

**VERİ MADENCİLİĞİ:
YAPAY SİNİR AĞI VE DOĞRUSAL REGRESYON YÖNTEMLERİ İLE
FİYAT TAHMİNİ**

**Pamukkale Üniversitesi
Sosyal Bilimler Enstitüsü
Yüksek Lisans Tezi
İşletme Bölümü
Sayısal Yöntemler Anabilim Dalı**

Sait Uğur GÜLTEKİN


Danışman: Doç. Dr. Arzu ORGAN

**Ağustos 2017
DENİZLİ**

YÜKSEK LİSANS TEZİ ONAY FORMU


İşletme Anabilim Dalı, Sayısal Yöntemler Bilim Dalı öğrencisi Sait Uğur GÜLTEKİN tarafından Doç. Dr. Arzu ORGAN yönetiminde hazırlanