafta sonları, yol medyanı yokluğunun, gece koşullarının, kötü yol arazisinin (kavisli, ıslak ve engebeli yolların) yokluğunun, hit-yaya

çarpışmalarının ve sarhoş sürüşün, daha ciddi otobüs / minibüs kaza sonuçlarıyla ilişkili olduğunu ortaya koymuştur. Buna karşılık, minibüsler, yol omuzlarının olmaması, kavşaklardaki kazalar, trafik kontrolünün varlığı ve çarpışma türleri (isabet eden yayalar hariç) daha az şiddetli otobüs / minibüs kazalarıyla ilişkilidir.

Sarkar ve arkadaşları (2019), makine öğrenimi (ML) tekniğinin gelecekteki sonuçları tahmin etmedeki faydası, farklı uygulama alanlarında (örneğin, sağlık bakımı) belirlenmiş olmasına rağmen, iş güvenliği alanındaki kazaları tahmin etmede araştırması neredeyse yeni olarak bilinmektedir. Bu, kazaların öngörülmesinde ML tekniklerinin araştırılmasını gerektirmektedir. Ancak, ML tabanlı algoritmalar, parametreleri uygun şekilde ayarlanmadan veya optimize edilmeden en iyi performansı üretememektedir. Dahası, sadece etkin bilimsel sınıflandırıcı seçimi, genel kaza-kazanım amaçlarını yerine getirmeyebilir, çünkü kazaların ortaya çıkmasının arkasındaki faktörler arasındaki ilişkileri açıklayamaz. Bu nedenle, tahminin yanı sıra, kaza verilerinden karar alma kurallarının çıkarılması gerekmektedir. Yukarıda belirtilen hususlar göz önüne alındığında, bu çalışmada, iş kazası verilerini kullanarak yaralanma, kaçırılma ve maddi hasar gibi kaza sonuçlarını tahmin etmek için optimize edilmiş makine öğrenme algoritmaları uygulanmaktadır. Parametreleri iki güçlü optimizasyon algoritmasıyla optimize edilen, yani genetik algoritma (GA) ve parçacık sürüsü optimizasyonu (PSO) olmak üzere iki popüler makine öğrenme algoritması, yani vektör makineyi (SVM) ve yapay sinir ağını (ANN) desteklemektedir. Daha yüksek hassasiyet ve sağlamlık derecesi PSO tabanlı SVM, diğer algoritmaları en yüksek doğruluk ve sağlamlık seviyesinden daha iyi performans göstermektedir. Ayrıca, PSO tabanlı SVM modeli ile karar ağacı C5.0 algoritması dahil edilerek kurallar çıkarılmaktadır. Son olarak, sakatlığın temel nedenlerinin ve mal hasarı durumlarına yakın bir şekilde belirlemek için dokuz faydalı kural çıkarılmaktadır. Bir çelik tesisinden bir vaka çalışması, önerilen metodolojiyi desteklemek için sunulmaktadır.

Savolainen ve arkadaşları (2011), motorlu taşıt kazalarından kaynaklanan yaralanmaların ciddiyetini azaltmak, uzun zamandır karayolu taşımacılığı yapan kurumların ve motorlu taşıt üreticilerinin temel vurgularından biri olmuştur. İlerleme, zamanla yaralanma seviyelerindeki azalma ile basit bir şekilde ölçülebilse de, yaralanma azaltma teknolojilerinin, politikalarının ve düzenlemelerinin etkinliğine dair içgörüler, araç, karayolu ve insan faktörlerinin ortaya çıkardığı karmaşık etkileşimlerin daha detaylı bir ampirik değerlendirmesini gerektirir. kaza-yaralanma ciddiyetleri. Yıllar boyunca, araştırmacılar bu tür faktörlerin ayrıştırma düzeyi yaralanma-ciddiyet verileri üzerindeki etkisini değerlendirmek için geniş bir yelpazede

kullanılan metodolojik araçlar kullandılar ve son metodolojik gelişmeler bu faktörlerin etkisini daha kesin olarak belirleyebilecek sofistike modellerin geliştirilmesini sağladı. . Bu makale, motorlu taşıt yaralanma ciddiyetinin istatistiksel analizi ile ilgili olduğu için araştırma ve mevcut düşüncenin evrimini özetlemekte ve gelecekteki metodolojik yönlerin bir tartışmasını sunmaktadır.

Steinbach ve arkadaşları (2019), karayolu trafik gürültüsü, çevresel gürültü kirliliğinin en can sıkıcı şeklidir. Elektrikle çalışan araçlar için yapay olarak üretilen gürültüyü kullanma zorunluluğu şu anda artmaktadır. Bununla ilgili olarak, sinir bozucu olmayan düzenlemelere ilişkin sesler üretmek önemlidir. Dünyada birçok can sıkma modeli mevcut olsa da, bu modeller bu yeni sesler için genelleştirilemez ve bir dinleme testi ile yeni üretilen her bir gürültünün sıkıntısını ölçmek çok zaman alırken, yapay sinir ağları kullanmak fikri ortaya çıkmıştır. Bu çalışmanın amacı, sabit bir hızda, tek bir araba geçişi durumunda, farklı elektrikli araç seslerinin rahatsızlığını tespit etmektir. Bu amaçla, sıkıntıdaki farklılıklar algı çalışmaları ile incelenmektedir. Bu çalışmada, fiziksel-psikoakustik parametreler ile jüri testlerinden elde edilen can sıkma tahminleri arasındaki korelasyon da incelenmektedir. Ayrıca, yapay bir sinir ağı (YSA) olası farklı uyaranların daha fazla değerlendirilmesi için sıkıntı tahminlerinin bir tahmin aracı olarak kullanılmaktadır. Genel olarak, bu çalışmada farklı gizli katmanlara sahip toplamda 150 YU modeli yapılmıştır. En iyi performans gösteren modeller, psikoakustik parametreye dayanan doğrusal regresyon modelleriyle karşılaştırılmaktadır. Son olarak, tespit edilebilirlik tahminleri için YSA kullanmanın avantajları ve eksiklikleri de tartışılmaktadır.

Tixier ve arkadaşları (2016) objektif, ampirik verilerden elde edilen bilgiler konusundaki belirsizlik altında inşaat güvenliği ile ilgili kararları temellendirmenin gereğine baskı yapmaktadır. İnşaat araştırması, makine öğrenimini (ML) yirmi yıldan daha uzun bir süredir dikkate almış olsa da, güvenlik kaygıları için henüz uygulanmamaktadır. Çok sayıda ML modeli olan Random Forest (RF) ve Stochastic Gradient Tree Boost (SGTB) modeli, büyük bir metinsel inşaat yaralanma raporları havuzundan elde edilen, dikkatlice öne çıkan özelliklere ve kategorik güvenlik sonuçlarına ait bir veri seti için uygulamaktadır. Yapılan araştırmalar neticesinde geliştirilen son derece hassas bir Doğal Dil İşleme (NLP) aracı ile modeller, literatürde bulunan parametrik modellerden daha iyi olan, yüksek beceriye sahip ($0.236 < R_{PSS} < 0.436$) yaralanma tipini, enerji tipini ve vücut kısmını tahmin edebilir. Ulaşılan yüksek öngörücü beceri, yaralanmaların rastgele meydana gelmediğini ve bu nedenle inşaat verilerinin, subjektif verilerin, uzman görüşünün, düzenleyici ve yönetsel bakış açısının analiziyle kesin bir

şekilde ele alınmasından ziyade ampirik ve nicel olarak incelenmesi gerektiğini göstermektedir. Bu, inşaat güvenliğinin deneysel temelli nicel bir bilim kabul edildiği yeni bir araştırma alanına açılan kapıdır. Son olarak, çıktı değişkeninde yaralanma ciddiyeti için öngörücü becerinin bulunmaması, diğer güvenlik sonuçlarından farklı olarak, yaralanma şiddetinin esas olarak rasgele olduğunu veya ortamdaki enerji seviyesi gibi tahminlerde ekstra tahmin katmanlarının kullanılması gerektiğini göstermektedir. Yapı güvenliği analizi bağlamında bu çalışma, sonuçların bir kaza olması durumunda muhtemel sonuçların güvenilir olasılıklı tahminlerini sağlaması ayrıca bunların ikili ve fiziksel doğası nedeniyle bina bilgi modellemesi ve iş paketlemesi ile entegrasyon için büyük potansiyel göstermesi bakımından önemli adımlar atmaktadır. Giriş değişkenleri, bu tür veriye dayalı tahminler, kuruluşundan bu yana sahadan alınmamaktadır.

Wang ve arkadaşları (2017), bu çalışma, Entegre Yuvalanmış Laplace Yaklaşımı (INLA) Çok Değişkenli Poisson Lognormal (MVPLN) modelini kullanarak kaza tipini ve kaza şiddetini tahmin etmektir ve katkıda bulunan faktörlerin kırsaldaki farklı kaza tipi ve şiddeti sayıları üzerindeki farklı etkilerini tanımlamaktır. iki şeritli otoyollar. INLA MVPLN modeli aynı zamanda çarpışma sayılarını çarpışma tipine ve çarpışma şiddetine göre modelleyebilir ve bunlar arasındaki potansiyel korelasyonları hesaba katarak Markov Chain Monte Carlo (MCMC) yöntemini kullanarak MVPLN modelinin tam bir Bayesian uyumu ile karşılaştırıldığında hesaplama süresini önemli ölçüde azaltır. Bu makalede, üç yollu durma kontrollü (3ST) kavşaklar, dört yollu durma kontrollü (4ST) kavşaklar, dört yollu sinyalize (4SG) kavşaklar ve kırsal iki şeritli otoyollarda yol bölümleri için MVPLN modellerinin tahmini açıklanmaktadır. Yıllık Ortalama Günlük trafik (AADT) ve karayolu koşullarını tanımlayan değişkenler (ışıklandırma, sola dönüş / sağa dönüş şeridi varlığı, şerit genişliği ve omuz genişliği dahil) yordayıcılar olarak kullanılmıştır. Tek değişkenli bir Poisson Lognormal (UPLN), her bir karayolu tesisi için kaza tipi ve ciddiyeti ile tahmin edildi ve tahmin sonuçları, Ortalama Öngörülen Ortalama Mutlak Hata (APMAE) istatistiğine dayanan MVPLN modeliyle karşılaştırıldı. Toplam çarpışmalar için bir UPLN modelinin de, katkıda bulunan faktörlerin katsayılarını, çarpma tipine ve ciddiyetine göre çarpma tahmin eden modellerle karşılaştırdığı tahmin edilmiştir. Model katsayısı tahminleri, sola dönüş şeridi mevcudiyeti, sağa dönüş şeridi mevcudiyeti, arazi genişliği ve hız sınırı için katsayı işaretlerinin çarpma türü veya ciddiyetine göre çarpma tahminini belirleyebileceğini düşündüren çarpma türü veya ciddiyet sayıları için farklı olduğunu göstermektedir. Kazaya katkıda bulunan faktörlerin belirlenmesinde daha yararlı olun. MVPLN modelindeki ortak değişkenlerin standart hataları,

değişkenlerin istatistiksel olarak anlamlı olduğu ve çarpışma tipine ve ciddiyetine göre çarpma sayıları arasında anlamlı bir ilişki olduğu zaman UPLN modelinden biraz daha düşüktür. Model öngörme karşılaştırmaları, MVPLN modelinin, tahmin doğruluğunda UPLN modelinden daha iyi performans gösterdiğini göstermektedir. Bu nedenle, kırsal iki şeritli otoyollar için kaza tahminini kaza tipine ve kaza ciddiyetine göre tahmin ederken, MVPLN modelinin tahmin hatasından kaçınması ve kaza tip sayıları ile kaza ciddiyeti sayıları arasındaki potansiyel korelasyonları hesaba katması düşünülmelidir.

Washington ve arkadaşları (2014), bu makale, bir ulaşım ağındaki sıcak noktaları tespit etmek için bir PDO denklik hesaplaması ve nicel regresyon tekniğinin bir kombinasyonunu önermektedir. Özellikle, düşük raporlama ve kaza ciddiyetiyle ilgili konular, eşdeğer PDO kazalarının dahil edilmesiyle ele alınmakta, eşdeğer PDO kazalarının sayılmaz niteliği ve kaza verilerinin eğikliği ile ilgili endişeler parametrik olmayan kuantil regresyon tekniği ile ele alınmaktadır. Önerilen yöntem, nüfusun pratikte çoğu yöntemde olduğu gibi popülasyonun çeşitli miktarları üzerindeki ortak değişkenleri tanımlar; bu, uygulamada siyah noktaların nasıl tanımlandığına daha yakından karşılık gelir. Önerilen metodoloji Kore'den gelen kırsal yol segmenti verileri kullanılarak gösterilmekte ve negatif binom regresyonu ile geleneksel EB yöntemiyle karşılaştırılmaktadır. Eşdeğer PDO kazalarına niceliksel bir regresyon modelinin uygulanması, topluma gerçek güvenlik maliyetlerini yansıtan, aynı zamanda yeterince bildirilmeyen PDO ve küçük yaralanma kazalarının etkisini azaltan ve geleneksel sınırlamanın üstesinden gelen bir risk grubunun tanımlanmasını sağlar.

Xie ve arkadaşları (2013), çekirdek yoğunluğu kestirimi (KDE) trafik kazası sıcak noktalarının tespitinde uzun zamandır kullanılmaktadır ve ağ çekirdeği yoğunluğu kestiriminin (NetKDE) bir ağ üzerindeki kaza analizinde faydalı olduğu kanıtlanmaktadır. Bununla birlikte, hem düzlemsel KDE hem de NetKDE, niceliksel istatistiksel çıkarım değerlendirmesinin eksikliğinden dolayı, hala büyük ölçüde bir görselleştirme aracı olarak kullanılmaktadır. Bu yazı, trafik kazalarının anında tespit edilmesi için NetKDE'yi yerel Moran'in ile birleştirmektedir. NetKDE üzerinden yol bölümleri için yoğunluğun hesaplanmasından sonra, yerel Moran I'in hesaplanması için bir öznitelik olarak kullanılmaktadır.

Xu ve arkadaşları (2017), bu çalışmada, etkileşimli korozyon kusurlarına sahip boru hatlarının başarısızlık davranışı sonlu bir eleman yöntemi kullanılarak incelenmiştir ve daha sonra yapay sinir ağı yöntemi kullanarak patlama basıncını tahmin etmek için bir çözüm önerilmiştir.

Çözüm önceki çalışmalardaki deneysel sonuçlarla doğrulanmış ve uygulanabilirliğini ve etkinliğini kanıtlamak için mevcut diğer değerlendirme çözümleriyle karşılaştırılmıştır.

Yannis ve arkadaşları (2016), karayolu güvenlik önlemlerinin değerlendirilmesi, Avrupa'daki karayolu güvenliği yönetim sistemlerinin en zayıf bileşeni olarak görülmektedir. Karayolu Altyapısı Güvenliği Yönetimi'ni geliştirmek için, karayolu otoriteleri, karayolu tasarımcıları ve karayolu güvenliği uygulayıcıları, genel olarak Kaza Tahmin Modelleri (APM'ler) olarak bilinen olası güvenlik sorunlarının analizini, güvenlik iyileştirmelerinin tespitini ve potansiyel etkilerini tahmin etmesine olanak sağlayan tahmin araçlarına ihtiyaç duymaktadırlar. Yukarıdaki bağlamda, bu çalışmanın amacı, hem ilgili bir araştırmanın sonuçlarına hem de PRACT projesi içinde yürütülen kapsamlı bir literatür taramasına dayanarak, APM'lerde iklim uygulamalarının bir sentezini sunmaktır. Avrupa ve dünya çapındaki farklı Ulusal Karayolları İdareleri (NRA) tarafından kullanılan, kullanılmış Kaza Tahmin Modellerine (APM) ayrıca APM'lerin geliştirilmesi ve uygulanması için hâlihazırda kullanılan veri kaynaklarına tam bir genel bakış sunmak için ilgili bir anket tasarlanmaktadır. Anket özel olarak tasarlanmış olup bunlar tarafından geliştirilen ve kullanılan APM'lere ayrıntılı bilgi toplamak için Avrupa'daki ve dünyadaki çeşitli NRA'lara gönderilmektedir. Ayrıca, Avrupa bağlamında uygulanabilir veya devredilebilir olan bu modelleme yaklaşımlarını ve spesifik modelleri belirlemeye odaklanarak, ilgili uluslararası literatür taraması yapılmaktadır. Anket verileri ve literatür taraması sonuçlarına dayanarak, en kullanışlı modellerin tanımlanmasının yanı sıra web tabanlı bir APM deposunun uygulanması için temel olarak APM'lere ilişkin bir cenent uygulamaları sentezi geliştirilmektedir. Toplamda, 18 Avrupa ülkesinden, ABD ve Avustralya'dan 23 anket toplanmaktadır.

Yasmin ve arkadaşları (2014), sürücü yaralanma ciddiyetini incelemek için gizli bölümlenme tabanlı genelleştirilmiş sıralı logit (LSGOL) modeli olarak adlandırılan ekonometrik bir modeli formüle eder ve tahmin eder. Önerilen model, dış kaynaklı değişkenlerin sürücü yaralanma şiddeti seviyesi üzerindeki etkilerinin, hem gözlenen hem de gözlemlenmemiş çarpışma özelliklerine bağlı olarak farklı sürücüler arasında değişebileceğini kabul etmek için, sürücüleri (çarpışmada yer alan) çarpışma özelliklerine dayanarak farklı yaralanma şiddeti segmentlerine ayırıyor. Önerilen model, 2006'dan 2010'a kadar Avustralya'daki Victoria Kazası Veri Tabanı kullanılarak tahmin edilmiştir. Model tahmini, altı geniş kategoride gruplanan kapsamlı bir dışsal değişkenler setinin etkisini içermektedir: çarpışma özellikleri, sürücü özellikleri, araç özellikleri, karayolu tasarım özellikleri, çevresel faktörler ve durumsal faktörler. Sonuçlar,

çarpışma özelliklerine göre segmentasyon ihtiyacını açıkça vurgulamaktadır. Sürücülerin bölümlere ayrılmasını etkileyen çarpışma özellikleri şunları içerir: çarpışma nesnesi, aracın hareketinin yörüngesi ve çarpışma şekli. Ayrıca, ciddi sürücü yaralanması şiddeti ile sonuçlanan temel faktörler sürücü yaşı 65 ve üstü, sürücü çıkarma, emniyet kemeri takmama ve yüksek hızlı bir bölgede çarpışmadır. Sürücü yaralanma ciddiyetini azaltan faktörler, yaya kontrolünün varlığını, döner kavşağın varlığını, panel minibüsünü sürmeyi, asfaltlanmamış yol durumunu ve yolcuların varlığını içerir.

Zeng ve arkadaşları (2014), kaza yaralanmasının ciddiyetinin tahmini için bir sinir ağı (NN) modelini hızlı ve kararlı bir şekilde eğitmek üzere dışbükey bir kombinasyon (CC) algoritması ve ağ yapısını optimize edip fonksiyon yaklaşımı (N2PFA) algoritması için modifiye edilmekte bir NN budaması önerilmektedir. Önerilen yaklaşımları göstermek ve bunları, 2006 yılında Florida Karayolu Güvenliği ve Motorlu Araçlar Dairesi tarafından sağlanan iki araçlı bir çarpışma veri seti olan geleneksel geri yayılım (BP) algoritması ile eğitilmiş NN ve karşılaştırmalı bir logit (OL) modeli ile karşılaştırmak için (DHSMV) kullanılmıştır. Sonuçlara göre, CC algoritması hem yakınsama kabiliyeti hem de eğitim hızında BP algoritmasını geride bırakmaktadır. Tamamen bağlı bir NN ile karşılaştırıldığında, optimize edilmiş NN çok daha az ağ düğümü içerir ve karşılaştırılabilir sınıflandırma doğruluğu sağlamaktadır. Her ikisi de, OL modeline göre daha iyi uydurma ve öngörme performansına sahiptir, bu da NN'in kaza yaralanmasının ciddiyetini tahmin etmek için istatistiksel modellere göre üstünlüğünü göstermektedir. Budanmış giriş düğümleri ayrıca, çarpışma sonucu ile ilgisi olmayan faktörleri belirlemek için yapı optimizasyon yönteminin kabiliyetini haklı çıkarır. Açıklayıcı değişkenlerin her yaralanma ciddiyeti sonucu üzerindeki etkisini belirlemek için, optimize edilmiş NN'nin bir duyarlılık analizi ayrıca yapılmaktadır. Elde edilen sonuçların çoğu OL modelindeki katsayı tahminine ve önceki çalışmalara uygun olsa da, bazı değişkenlerin, önerilen yöntemin gücünü daha da doğrulayan, yaralanma şiddeti ile doğrusal olmayan ilişkileri olduğu bulunmaktadır.

Zeng ve arkadaşları (2016), kaza sıklığı ile risk faktörleri arasındaki doğrusal olmayan ilişkiyi araştırmak için sinir ağı modelleri geliştirmektedir. Aşırı montaj olasılığını ortadan kaldırmak ve kara kutu karakteristiğiyle başa çıkmak için bir ağ yapısı optimizasyonu ve bir kural çıkarma yöntemi önerilmiştir. Bir örnek çalışma, modifiye edilmiş sinir ağı modellerinin performansını, Hong Kong'daki yol bölümlerinde ciddiyetle çarpma sıklığını tahmin etmek için kullanılan geleneksel çok değişkenli Poisson-lognormal modelinin performansını karşılaştırmaktadır.

Sonuçlar, eğitilmiş ve optimize edilmiş sinir ağlarının çok değişkenli Poisson-lognormal modelinden daha iyi uydurma ve öngörücü performansa sahip olduğunu göstermektedir. Dahası, budanmış girdi ve gizli düğümlere sahip optimize edilmiş sinir ağlarındaki eğitim ve test hataları arasındaki küçük farklar, yapı optimizasyon algoritmasının önemsiz faktörleri belirleme ve modelin genelleştirilebilirliğini geliştirme yeteneğini göstermektedir. Ayrıca, her bir önemli açıklayıcı değişkenin, farklı koşullar altında ciddiyetle çarpma sıklığı üzerindeki kesin etkisini açıkça ortaya çıkarmak için optimize edilmiş sinir ağlarından iki kural kümesi çıkarılır. Kurallar, her bir yaralanma ciddiyeti sonucu ile risk faktörleri ve kaza sıklıkları arasında doğrusal olmayan bir ilişki olduğunu göstermektedir. Yapı optimizasyon algoritması ve kural çıkarma yöntemi ile, modifiye edilmiş sinir ağı modelleri, çarpışma sıklığını ciddiyetle modelleme konusunda büyük potansiyele sahiptir ve yol güvenliği analizi için iyi bir alternatif olarak düşünülmelidir.

Zhang ve arkadaşları (2018), trafik kazasını sosyal medya verilerinden tespit etmede derinlemesine öğrenme kullanmaktadır. Öncelikle, iki büyük metropol alanda 1 milyondan fazla tweet içeriğini 1 yılını ayrıntılı olarak araştırmaktadır. Northern Virginia ve New York City bu iki büyük metropoldür. Sonuçlardan birincisi, eşleştirilmiş jetonların kazayla ilgili tweet'lerin içerisindeki ilişkilendirme kurallarını yakalayabildiğini ve trafik kazası tespitinin doğruluğunu daha da artırabildiğini göstermektedir. İkincisi, iki derin öğrenme yöntemidir. Derin İnanç Ağı (DBN) ve Uzun Kısa Süreli Bellek (LSTM) çıkartılmış belirteç üzerinde araştırılmış ve uygulanmıştır. Sonuçlar, DBN'nin yaklaşık 44 ayrı belirteç özelliği ve 17 eşleştirilmiş belirteç özelliği ile toplamda % 85'lik bir kesinliğe sahip olduğunu göstermektedir. Sınıflandırma, DBN'den, Destek Vektör Makineleri (SVM'ler) ve denetimli Latent Dirichlet tahsisatından (sLDA) daha iyi sonuç verir. Son olarak, bu çalışmayı doğrulamak için, kaza ile ilgili tweet'leri hem otoyollardaki trafik kazası günlüğü hem de yerel yollardaki 15.000 döngü detektöründen gelen trafik verileriyle karşılaştırılmıştır. Kaza ile ilgili tweet'lerin yaklaşık % 66'sının kaza kütüğü tarafından bulunabileceği ve bunların % 80'inden fazlasının yakındaki anormal trafik verilerine bağlanabileceği tespit edilmiştir. Trafik kazalarını tespit etmek için Twitter kullanmanın bazı önemli hususları, yer ve zaman önyargısının yanı sıra etkili kullanıcıların ve hashtaglerin özelliklerini içeren karşılaştırmalarla gündeme gelmektedir.

3. MATERYAL VE YÖNTEM

3.1. Karayollarında Kaza Sayısı

Yapılan bu çalışmada Amerikan Karayolları İdaresi'nden 1988-2016 yılları arasındaki veriler kullanılarak bir veri seti oluşturulmaktadır. Bu veri setinde yer alan bağımsız değişkenler; nüfus, taşıt sayısı, sürücü sayısı, taşıt-kilometredir. Bağımlı değişken ise kaza sayısıdır. Çalışmada kullanılan veri seti Çizelge 3.1'de verilmektedir. Kullanılan yöntemler logaritmik regresyon ve çok değişkenli regresyon yöntemlerinden lineer, interaction, quadratic ve purequadratic türleri, YSA ve BM'dir.

Çizelge 3.1. Amerikan karayolları idaresi (fhwa) kaza sayısı verileri

YILLAR	LİSANSLI SÜRÜCÜLER (BİN KİŞİ)	NÜFUS SAYISI	TAŞIT-KM (MİLYAR)	TAŞIT SAYISI	KAZA SAYISI
1988	162854	244499	2026	61219	2275130
1989	165554	246819	2096	59286	2193741
1990	167015	249464	2144	57757	2161836
1991	168995	252153	2172	53299	2044937
1992	173125	255030	2247	50939	2025942
1993	173149	257783	2296	52370	2057780
1994	175403	260327	2358	53609	2159254
1995	176628	262803	2423	55267	2254241
1996	179539	265229	2484	55904	2275494
1997	182709	267784	2552	55764	2186324
1998	184861	270248	2628	55692	2066107
1999	187170	272691	2690	55438	2091140
2000	190625	282162	2747	56270	2107526
2001	191276	284969	2796	56505	2040862
2002	194602	287625	2856	56994	1967491
2003	196166	290108	2890	57384	1963477
2004	198889	292805	2965	57191	1900444
2005	200549	295517	2989	57766	1855252
2006	202810	298380	3014	56400	1784648
2007	205742	301231	3031	54605	1748435
2008	208321	304094	2977	49151	1664172
2009	209618	306772	2957	44185	1547862
2010	210115	309348	2967	43440	1572296
2011	211875	311663	2950	42716	1559867
2012	211815	313998	2969	44557	1665006
2013	212160	316205	2988	43606	1621202
2014	214092	318563	3026	43509	1678056
2015	218084	320897	3095	47884	1747539
2016	221712	323128	3174	50542	2211439

3.2. Karayollarında Ölüm Sayısı

Yapılan bu çalışmada Amerikan Karayolları İdaresi'nden 1988-2016 yılları arasındaki veriler kullanılarak bir veri seti oluşturulmaktadır. Bu veri setinde yer alan bağımsız değişkenler; nüfus, taşıt sayısı, sürücü sayısı, taşıt-kilometredir. Bağımlı değişken ise ölüm sayısıdır. Çalışmada kullanılan veri seti Çizelge 3.1'de verilmektedir. Kullanılan yöntemler logaritmik regresyon ve çok değişkenli regresyon yöntemlerinden lineer, interaction, quadratic ve purequadratic türleri, YSA ve BM'dir.

Çizelge 3.2. Amerikan karayolları idaresi (fhwa) ölüm sayısı verileri

YILLAR	LİSANSLI SÜRÜCÜLER (BİN KİŞİ)	NÜFUS SAYISI	TAŞIT-KM (MİLYAR)	TAŞIT SAYISI	ÖLÜM SAYISI
1988	162854	244499	2026	61219	47087
1989	165554	246819	2096	59286	45582
1990	167015	249464	2144	57757	44599
1991	168995	252153	2172	53299	41508
1992	173125	255030	2247	50939	39250
1993	173149	257783	2296	52370	40150
1994	175403	260327	2358	53609	40716
1995	176628	262803	2423	55267	41817
1996	179539	265229	2484	55904	42065
1997	182709	267784	2552	55764	42013
1998	184861	270248	2628	55692	41501
1999	187170	272691	2690	55438	41717
2000	190625	282162	2747	56270	41945
2001	191276	284969	2796	56505	42196
2002	194602	287625	2856	56994	43005
2003	196166	290108	2890	57384	42884
2004	198889	292805	2965	57191	42836
2005	200549	295517	2989	57766	43510
2006	202810	298380	3014	56400	42708
2007	205742	301231	3031	54605	41259
2008	208321	304094	2977	49151	37423
2009	209618	306772	2957	44185	33883
2010	210115	309348	2967	43440	32999
2011	211875	311663	2950	42716	32479
2012	211815	313998	2969	44557	33782
2013	212160	316205	2988	43606	32893
2014	214092	318563	3026	43509	32744
2015	218084	320897	3095	47884	35485
2016	221712	323128	3174	50542	37461

3.3. Karayollarında Yaralı Sayısı

Yapılan bu çalışmada Amerikan Karayolları İdaresi'nden 1988-2016 yılları arasındaki veriler kullanılarak bir veri seti oluşturulmaktadır. Bu veri setinde yer alan bağımsız değişkenler; nüfus, taşıt sayısı, sürücü sayısı, taşıt-kilometredir. Bağımlı değişke ise yaralı sayısıdır. Çalışmada kullanılan veri seti Çizelge 3.1'de verilmektedir. Kullanılan yöntemler logaritmik regresyon ve çok değişkenli regresyon yöntemlerinden lineer, interaction, quadratic ve purequadratic türleri, YSA ve BM'dir.

Çizelge 3.3. Amerikan karayolları idaresi (fhwa) yaralı sayısı verileri

YILLAR	LİSANSLI SÜRÜCÜLER (BİN KİŞİ)	NÜFUS SAYISI	TAŞIT-KM (MİLYAR)	TAŞIT SAYISI	YARALI SAYISI
1988	162854	244499	2026	61219	3416000
1989	165554	246819	2096	59286	3284000
1990	167015	249464	2144	57757	3231000
1991	168995	252153	2172	53299	3097000
1992	173125	255030	2247	50939	3070000
1993	173149	257783	2296	52370	3149000
1994	175403	260327	2358	53609	3266000
1995	176628	262803	2423	55267	3465000
1996	179539	265229	2484	55904	3483000
1997	182709	267784	2552	55764	3348000
1998	184861	270248	2628	55692	3192000
1999	187170	272691	2690	55438	3236000
2000	190625	282162	2747	56270	3189000
2001	191276	284969	2796	56505	3033000
2002	194602	287625	2856	56994	2926000
2003	196166	290108	2890	57384	2889000
2004	198889	292805	2965	57191	2788000
2005	200549	295517	2989	57766	2699000
2006	202810	298380	3014	56400	2575000
2007	205742	301231	3031	54605	2491000
2008	208321	304094	2977	49151	2346000
2009	209618	306772	2957	44185	2217000
2010	210115	309348	2967	43440	2239000
2011	211875	311663	2950	42716	2217000
2012	211815	313998	2969	44557	2362000
2013	212160	316205	2988	43606	2313000
2014	214092	318563	3026	43509	2338000
2015	218084	320897	3095	47884	2443000
2016	221712	323128	3174	50542	2385000

3.4. Çok Değişkenli Lineer Regresyon İle tahmin Edilmesi

Çok değişkenli durumlarda bağımlı değişkene etki eden diğer değişkenler sabit kabul edilerek hesaplama yapılmaktadır. Bu değişkenlerin bağımlı değişkeni nasıl etkilediği bir katsayı ile belirlenmektedir. Bu katsayıya ise değişkenin regresyon katsayısı denir ve bağıllığın derecesini gösterir. Önemli olan etkileyen ile etkilenen arasında bir sebep sonuç ilişkisi bulunmasıdır. Kısaca özetlemek gerekirse Veri tablosuna en uygun fonksiyonu bulma işine Regresyon Analizi denilmektedir. Regresyon analizi, aralarında sebep-sonuç ilişkisi bulunan iki veya daha fazla değişken arasındaki ilişkiyi belirlemek ve bu ilişkiyi kullanarak o konu ile ilgili tahminler yapabilmek amacıyla kullanılan bir metottür. Regresyon Analizinde, değişkenler arasındaki ilişkiyi fonksiyonel olarak açıklamak ve bu ilişkiyi bir modelle tanımlayabilmek amaçlanmaktadır. Eş 3.1’de çok değişkenli lineer regresyonun genel formülü yer almaktadır.

$$y(x) = \beta_0 + \sum_{i=0}^N \beta_i x_i + \sum_{i < j}^N \beta_{ij} x_i x_j + \sum_{i=0}^N \beta_{ii} x_i^2 + \varepsilon \quad (3.1)$$

Bu eşitlikte, x_i ($i = 1, \dots, N$) bağımsız değişkenleri, y bağımlı değişkeni, β regresyon katsayılarını ve ε hatayı temsil etmektedir.

Çok değişkenli lineer regresyon yöntemleri ve logaritmik regresyon yöntemi MATLAB programında Çizelge 3.1, Çizelge 3.2 ve Çizelge 3.3’te verilen veriler kullanılarak analizler yapılmaktadır. Bu analizler sonucunda modellerin katsayıları hesaplanmakta ve bu yöntemlerin formülleri oluşturulmaktadır. Çok değişkenli lineer regresyon modelinin 4 bağımsız değişken için oluşturulan formülü Eş 3.2’de verilmektedir.

$$Y_i = (\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4) \quad (3.2)$$

İnteraction regresyon model için kullanılan formül Eş 3.3’te verilmektedir.

$$Y_i = (\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_1 X_2 + \beta_6 X_1 X_3 + \beta_7 X_1 X_4 + \beta_8 X_2 X_3 + \beta_9 X_2 X_4 + \beta_{10} X_3 X_4) \quad (3.3)$$

Eş 3.4’te çok değişkenli quadratic regresyonun denklemini yer almaktadır.

$$Y_i = (\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_1 X_2 + \beta_6 X_1 X_3 + \beta_7 X_1 X_4 + \beta_8 X_2 X_3 + \beta_9 X_2 X_4 + \beta_{10} X_3 X_4 + \beta_{11} X_1^2 + \beta_{12} X_2^2 + \beta_{13} X_3^2 + \beta_{14} X_4^2) \quad (3.4)$$

Eş 3.5'te çok değişkenli purequadratic regresyonun denklemi yer almaktadır.

$$Y_i = (\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_1^2 + \beta_6 X_2^2 + \beta_7 X_3^2 + \beta_8 X_4^2) \quad (3.5)$$

Eş 3.6'da ise logaritmik regresyonun denklemi yer almaktadır.

$$Y_i = (\beta_0 * X_1^{\beta_1} * X_2^{\beta_2} * X_3^{\beta_3} * X_4^{\beta_4}) \quad (3.6)$$

3.5. Yapay Sinir Ağları İle Tahmin Edilmesi

Matematiksel hesaplamaların insan beyninin hücresel çalışmaları esası ile sayısallaştırma yöntemlerinin başlangıcı olarak Warren McCulloch ve Walter Pitts'in 1943 yılındaki oluşturdukları yapay sinir ağ modeli gösterilmektedir. Wiener tarafından 1948 yılında kaleme alınan Cybernetics'te ise sinirsel çalışmalar üzerinde durulmaktadır. Öğrenme hakkındaki esas teori 1949 yılında Hebb ile birlikte kendi kitabı olan "Organization of Behavior" da üzerinde incelemelerde bulunduğu görülmektedir (Yavuz ve Deveci, 2012; Elmas, 2003). 1960'tan sonra yaklaşık 20 yıl YSA ile alakalı çalışmalar duraksamalar ile devam etmektedir. Bilgisayar gibi elektroniğin bazı alanlarındaki yeni buluşlar ile bu duraksamalar atlatılarak YSA'nın geliştirilmesi 1980'den itibaren artarak devam etmektedir. YSA'ya yaptırılanlarının arasında optimizasyon, analiz, öğrenme, sınıflandırma ve benzeri çalışmaların yanı sıra önemli bir çalışma türü de tahmindir.

YSA genelleme yapabilme ve öğrenebilme yetisi gibi özellikleri sayesinde günümüzde birçok alanda geniş uygulama olanağı bulmaktadır ve bu problemleri başarılı bir şekilde çözebilmektedir. YSA'da tıpkı insan beyinde olan nöronlar gibi yapay nöronları vardır. Bu yapay nöronlar birbirlerine çeşitli şekillerde bağlanarak YSA'yı oluşturmaktadır. YSA ulaştırmanın birçok alanında kullanılmaktadır. YSA insan beyni gibi çalıştığı için başarılı tahminler yapabilmektedir. Literatürde kaza sayısı tahmini ile ilgili birçok YSA çalışmaları bulunmaktadır. Bizim çalışmamızda kaza sayısı tahmini için YSA modelleri oluşturulup en iyi modeli belirlemek ve bunu uygulamak için çalışılmaktadır. YSA' da genel olarak en iyi sonucu veren eğitim algoritması Levenberg-Marquardt (LM) eğitim algoritmasıdır.

YSA'nın avantajları;

- Matematiksel modele ihtiyaç duymazlar.
- Öğrenme kabiliyeti vardır.

- Daha önce görülmemiş örnekler hakkında bilgi üretebilir.
- Doğrusal olmayan çok boyutlu, gürültülü ve eksik bilgili durumlarda başarılıdır.
- Bir problem için ağ modelleneyeceği zaman herhangi bir bilgiye ihtiyaç duyulmaz sadece örnek gereklidir. Örnek bulmaksa bilgi bulmaktan kolaydır.
- YSA' nın uygulanması oldukça pratik ve ekonomiktir.
- YSA, aynı olay için yeni ve farklı bilgiler oluşturduğunda da yeniden rahatlıkla eğitilebilir ve ortama uyum sağlayabilir.

YSA'nın dezavantajları ise;

- YSA ile bir uygulama geliştirilirken model seçiminde ve ağların topolojisini belirlerken belli bir kural yoktur. Doğru seçimlerin yapılması tamamen kullanıcının tecrübesine bağlıdır.
- Kara kutu olarak nitelendirilir. YSA, regresyon modellerinde olduğu gibi girdilerin çıktılar üzerindeki etkisini söyleyemez.
- Genel minimumu bulamama riski vardır. Ancak genel minimuma yakın yerel minimumlarda oldukça iyi sonuçlar verebilir.
- Tam olarak genelleştirme yapabilmesi için çok sayıda örneğe ihtiyaç vardır.
- Problemin ağa gösterimi çok önemli bir etkidir. YSA sadece sayısal bilgilerle çalışır ve problemin sayısal değerlere çevrilmesi gerekmektedir. Bu da kullanıcının becerisine bağlıdır.

3.6. Bulanık Mantık (BM) İle Tahmin Edilmesi

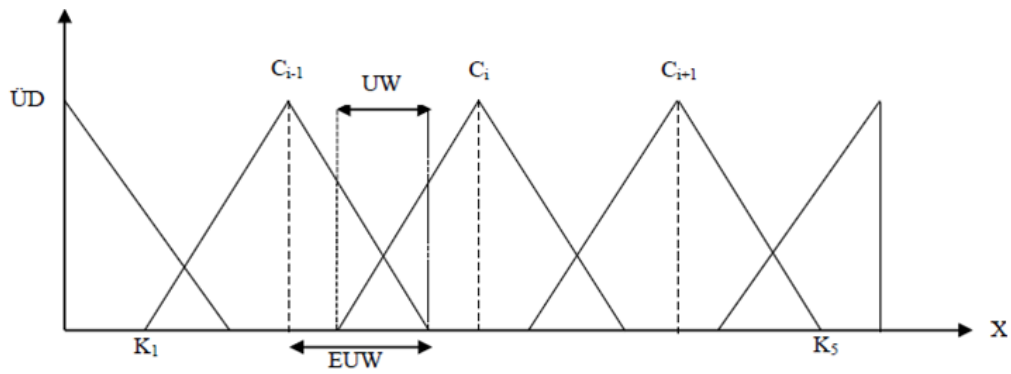
BM metodu bulanık küme mantığına dayanmaktadır. Bulanık küme mantığı ilk kez Zadeh (1965) tarafından ortaya atılmıştır. Bu nedenle Zadeh modern anlamda belirsizlik kavramının değerlendirilmesinde önemli bir nokta olarak kabul edilmektedir. Bu çalışma kesin olmayan sınırlara sahip nesnelerin oluşturduğu bulanık küme teorisini ortaya koymuştur. Bu çalışmanın yankı bulması sadece olasılık teorisine bir alternatif oluşundan değil, ayrıca o güne değin hemen hemen tüm bilimlere temel olan Aristo mantığına karşı bir alternatif olabileceğinden de kaynaklanmaktaydı. Bu çalışmadan sonra BM'nin Uzak Doğu ve Avrupa'da kısa sürede teknolojik uygulamaları ortaya çıkmaya başlamıştır. Günümüzde ise başta elektronikte, kontrol sistemlerinde olmak üzere hemen hemen tüm disiplinlerde yerini almış ve konu ile ilgili çok sayıda bilimsel çalışma yayınlanmıştır.

Bu tez çalışmasında BM'nin SMGRT yöntemi kullanılmaktadır. SMGRT yöntemi Toprak (2009) tarafından ortaya atılmıştır. Verilen bir bulanık sistemdeki temel soru, sistemdeki en iyi sonuçları veren üyelik fonksiyonu (MFs) ve bulanıklık kurallarının (FRs) nasıl oluşturulacağıdır (Toprak, 2009). Bulanık bir sistemdeki MFs ve FRs'lerin sayısına, şekline ve mantığına karar vermedeki zorlukların üstesinden gelmek için SMGRT yöntemi geliştirilmiştir. Bu yeni bulanık teknik sadece girdi ve çıktı değişkenlerinin tüm MFs'leri için üretilen bazı anahtar sayılarına dayanmaktadır. Anahtar sayıları MFs'lerin şekline (üçgen, yamuk, vb.) ve durulaştırma metoduna bağlıdır (Toprak, 2009). Toprak 2009' da sunduğu SMGRT yöntemini aşağıdaki adımlarla açıklamaktadır.

- Analiz için kullanılacak bağımsız ve bağımlı değişkenler belirlenir.
- Her değişken için maksimum ve minimum değerler (varyasyon etki alanı) belirlenir.
- Üyelik fonksiyonların (MF) şekline karar verilir (örneğin, üçgen, yamuk, vb.).
- Her bağımsız değişken için MF'nin sayısına karar verilir (en az 3 adet MF gerekir).
- Her bağımsız değişken için MF değerlerinin genişliğini ve çekirdeğini anahtar değerleri ile belirlenir. Anahtar değerlerin sayısının, her bağımsız değişken için MF sayısına eşit olacağı unutulmamalıdır. MF'lerin simetrik biçimde olması gerekmez.
- Bu anahtar değerler bulanık modelin girdileridir.
- Bulanık model, her değişken için ilk ve son MF'lerin değerleri arasında dağıtılan veriler için geçerlidir.
- Ardından, bulanık kural (FR) sayısını ve çıktının anahtar değerlerini veren bir tablo hazırlanır.
- Çıktının MF değerleri, MF girişleri için üretilir. Çıktı için anahtar değerlerin minimum değeri, ilk MF'nin merkez değeridir. Anahtar değerlerin maksimum değeri, son MF'nin merkez değeridir. Ara anahtar değerleri, orta MF'lerin merkez değerleridir. FR sayısı, çıktının MF sayısına eşitse, model daha iyi sonuçlar verir.

SGMRT yöntemi ile üyelik fonksiyonları aşağıdaki formüller yardımı ile hesaplanmaktadır. Şekil 3.1'de üyelik fonksiyonların görünümü ve formüldeki değişkenlerin nereye denk geldiğini göstermektedir. Formüller Toprak (2009) tarafından bulunmuştur.

- $V_R = V_{max} - V_{min}$,
- $UW = V_R / nu$
- $EUW = 3UW / 2$
- $K_1 = V_{min} + EUW / 3$
- $K_5 = V_{max} - EUW / 3$
- $C_i = K_i = V_R / 2 + V_{min}$,
- $C_{i+1} = K_{i+1} = V_{max} - (V_{max} - K_i / 2)$,
- $C_{i-1} = K_{i-1} = K_i - V_{min} / 2 + V_{min}$



Şekil 3.1. SMGRT formüllerindeki değişkenlerin gösterimi

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. Çok Değişkenli Lineer Regresyon İle Kaza Sayısının Tahmin Edilmesi

1988-2016 yılları arasındaki verilerden kullanılarak, logaritmik regresyon ve çok değişkenli lineer regresyon analizleri yapılmaktadır.

Çok değişkenli lineer regresyon modelinin denkleminde; kaza sayısı (K) sürücü sayısı (SS), nüfus sayısı (NS), taşıt-km değeri (TK) ve araç sayısı (AS) regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.2’ de yerine yazılarak Eş.4.1 oluşturulmaktadır.

$$K=6.2733*10^5+26.1414*SS+(-12.1077)*NS+(-689.3613)*TK+30.1582*AS \quad (4.1)$$

Çok değişkenli interaction regresyon modelinin denkleminde; K, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.3’te yerine yazılarak Eş.4.2 oluşturulmaktadır.

$$K=5.6685*10^7+(-525.6057)*SS+(-285.6415)*NS+3.1368*10^4*TK+(224.7566)*AS+0.0021*SS*NS+(-0.0313)*SS*TK+1.0401*10^{-4}*SS*AS+(0.0726)*NS*TK+0.0017*NS*AS+(-0.0871)*TK*AS \quad (4.2)$$

Çok değişkenli quadratic regresyon modelinin denkleminde; K, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.4’te yerine yazılarak Eş.4.3 oluşturulmaktadır.

$$K=1.1689*10^8+(-2.9072*10^3)*SS+824.3826*NS+6.7659*10^4*TK+(1.6728*10^3)*AS+(-0.0112)*SS*NS+(-0.8497)*SS*TK+0.0222*10^4*SS*AS+0.3243*NS*TK+(-0.0073)*NS*AS+(-0.4544)*TK*AS+0.0187*SS^2+0.0015*NS^2+4.9966*TK^2+0.0070*AS^2 \quad (4.3)$$

Çok değişkenli purequadratic regresyon modelinin denkleminde; K, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Elde edilen katsayılar Eş 3.5’te yerine yazılarak Eş.4.4 oluşturulmaktadır.

$$K=3.6015*10^7+(-555.4477)*SS+(-43.2183)*NS+1.6851*10^4*TK+123.9007*AS+0.0014*SS^2+7.3598*10^{-5}*NS^2+(-2.9788)*TK^2+(-8.9680*10^{-4})*AS^2 \quad (4.4)$$

Logaritmik regresyon modelinin denkleminde; K, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Elde edilen katsayılar Eş 3.6'da yerine yazılarak Eş 4.5 oluşturulmaktadır.

$$K=2.6535*10^3*SS^{1.8528}*NS^{-1.5335} *TK^{-0.6063}*AS^{0.7475} \quad (4.5)$$

Analiz sonucunda modeller karşılaştırılırken HKO, R ve YHO kriterleri kullanılmaktadır. Logaritmik regresyon ve çok değişkenli lineer regresyon yöntemlerinin karşılaştırılması Çizelge 4.1'de gösterilmektedir.

Çizelge 4.1. Kaza sayısı tahmini için çok değişkenli lineer regresyon modellerin karşılaştırması

Modeller	HKO	YHO (%)	R
Lineer Regresyon	14501376454.2255	4.8027	0.8577
İnteraction Regresyon	3326475148.8991	2.0864	0.9692
Quadratic Regresyon	1214042257.7187	1.4379	0.9889
Purequadratic Regresyon	3540099887.9246	2.1795	0.9672
Logaritmik Regresyon	15243601485.0837	4.8007	0.8502

Çizelge 4.1'den anlaşılacağı gibi çok değişkenli lineer regresyon modellerinden quadratic regresyon modeli diğer modellere göre daha iyi sonuçlar vermektedir.

4.2. Çok Değişkenli Lineer Regresyon İle Ölüm Sayısının Tahmin Edilmesi

Çok değişkenli lineer regresyon modelinin denkleminde; ölüm sayısı (Ö) sürücü sayısı (SS), nüfus sayısı (NS), taşıt-km değeri (TK) ve araç sayısı (AS) regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.2'de yerine yazılarak Eş 4.6 oluşturulmaktadır.

$$\ddot{O}=3.513*10^3+0.0148*SS+0.0022*NS+(-2.0874)*TK+0.7311*AS \quad (4.6)$$

Çok değişkenli interaction regresyon modelinin denkleminde; Ö, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.3'te yerine yazılarak Eş 4.7 oluşturulmaktadır.

$$\begin{aligned} \ddot{O} = & (-1.2472 \cdot 10^5) + (-0.3878) \cdot SS + 1.8515 \cdot NS + (-82.2729) \cdot TK + 1.1870 \cdot AS + (-4.9324 \cdot 10^{-6}) \cdot SS \cdot NS \\ & + 5.1228 \cdot 10^{-4} \cdot SS \cdot TK + 8.9684 \cdot 10^{-6} \cdot SS \cdot AS + (-1.2761 \cdot 10^{-4}) \cdot NS \cdot TK + (-1.0764 \cdot 10^{-5}) \cdot NS \cdot AS + \\ & 3.1248 \cdot 10^{-4} \cdot TK \cdot AS \end{aligned} \quad (4.7)$$

Çok değişkenli quadratic regresyon modelinin denkleminde; Ö, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.4'te yerine yazılarak Eş 4.8 oluşturulmaktadır.

$$\begin{aligned} \ddot{O} = & (-3.5808 \cdot 10^5) + 5.6396 \cdot SS + 0.6492 \cdot NS + (-291.2846) \cdot TK + 5.1863 \cdot AS + (-5.0407 \cdot 10^{-5}) \cdot SS \cdot NS \\ & + 0.0024 \cdot SS \cdot TK + (-4.1819 \cdot 10^{-5}) \cdot SS \cdot AS + (-1.4007 \cdot 10^{-4}) \cdot NS \cdot TK + 1.6512 \cdot 10^{-7} \cdot NS \cdot AS \\ & + 0.0018 \cdot TK \cdot AS + 1.1805 \cdot 10^{-5} \cdot SS^2 + 1.6549 \cdot 10^{-5} \cdot NS^2 + (-0.0417) \cdot TK^2 \\ & + (-1.3746 \cdot 10^{-5}) \cdot AS^2 \end{aligned} \quad (4.8)$$

Çok değişkenli purequadratic regresyon modelinin denkleminde; Ö, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Elde edilen katsayılar Eş 3.5'te yerine yazılarak Eş 4.9 oluşturulmaktadır.

$$\begin{aligned} \ddot{O} = & (-5.8229 \cdot 10^4) + 0.3914 \cdot SS + 0.6013 \cdot NS + (-43.8333) \cdot TK + 0.6541 \cdot AS + (-9.5227 \cdot 10^{-7}) \cdot SS^2 + \\ & (-10680 \cdot 10^{-6}) \cdot NS^2 + 0.0078 \cdot TK^2 + 1.4206 \cdot 10^{-7} \cdot AS^2 \end{aligned} \quad (4.9)$$

Logaritmik regresyon modelinin denkleminde; Ö, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Elde edilen katsayılar Eş 3.6'da yerine yazılarak Eş 4.10 oluşturulmaktadır.

$$\ddot{O} = 2.0037 \cdot SS^{0.06507} \cdot NS^{-0.036832} \cdot TK^{-0.10083} \cdot AS^{0.953382} \quad (4.10)$$

Analiz sonucunda modeller karşılaştırılırken HKO, R ve YHO kriterleri kullanılmaktadır. Logaritmik regresyon ve çok değişkenli lineer regresyon yöntemlerinin karşılaştırılması Çizelge 4.2'de gösterilmektedir.

Çizelge 4.2. Ölüm sayısı tahmini için çok değişkenli lineer regresyon modellerin karşılaştırması

Modeller	HKO	YHO (%)	R
Lineer Regresyon	99919.4830	0.6600	0.9971
İnteraction Regresyon	19416.1569	0.2926	0.9994
Quadratic Regresyon	13087.7865	0.2071	0.9996
Purequadratic Regresyon	25040.2321	0.3437	0.9993
Logaritmik Regresyon	96023.6160	0.6375	0.9972

Çizelge 4.2'den anlaşılacağı gibi çok değişkenli lineer regresyon modellerinden quadratic regresyon modeli diğer modellere göre daha iyi sonuçlar vermektedir.

4.3. Çok Değişkenli Lineer Regresyon İle Yaralı Sayısının Tahmin Edilmesi

Çok değişkenli lineer regresyon modelinin denkleminde; yaralı sayısı (Y) sürücü sayısı (SS), nüfus sayısı (NS), taşıt-km değeri (TK) ve araç sayısı (AS) regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.2'de yerine yazılarak Eş 4.11 oluşturulmaktadır.

$$Y=6.8746*10^6+(-25.1504)*SS+(-6.3336)*NS+753.9942*TK+11.2386*AS \quad (4.11)$$

Çok değişkenli interaction regresyon modelinin denkleminde; Y, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.3'te yerine yazılarak Eş 4.12 oluşturulmaktadır.

$$Y=5.0420*10^7+(-375.0762)*SS+(-431.0207)*NS+4.1488*10^4*TK+(-192.7650)*AS \\ +0.0022*SS*NS+(-0.1291)*SS*TK+0.0011*SS*AS+(-0.0287)*NS*TK+0.0016*NS*AS+ \\ (-0.1599)*TK*AS \quad (4.12)$$

Çok değişkenli quadratic regresyon modelinin denkleminde; Y, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Yapılan analizler sonucunda elde edilen katsayılar Eş 3.4'de yerine yazılarak Eş 4.13 oluşturulmaktadır.

$$Y=1.2311*10^8+(-672.7613)*SS+(-834.0390)*NS+7.6134*10^4*TK+(-1.4754*10^3)*AS+0.0169*SS*NS+0.0336*SS*TK+0.0051*10^4*SS*AS+(-0.2472)*NS*TK+0.0043*NS*AS+(-0.4504)*TK*AS+(-0.0118)*SS^2+(-0.0035)*NS^2+2.0644*TK^2+0.0051*AS^2 \quad (4.13)$$

Çok değişkenli purequadratic regresyon modelinin denkleminde; Y, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Elde edilen katsayılar Eş 3.5'te yerine yazılarak Eş 4.14 oluşturulmaktadır.

$$Y=2.8920*10^7+(-247.4091)*SS+(-228.0546)*NS+2.1402*10^4*TK+79.9846*AS+5.8189*10^{-4}*SS^2+4.0536*10^{-4}*NS^2+(-3.9836)*TK^2+(-3.0092*10^{-4})*AS^2 \quad (4.14)$$

Logaritmik regresyon modelinin denkleminde; Y, SS, NS, TK ve AS regresyon katsayıları kullanılarak modelin denklemi oluşturulmaktadır. Elde edilen katsayılar Eş 3.6'da yerine yazılarak Eş 4.15 oluşturulmaktadır.

$$Y=1.39813*10^{17}*SS^{-2.432832}*NS^{-0.443236}*TK^{1.071192}*AS^{0.191270} \quad (4.15)$$

Analiz sonucunda modeller karşılaştırılırken HKO, R ve YHO kriterleri kullanılmaktadır. Logaritmik regresyon ve çok değişkenli lineer regresyon yöntemlerinin karşılaştırılması Çizelge 4.3'te gösterilmektedir.

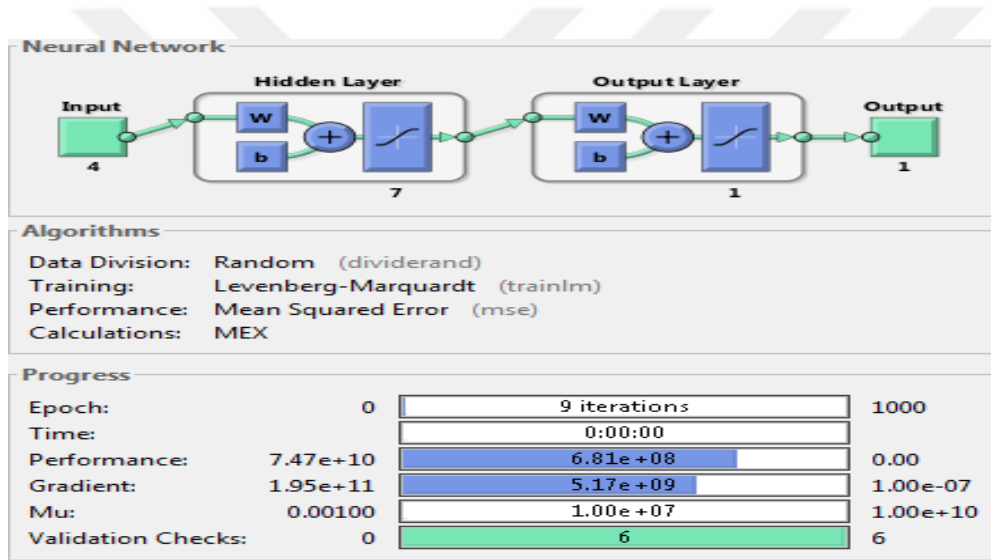
Çizelge 4.3. Modellerin karşılaştırması

Modeller	HKO	YHO (%)	R
Lineer Regresyon	21634202561.6271	4.5540	0.9390
İnteraction Regresyon	2420035918.9591	1.4955	0.9934
Quadratic Regresyon	5340363074.3138	1.6821	0.9925
Purequadratic Regresyon	600590065.7349	0.6148	0.9951
Logaritmik Regresyon	18549631727.8743	4.1322	0.9481


Çizelge 4.3'ten anlaşılacağı gibi çok değişkenli lineer regresyon modellerinden quadratic regresyon modeli diğer modellere göre daha iyi sonuçlar vermektedir.

4.4. Yapay Sinir Ağları İle Kaza Sayısının Tahmin Edilmesi

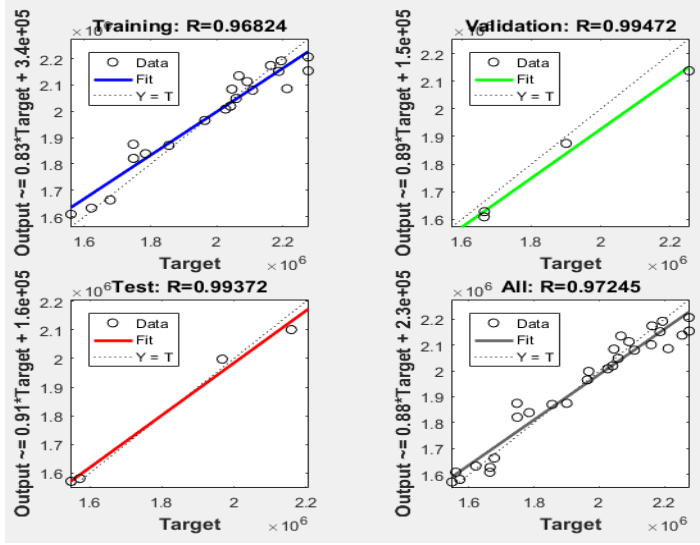
Bu çalışmada; kaza sayısı tahmini için, 1988-2016 yılları arasındaki veri seti kullanılarak yapılan analizler sonucunda tek gizli katmana sahip ve bu katmanda 7 adet nöronu bulunan model en iyi sonucu vermektedir. Bu modelde girdi ve çıktıda sırası ile tanjant sigmoid ve tanjant sigmoid transfer fonksiyonu kullanılmaktadır. Analizler sonucunda bu modelin eğitim algoritması Levenberg-Marquardt (LM) olarak belirlenmektedir. Yapılan analizler sonucunda elde edilen R değeri 0,9816, HKO değeri 2152002423,035 ve OYH değeri %1,6463 olarak hesaplanmaktadır. YSA'ya ait model görünümü, performans ve eğitim grafikleri ve regresyon katsayısı grafiği Şekil 4.1, Şekil 4.2 ve Şekil 4.3'te verilmektedir.



Şekil 4.1. Kaza sayısı tahmini için ysa model görünümü




Şekil 4.2. Kaza sayısı tahmini için ysa modelinin performans ve eğitim görünümü




Şekil 4.3. Kaza sayısı tahmini için ysa modelinin regresyon katsayısı grafiği

4.5. Yapay Sinir Ağları İle Ölüm Sayısının Tahmin Edilmesi


Ölüm sayısı tahmini için, yapılan analizler sonucunda tek gizli katmana sahip ve bu katmanda 5 adet nöronu bulunan model en iyi sonucu vermektedir. Bu modelde girdi ve çıktıda sırası ile logaritmik sigmoid ve purelin transfer fonksiyonu kullanılmaktadır. Analizler sonucunda bu modelin eğitim algoritması Levenberg-Marquardt (LM) olarak belirlenmektedir. Bu model sonucunda elde edilen R değeri 0,9972, HKO değeri 98718,9991 ve OYH değeri %0,3949 olarak hesaplanmaktadır. YSA'ya ait model görünümü, performans ve eğitim grafikleri ve regresyon katsayısı grafiği Şekil 4.4, Şekil 4.5 ve Şekil 4.6'da verilmektedir.



Şekil 4.4. Ölüm sayısı tahmini için ysa model görünümü




Şekil 4.5. Ölüm sayısı tahmini için ysa modelinin performans ve eğitim görünümü



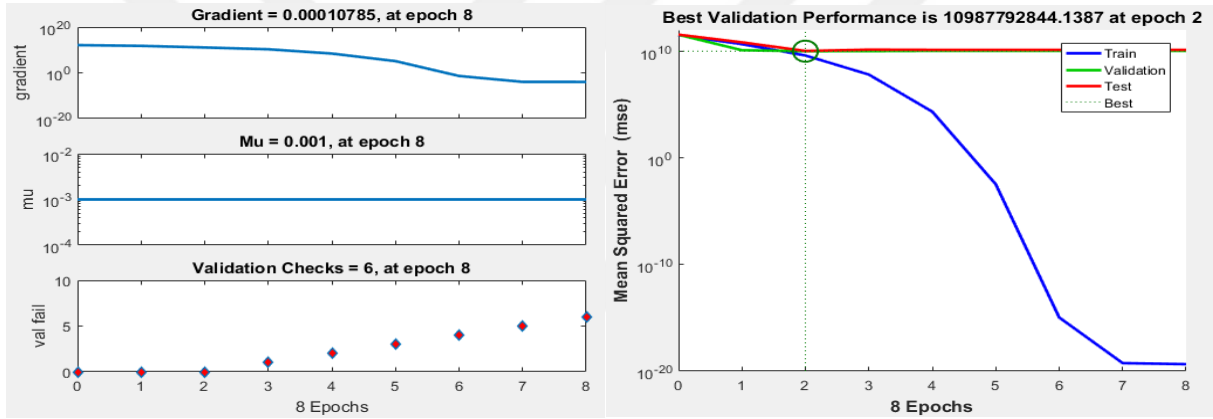
Şekil 4.6. Ölüm sayısı tahmini için ysa modelinin regresyon katsayısı grafiği

4.6. Yapay Sinir Ağları İle Yaralı Sayısının Tahmin Edilmesi


Yaralı sayısı tahmini için, yapılan analizler sonucunda tek gizli katmana sahip ve bu katmanda 13 adet nöronu bulunan model en iyi sonucu vermektedir. Bu modelde girdi ve çıktıda sırası ile tanjant sigmoid ve purelin transfer fonksiyonu kullanılmaktadır. Analizler sonucunda bu modelin eğitim algoritması Levenberg-Marquardt (LM) olarak belirlenmektedir. Bu model sonucunda elde edilen R değeri 0,9860, HKO değeri 6268315631,2724 ve OYH değeri %2,4522 olarak hesaplanmaktadır. YSA'ya ait model görünümü, performans ve eğitim grafikleri ve regresyon katsayısı grafiği Şekil 4.7, Şekil 4.8 ve Şekil 4.9'da verilmektedir.



Şekil 4.7. Yaralı sayısı tahmini için ysa model görünümü



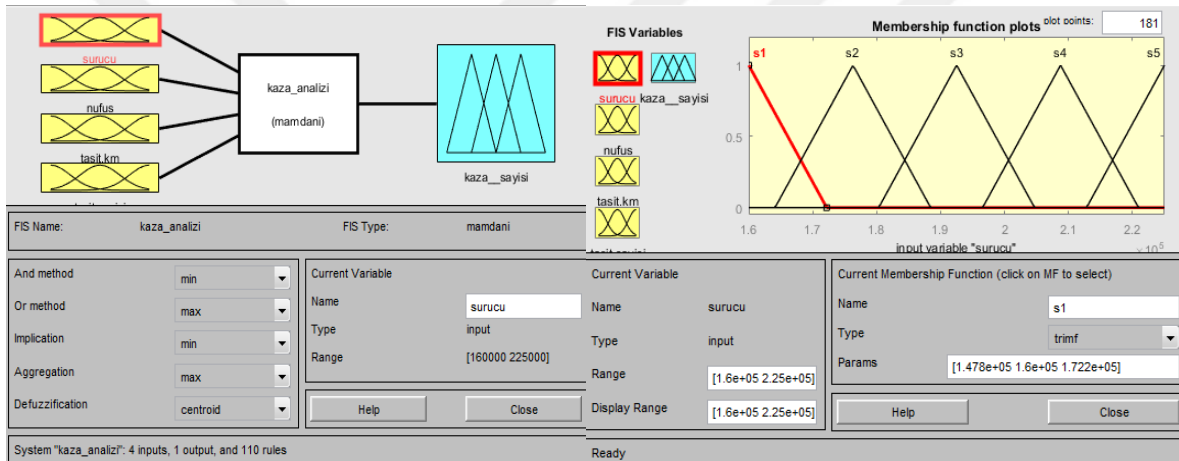
Şekil 4.48. Yaralı sayısı tahmini için ysa modelinin performans ve eğitim görünümü



Şekil 4.9. Yaralı sayısı tahmini için ysa modelinin regresyon katsayısı grafiği

4.7. Fuzzy Logic İle Kaza Sayısının Tahmin Edilmesi


Bu modelde Mamdani yöntemi kullanılmaktadır. Üyelik Fonksiyonu üçgen model olarak seçilip girdi ve çıktı katmanları için 5 adet olarak seçilmektedir. Çıktı değerlerinin hesaplanmasında centroid yöntemi kullanılmaktadır. Yapılan çalışma sonucunda tahmin değerlerinin hesaplanması için 110 adet kural oluşturulmaktadır. Kaza sayısını tahmin etmek için yapılan bu model sonucunda elde edilen R değeri 0,8869, HKO değeri 16956785090,7348 ve OYH değeri %5,7766 olarak hesaplanmaktadır. Analizler sonucunda elde edilen modelin görünümü, üyelik fonksiyon görünümü, kural tablosu ve saçılım grafiği Şekil 4.10, Şekil 4.11 ve Şekil 4.12’de verilmektedir.



Şekil 4.10. Kaza sayısının belirlenmesinde fuzzy model ve üyelik fonksiyonlarının görünümü

If	and	and	and	Then
surucu is	nufus is	tasit.km is	tasit.sayisi is	kaza_sayisi is
s1	n1	tkm1	tas1	kaza1
s2	n2	tkm2	tas2	kaza2
s3	n3	tkm3	tas3	kaza3
s4	n4	tkm4	tas4	kaza4
s5	n5	tkm5	tas5	kaza5
none	none	none	none	none
<input type="checkbox"/> not	<input type="checkbox"/> not	<input type="checkbox"/> not	<input type="checkbox"/> not	<input type="checkbox"/> not
Connection: <input checked="" type="radio"/> and		Weight: 1		
		Delete rule		Add rule
		Change rule		
FIS Name: kaza_analizi				
Help Close				


Şekil 4.11. Kaza sayısının belirlenmesinde fuzzy modelin kural tablosu



Şekil 4.12. Kaza sayısının belirlenmesinde fuzzy modelin saçılım grafiği

4.8. Fuzzy Logic İle Ölüm Sayısının Tahmin Edilmesi

Yapılan analizler sonucunda elde edilen modelde Mamdani yöntemi kullanılmaktadır. Üyelik Fonksiyonu üçgen model olarak seçilip girdi ve çıktı katmanları için 5 adet olarak seçilmektedir. Çıktı değerlerinin hesaplanmasında centroid yöntemi kullanılmaktadır. Yapılan çalışma sonucunda tahmin değerlerinin hesaplanması için 130 adet kural oluşturulmaktadır. Ölüm sayısının tahmini için yapılan bu model sonucunda elde edilen R değeri 0,9437, HKO değeri 4737707,4473 ve OYH değeri %4,4421 olarak hesaplanmaktadır. Analizler sonucunda elde edilen modelin görünümü, üyelik fonksiyon görünümü, kural tablosu ve saçılım grafiği Şekil 4.13, Şekil 4.14 ve Şekil 4.15'te verilmektedir.



Şekil 4.13. Ölüm sayısının belirlenmesinde fuzzy model ve üyelik fonksiyonlarının görünümü


1. If (sürücü is s4) and (nufus is n4) and (tasit-km is tkm4) and (tasit_sayisi is tas1) then (olum_sayisi is ol1) (1)				
2. If (sürücü is s5) and (nufus is n4) and (tasit-km is tkm4) and (tasit_sayisi is tas1) then (olum_sayisi is ol1) (1)				
3. If (sürücü is s4) and (nufus is n5) and (tasit-km is tkm4) and (tasit_sayisi is tas1) then (olum_sayisi is ol1) (1)				
4. If (sürücü is s5) and (nufus is n5) and (tasit-km is tkm4) and (tasit_sayisi is tas1) then (olum_sayisi is ol1) (1)				
5. If (sürücü is s4) and (nufus is n4) and (tasit-km is tkm5) and (tasit_sayisi is tas1) then (olum_sayisi is ol1) (1)				
6. If (sürücü is s5) and (nufus is n4) and (tasit-km is tkm5) and (tasit_sayisi is tas1) then (olum_sayisi is ol1) (1)				
7. If (sürücü is s4) and (nufus is n5) and (tasit-km is tkm5) and (tasit_sayisi is tas1) then (olum_sayisi is ol1) (1)				
8. If (sürücü is s5) and (nufus is n5) and (tasit-km is tkm5) and (tasit_sayisi is tas1) then (olum_sayisi is ol1) (1)				
9. If (sürücü is s4) and (nufus is n4) and (tasit-km is tkm4) and (tasit_sayisi is tas2) then (olum_sayisi is ol1) (1)				
10. If (sürücü is s5) and (nufus is n4) and (tasit-km is tkm4) and (tasit_sayisi is tas2) then (olum_sayisi is ol1) (1)				

If	and	and	and	Then
sürücü is	nufus is	tasit-km is	tasit_sayisi is	olum_sayisi is
s1	n1	tkm1	tas1	ol1
s2	n2	tkm2	tas2	ol2
s3	n3	tkm3	tas3	ol3
s4	n4	tkm4	tas4	ol4
s5	n5	tkm5	tas5	ol5
none	none	none	none	none
<input type="checkbox"/> not	<input type="checkbox"/> not	<input type="checkbox"/> not	<input type="checkbox"/> not	<input type="checkbox"/> not
Connection		Weight:		
<input type="radio"/> or		1		
<input checked="" type="radio"/> and		Delete rule		
		Add rule		
		Change rule		
		<<		
		>>		

FIS Name: olum_analizi

Help Close

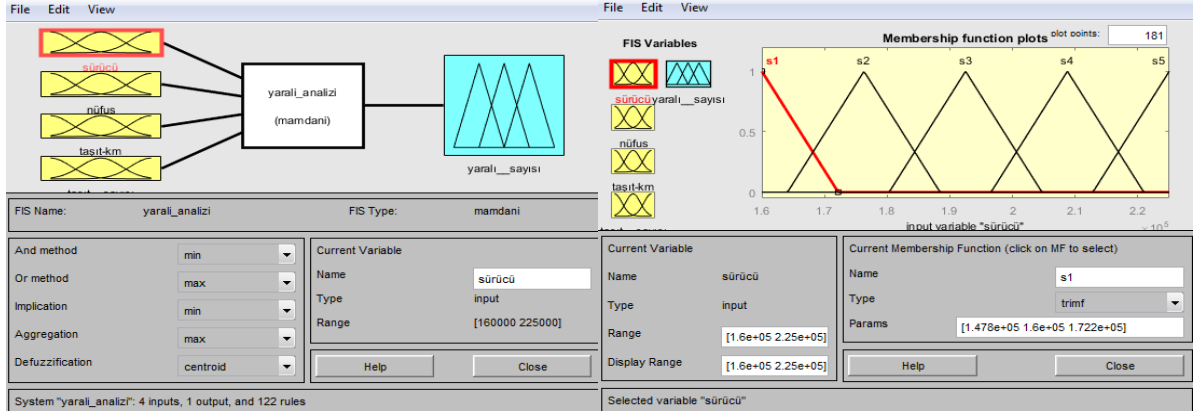
Şekil 4.14. Ölüm sayısının belirlenmesinde fuzzy modelin kural tablosu



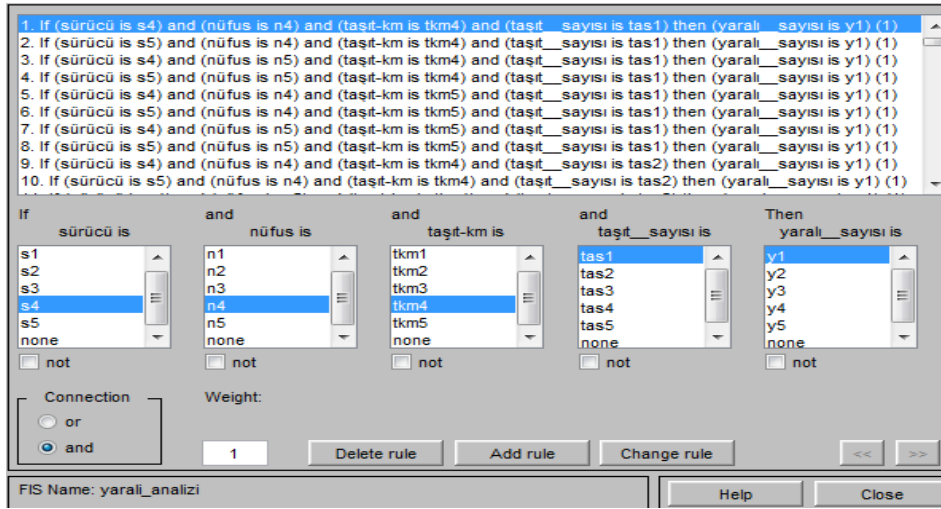
Şekil 4.15. Ölüm sayısının belirlenmesinde fuzzy modelin saçılım grafiği

4.9. Fuzzy Logic İle Yaralı Sayısının Tahmin Edilmesi


Yapılan analizler sonucunda elde edilen modelde Mamdani yöntemi kullanılmaktadır. Üyelik Fonksiyonu üçgen model olarak seçilip girdi ve çıktı katmanları için 5 adet olarak seçilmektedir. Çıktı değerlerinin hesaplanmasında centroid yöntemi kullanılmaktadır. Yapılan çalışma sonucunda tahmin değerlerinin hesaplanması için 122 adet kural oluşturulmaktadır. Yaralı sayısının tahmini için yapılan bu model sonucunda elde edilen R değeri 0,9518, HKO değeri 28260831083,4280 ve OYH değeri %5,0739 olarak hesaplanmaktadır. Analizler sonucunda elde edilen modelin görünümü, üyelik fonksiyon görünümü, kural tablosu ve saçılım grafiği Şekil 4.16, Şekil 4.17 ve Şekil 4.18'de verilmektedir.



Şekil 4.16. Yaralı sayısının belirlenmesinde fuzzy model ve üyelik fonksiyonlarının görünümü



Şekil 4.17. Yaralı sayısının belirlenmesinde fuzzy modelin kural tablosu



Şekil 4.18. Yaralı sayısının belirlenmesinde fuzzy modelin yaralı sayısı saçılım grafiği

4.10. Kaza Sayısı Tahminlerinin Karşılaştırılması

Yapılan bu çalışmada; kaza sayısının tahmini için kullanılan yöntemlerden ilki çok değişkenli lineer regresyon yöntemlerinden lineer, interaction, quadratic ve purequadratic ikinci yöntem logaritmik regresyon üçüncü yöntem YSA ve dördüncü yöntem olarakta Fuzzy Logic yöntemi kullanılmaktadır. Kullanılan bu yöntemler R, HKO ve OYH kriterleri baz alınarak karşılaştırma yapılmaktadır. Analizler sonucu elde edilen değerler göz önünde bulundurularak kaza sayısı tahmininde en iyi sonucu veren yöntem, çok değişkenli lineer regresyon türlerinden biri olan quadratic regresyon modelidir. Kullanılan yöntemler ile elde edilen R, HKO ve OYH değerleri Çizelge 4.4'te verilmektedir.

Çizelge 4.4. Kaza sayısı tahmini için modellerin karşılaştırması

Modeller	HKO	YHO (%)	R
Lineer Regresyon	14501376454.2255	4.8027	0.8577
İnteraction Regresyon	3326475148.8991	2.0864	0.9692
Quadratic Regresyon	1214042257.7187	1.4379	0.9889
Purequadratic Regresyon	3540099887.9246	2.1795	0.9672
Logaritmik Regresyon	15243601485.0837	4.8007	0.8502
Yapay Sınır Ağları	2152002423.0352	1.6463	0.9816
Fuzzy Logic	16956785090.7348	5.7766	0.8869

4.11. Ölüm Sayısı Tahminlerinin Karşılaştırılması

Ölüm sayısının tahmini için kullanılan yöntemlerden ilki çok değişkenli lineer regresyon yöntemlerinden lineer, interaction, quadratic ve purequadratic ikinci yöntem logaritmik regresyon üçüncü yöntem YSA ve dördüncü yöntem olarakta Fuzzy Logic yöntemi kullanılmaktadır. Kullanılan bu yöntemler R, HKO ve OYH kriterleri baz alınarak karşılaştırma yapılmaktadır. Analizler sonucu elde edilen değerler göz önünde bulundurularak kaza sayısı tahmininde en iyi sonucu veren yöntem, çok değişkenli lineer regresyon türlerinden biri olan quadratic regresyon modelidir. Kullanılan yöntemler ile elde edilen R, HKO ve OYH değerleri Çizelge 4.5'te verilmektedir.

Çizelge 4.5. Ölüm sayısı tahmini için modellerin karşılaştırması

Modeller	HKO	YHO (%)	R
Lineer Regresyon	99919.4830	0.6600	0.9971
İnteraction Regresyon	19416.1569	0.2926	0.9994
Quadratic Regresyon	13087.7865	0.2071	0.9996
Purequadratic Regresyon	25040.2321	0.3437	0.9993
Logaritmik Regresyon	96023.6160	0.6375	0.9972
Yapay Sınır Ağları	98718.9991	0.3949	0.9972
Fuzzy Logic	4737707.4473	4.4421	0.9437

4.12. Yaralı Sayısı Tahminlerinin Karşılaştırılması

Yaralı sayısının tahmini için kullanılan yöntemlerden ilki çok değişkenli lineer regresyon yöntemlerinden lineer, interaction, quadratic ve purequadratic ikinci yöntem logaritmik regresyon üçüncü yöntem YSA ve dördüncü yöntem olarakta Fuzzy Logic yöntemi kullanılmaktadır. Kullanılan bu yöntemler R, HKO ve OYH kriterleri baz alınarak karşılaştırma yapılmaktadır. Analizler sonucu elde edilen değerler göz önünde bulundurularak kaza sayısı tahmininde en iyi sonucu veren yöntem, çok değişkenli lineer regresyon türlerinden biri olan purequadratic regresyon modelidir. Kullanılan yöntemler ile elde edilen R, HKO ve OYH değerleri Çizelge 4.6'da verilmektedir.

Çizelge 4.6. Yaralı sayısı tahmini için modellerin karşılaştırması

Modeller	HKO	YHO (%)	R
Lineer Regresyon	21634202561.6271	4.5540	0.9390
İnteraction Regresyon	2420035918.9591	1.4955	0.9934
Purequadratic Regresyon	5340363074.3138	1.6821	0.9925
Quadratic Regresyon	600590065.7349	0.6148	0.9951
Logaritmik Regresyon	18549631727.8743	4.1322	0.9481
Yapay Sınır Ağları	6268315631.2724	2.4522	0.9960
Fuzzy Logic	28260831083.4280	5.0739	0.9518

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, nüfus, taşıt sayısı, sürücü sayısı, taşıt-kilometre makro değişkenleri bağımsız değişken olarak kullanılmıştır. Bu değişkenler kullanılarak kaza sayısı, ölüm sayısı ve yaralı sayısı tahmin edilmiştir. Trafik kazalarında ölüm sayısını tahmin etmek için kullanılan ve başarılı sonuçlara ulaşılan logaritmik regresyon bu çalışmada kaza sayısını ve yaralı sayısını tahmin etmek için kullanılmıştır. Logaritmik regresyon modeli, çok değişkenli lineer regresyon modelleri, YSA ve BM modelleri karşılaştırılmıştır. Çok değişkenli lineer regresyon modelinin, lineer, interaction, quadratic ve purequadratic türleri uygulanmaktadır. Modeller arası karşılaştırmalar korelasyon katsayısı, yüzde hataların ortalaması ve hataların karesinin ortalaması ile yapılmaktadır.

Kaza sayısı tahmini için yapılan analizler sonucunda çok değişkenli lineer regresyon yöntemlerinden, lineer regresyon modelinin R değeri 0,8577, YHO değeri %4,8027, HKO değeri ise 14501376454,2255 olarak hesaplanmıştır. İnteraction regresyon modelinin R değeri 0,9692, YHO değeri %2,0864, HKO değeri ise 3326475148,8991 olarak hesaplanmıştır. Purequadratic regresyon modelinin R değeri 0,9672, YHO değeri %2,1795, HKO değeri ise 3540099887,9246 olarak hesaplanmıştır. Quadratic regresyon modelinin R değeri 0,9889, YHO değeri %1,4379, HKO değeri ise 1214042257,7187 olarak hesaplanmıştır. Logaritmik regresyon modeli sonucu elde edilen R değeri 0,8502, YHO değeri %4,8007 ve HKO değeri ise 15243601485,0837 olarak hesaplanmıştır. YSA analiz sonucu elde edilen R değeri 0,9816, YHO değeri %1,6463 ve HKO değeri ise 2152002423,0350 olarak hesaplanmıştır. BM analiz sonucu elde edilen R değeri 0,8869, YHO değeri %5,7766 ve HKO değeri ise 16956785090,7348 olarak hesaplanmıştır. Yapılan analizler sonucunda kaza sayısı tahmininde en iyi sonucu veren yöntem çok değişkenli lineer regresyon yöntemlerinden quadratic regresyon modeli'dir. Buna benzer çalışmalarda quadratic regresyon modeli kullanılması daha uygun olacaktır.

Yaralı sayısı tahmini için yapılan analizler sonucunda çok değişkenli lineer regresyon yöntemlerinden, lineer regresyon modelinin R değeri 0,9390, YHO değeri %4,5540, HKO değeri ise 21634202561,6271 olarak hesaplanmıştır. İnteraction regresyon modelinin R değeri 0,9934, YHO değeri %1,4955, HKO değeri ise 2420035918,9591 olarak hesaplanmıştır. Purequadratic regresyon modelinin R değeri 0,9925, YHO değeri %1,6821, HKO değeri ise 5340363074,3138 olarak hesaplanmıştır. Quadratic regresyon modelinin R değeri 0,9951,

YHO değeri %0,6148, HKO değeri ise 600590065,7349 olarak hesaplanmıştır. Logaritmik regresyon modeli sonucu elde edilen R değeri 0,9481, YHO değeri %4,1322 ve HKO değeri ise 18549631727,8743 olarak hesaplanmıştır. YSA analiz sonucu elde edilen R değeri 0,9860, YHO değeri %2,4522 ve HKO değeri ise 6268315631,2724 olarak hesaplanmıştır. BM analiz sonucu elde edilen R değeri 0,9518, YHO değeri %5,0739 ve HKO değeri ise 26260831083,4280 olarak hesaplanmıştır. Yapılan analizler sonucunda yaralı sayısı tahmininde en iyi sonucu veren yöntem R değeri YSA'nın daha iyi olmasına rağmen YHO ve HKO değerine kıyasla purequadratic regresyon modeli daha iyi sonuçlar vermiştir. Buna benzer çalışmalarda YSA ve purequadratic regresyon modeli kullanılması daha uygun olacaktır.

Ölüm sayısı tahmini için yapılan analizler sonucunda çok değişkenli lineer regresyon yöntemlerinden, lineer regresyon modelinin R değeri 0,9971, YHO değeri %0,6600, HKO değeri ise 99919,4830 olarak hesaplanmıştır. İnteraction regresyon modelinin R değeri 0,9994, YHO değeri %0,2926, HKO değeri ise 19416,1569 olarak hesaplanmıştır. Purequadratic regresyon modelinin R değeri 0,9993, YHO değeri %0,3437, HKO değeri ise 25040,2321 olarak hesaplanmıştır. Quadratic regresyon modelinin R değeri 0,9996, YHO değeri %0,2071, HKO değeri ise 13087,7865 olarak hesaplanmıştır. Logaritmik regresyon modeli sonucu elde edilen R değeri 0,9972, YHO değeri %0,6375 ve HKO değeri ise 96023,6160 olarak hesaplanmıştır. YSA analiz sonucu elde edilen R değeri 0,9972, YHO değeri %0,3949 ve HKO değeri ise 98718,9991 olarak hesaplanmıştır. BM analiz sonucu elde edilen R değeri 0,9437, YHO değeri %4,4421 ve HKO değeri ise 4737707,4473 olarak hesaplanmıştır. Yapılan analizler sonucunda ölüm sayısı tahmininde en iyi sonucu veren yöntem çok değişkenli lineer regresyon yöntemlerinden quadratic regresyon modelidir. Buna benzer çalışmalarda quadratic regresyon modeli kullanılması daha uygun olacaktır.

KAYNAKLAR

- Agarwal, S., Kachroo, P., & Regentova, E. (2016). A hybrid model using logistic regression and wavelet transformation to detect traffic incidents. *Iatss Research*, 40(1), 56-63.
- Ali, G. A., & Tayfour, A. (2012). Characteristics and Prediction of Traffic Accident Casualties In Sudan Using Statistical Modeling and Artificial Neural Networks. *International journal of transportation science and technology*, 1(4), 305-317.
- Alikhani, M., Nedaie, A., & Ahmadvand, A. (2013). Presentation of clustering-classification heuristic method for improvement accuracy in classification of severity of road accidents in Iran. *Safety science*, 60, 142-150.
- Anarkooli, A. J., Hosseinpour, M., & Kardar, A. (2017). Investigation of factors affecting the injury severity of single-vehicle rollover crashes: a random-effects generalized ordered probit model. *Accident Analysis & Prevention*, 106, 399-410.
- Bertsimas, D., Masiakos, P. T., Mylonas, K. S., & Wiberg, H. (2019). Prediction of cervical spine injury in young pediatric patients: an optimal trees artificial intelligence approach. *Journal of Pediatric Surgery*.
- Chang, L. Y. (2005). Analysis of freeway accident frequencies: negative binomial regression versus artificial neural network. *Safety science*, 43(8), 541-557.
- Chang, L. Y., & Wang, H. W. (2006). Analysis of traffic injury severity: An application of non-parametric classification tree techniques. *Accident Analysis & Prevention*, 38(5), 1019-1027.
- Chen, C., Zhang, G., Qian, Z., Tarefder, R. A., & Tian, Z. (2016). Investigating driver injury severity patterns in rollover crashes using support vector machine models. *Accident Analysis & Prevention*, 90, 128-139.
- De Naurois, C. J., Bourdin, C., Stratulat, A., Diaz, E., & Vercher, J. L. (2017). Detection and prediction of driver drowsiness using artificial neural network models. *Accident Analysis & Prevention*.
- De Oña, J., López, G., Mujalli, R., & Calvo, F. J. (2013). Analysis of traffic accidents on rural highways using Latent Class Clustering and Bayesian Networks. *Accident Analysis & Prevention*, 51, 1-10.
- De Oña, J., Mujalli, R. O., & Calvo, F. J. (2011). Analysis of traffic accident injury severity on Spanish rural highways using Bayesian networks. *Accident Analysis & Prevention*, 43(1), 402-411.

- Deka, L., & Quddus, M. (2014). Network-level accident-mapping: distance based pattern matching using artificial neural network. *Accident Analysis & Prevention*, *65*, 105-113.
- 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.
- Depaire, B., Wets, G., & Vanhoof, K. (2008). Traffic accident segmentation by means of latent class clustering. *Accident Analysis & Prevention*, *40*(4), 1257-1266.
- Deublein, M., Schubert, M., Adey, B. T., Köhler, J., & Faber, M. H. (2013). Prediction of road accidents: A Bayesian hierarchical approach. *Accident Analysis & Prevention*, *51*, 274-291.
- Durduran, S. S. (2010). A decision making system to automatic recognize of traffic accidents on the basis of a GIS platform. *Expert Systems with Applications*, *37*(12), 7729-7736.
- Garrido, R., Bastos, A., de Almeida, A., & Elvas, J. P. (2014). Prediction of road accident severity using the ordered probit model. *Transportation Research Procedia*, *3*, 214-223.
- Hashimoto, S., Yoshiki, S., Saeki, R., Mimura, Y., Ando, R., & Nanba, S. (2016). Development and application of traffic accident density estimation models using kernel density estimation. *Journal of traffic and transportation engineering (English edition)*, *3*(3), 262-270.
- Hojati, A. T., Ferreira, L., Washington, S., Charles, P., & Shobeirinejad, A. (2014). Modelling total duration of traffic incidents including incident detection and recovery time. *Accident Analysis & Prevention*, *71*, 296-305.
- Huang, H. B., Wu, J. H., Huang, X. R., Yang, M. L., & Ding, W. P. (2019). The development of a deep neural network and its application to evaluating the interior sound quality of pure electric vehicles. *Mechanical Systems and Signal Processing*, *120*, 98-116.
- Ihueze, C. C., & Onwurah, U. O. (2018). Road traffic accidents prediction modelling: An analysis of Anambra State, Nigeria. *Accident Analysis & Prevention*, *112*, 21-29.
- Iranitalab, A., & Khattak, A. (2017). Comparison of four statistical and machine learning methods for crash severity prediction. *Accident Analysis & Prevention*, *108*, 27-36.
- Kaplan, S., & Prato, C. G. (2012). Risk factors associated with bus accident severity in the United States: A generalized ordered logit model. *Journal of safety research*, *43*(3), 171-180.
- Kashani, A. T., & Mohaymany, A. S. (2011). Analysis of the traffic injury severity on two-lane, two-way rural roads based on classification tree models. *Safety Science*, *49*(10), 1314-1320.

- Kinoshita, A., Takasu, A., & Adachi, J. (2015). Real-time traffic incident detection using a probabilistic topic model. *Information Systems, 54*, 169-188.
- Kwon, O. H., Rhee, W., & Yoon, Y. (2015). Application of classification algorithms for analysis of road safety risk factor dependencies. *Accident Analysis & Prevention, 75*, 1-15.
- Li, Y., Ma, D., Zhu, M., Zeng, Z., & Wang, Y. (2018). Identification of significant factors in fatal-injury highway crashes using genetic algorithm and neural network. *Accident Analysis & Prevention, 111*, 354-363.
- Li, Z., Jin, X., & Zhao, X. (2015). Drunk driving detection based on classification of multivariate time series. *Journal of safety research, 54*, 61-e29.
- Lin, L., Wang, Q., & Sadek, A. W. (2015). A novel variable selection method based on frequent pattern tree for real-time traffic accident risk prediction. *Transportation Research Part C: Emerging Technologies, 55*, 444-459.
- Liu, J., Boyle, L. N., & Banerjee, A. G. (2018). Predicting interstate motor carrier crash rate level using classification models. *Accident Analysis & Prevention, 120*, 211-218.
- Mannering, F. L., & Bhat, C. R. (2014). Analytic methods in accident research: Methodological frontier and future directions. *Analytic methods in accident research, 1*, 1-22.
- Mannering, F. L., Shankar, V., & Bhat, C. R. (2016). Unobserved heterogeneity and the statistical analysis of highway accident data. *Analytic methods in accident research, 11*, 1-16.
- Qin, X., Ng, M., & Reyes, P. E. (2010). Identifying crash-prone locations with quantile regression. *Accident Analysis & Prevention, 42*(6), 1531-1537.
- Sam, E. F., Daniels, S., Brijs, K., Brijs, T., & Wets, G. (2018). Modelling public bus/minibus transport accident severity in Ghana. *Accident Analysis & Prevention, 119*, 114-121.
- Sarkar, S., Vinay, S., Raj, R., Maiti, J., & Mitra, P. (2019). Application of optimized machine learning techniques for prediction of occupational accidents. *Computers & Operations Research, 106*, 210-224.
- Savolainen, P. T., Mannering, F. L., Lord, D., & Quddus, M. A. (2011). The statistical analysis of highway crash-injury severities: a review and assessment of methodological alternatives. *Accident Analysis & Prevention, 43*(5), 1666-1676.
- Steinbach, L., & Altinsoy, M. E. (2019). Prediction of annoyance evaluations of electric vehicle noise by using artificial neural networks. *Applied Acoustics, 145*, 149-158.

- Tixier, A. J. P., Hallowell, M. R., Rajagopalan, B., & Bowman, D. (2016). Application of machine learning to construction injury prediction. *Automation in construction*, 69, 102-114.
- Toprak, Z. F., TOPRAK, A., & AYKAÇ, Z. (2017). Bulanık SMRGT yönteminin pratik uygulamaları. *DÜMF Mühendislik Dergisi*, 8(1), 123-132.
- Toprak, Z. F. (2009). Flow discharge modeling in open canals using a new fuzzy modeling technique (SMRGT). *CLEAN–Soil, Air, Water*, 37(9), 742-752.
- Wang, K., Ivan, J. N., Ravishanker, N., & Jackson, E. (2017). Multivariate poisson lognormal modeling of crashes by type and severity on rural two lane highways. *Accident Analysis & Prevention*, 99, 6-19.
- Washington, S., Haque, M. M., Oh, J., & Lee, D. (2014). Applying quantile regression for modeling equivalent property damage only crashes to identify accident blackspots. *Accident Analysis & Prevention*, 66, 136-146.
- Xie, Z., & Yan, J. (2013). Detecting traffic accident clusters with network kernel density estimation and local spatial statistics: an integrated approach. *Journal of transport geography*, 31, 64-71.
- Xu, W. Z., Li, C. B., Choung, J., & Lee, J. M. (2017). Corroded pipeline failure analysis using artificial neural network scheme. *Advances in engineering software*, 112, 255-266.
- Yannis, G., Dragomanovits, A., Laiou, A., Richter, T., Ruhl, S., La Torre, F., ... & Li, H. (2016). Use of accident prediction models in road safety management—an international inquiry. *Transportation research procedia*, 14, 4257-4266.
- Yasmin, S., Eluru, N., Bhat, C. R., & Tay, R. (2014). A latent segmentation based generalized ordered logit model to examine factors influencing driver injury severity. *Analytic methods in accident research*, 1, 23-38.
- Zeng, Q., & Huang, H. (2014). A stable and optimized neural network model for crash injury severity prediction. *Accident Analysis & Prevention*, 73, 351-358.
- Zeng, Q., Huang, H., Pei, X., & Wong, S. C. (2016). Modeling nonlinear relationship between crash frequency by severity and contributing factors by neural networks. *Analytic methods in accident research*, 10, 12-25.
- Zhang, Z., He, Q., Gao, J., & Ni, M. (2018). A deep learning approach for detecting traffic accidents from social media data. *Transportation research part C: emerging technologies*, 86, 580-596.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : ALKILIÇ, Hatice
Uyruğu : T.C.
Doğum tarihi ve yeri : 03.01.1990, Osmaniye
Medeni hali : Evli
Telefon : 0 (553) 604 62 00
Faks : -
e-mail : htcagca@gmail.com



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	İskenderun Teknik Üniversitesi / İnşaat Mühendisliği	Devam ediyor
Lisans	Mustafa Kemal Üniversitesi/İnşaat Mühendisliği	2012
Lise	Adana Erkek Lisesi	2008

İş Deneyimi

Yıl	Yer	Görev
2015- halen	İstanbul Rölöve ve Anıtlar Müd.	Mühendis
2012-2015	Dinamik Güç Yapı Denetim	Kontrol Mühendisi

Yabancı Dil

İngilizce

Hobiler

Yüzme, Yürüyüş, Kitap Okuma

DİZİN

A

Abstract · v
 Analiz · iv, v, ix, 1, 2, 3, 5, 6, 7, 8,
 9, 10, 11, 12, 13, 14, 15, 16, 17,
 18, 19, 21, 22, 23, 24, 25, 26,
 30, 31, 33, 35, 36, 37, 38, 39,
 40, 41, 42, 44, 45, 46, 48, 49,
 50, 51

B

Bulanık Mantık · iv, v, ix, x, xii,
 xiii, 3, 8, 32

E

Eğitim · xii, 9, 14, 17, 25, 26, 31,
 40, 41, 42, 43

İ

Interaction · iv, vi, 2, 27, 28, 29,
 35, 36, 38, 48, 49, 50

K

Kaza Sayısı · iv, v, ix, x, xi, xii, 1,
 2, 10, 27, 31, 35, 36, 40, 41, 44,
 45, 48, 49, 50
 Karayolları · iv, ix, xi, xiii, 1, 24,
 27, 28, 29

L

Lineer · iv, v, ix, x, xi, 2, 27, 28,
 29, 30, 34, 36, 37, 38, 39, 48,
 49, 520, 51
 Logaritmik · iv, v, 2, 27, 28, 29,
 30, 31, 35, 36, 37, 38, 39, 41,
 48, 49, 50, 51

M-N

Model · iv, v, vi, vii, xi, xii, 2, 3, 4,
 5, 6, 7, 8, 9, 10, 11, 12, 13, 14,
 15, 16, 17, 18, 19, 20, 21, 22,
 23, 24, 25, 26, 30, 31, 32, 33,
 35, 36, 37, 38, 39, 40, 41, 42,
 43, 44, 45, 46, 47, 48, 49, 50,
 51
 Nüfus · iv, 1, 5, 11, 27, 28, 29, 35,
 36, 38, 50

Ö

Özet · iv
 Ölüm Sayısı · iv, v, ix, x, xi, xii,
 28, 36, 38, 41, 42, 45, 46, 48,
 49, 50, 51

P

Purequadratic · iv, vi, 2, 27, 28,
 29, 31, 35, 36, 37, 38, 39, 48,
 49, 50, 51

R

Regresyon · iv, v, ix, x, xi, xii, 2,
 4, 5, 6, 7, 8, 10, 14, 15, 17, 19,
 21, 23, 27, 28, 29, 30, 31, 32,
 35, 36, 37, 38, 39, 40, 41, 42,
 43, 48, 49, 50, 51

S

Sürücü Sayısı · iv, 1, 27, 28, 29,
 35, 36, 38, 50

T

Trafik · iv, v, vi, vii, viii, ix, x, xi,
 xii, xiii, 1, 2, 3, 4, 5, 6, 7, 8, 9,
 10, 11, 12, 13, 14, 15, 16, 17,
 18, 19, 20, 21, 22, 23, 24, 25,
 26, 27, 28, 29, 30, 31, 32, 33,
 34, 35, 36, 37, 38, 39, 40, 41,
 42, 43, 44, 45, 46, 47, 48, 49,
 50, 51
 Taşıt Sayısı · iv, 27, 28, 29, 50
 Tahmin · iv, v, ix, x, xi, xii, 1, 2, 3,
 5, 6, 7, 8, 9, 10, 11, 12, 13, 14,
 15, 17, 18, 19, 20, 21, 22, 23,
 24, 25, 30, 31, 32, 35, 36, 38,
 40, 41, 42, 43, 44, 45, 46, 48,
 49, 50, 51

Q

Quadratic · iv, v, vi, vii, 2, 27, 28,
 29, 30, 31, 35, 37, 38, 39, 48,
 49, 50, 51

Y

Yaralı Sayısı · iv, v, ix, x, xi, xii,
 29, 38, 42, 43, 46, 47, 48, 49,
 50, 51



TEKNOVERSITE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

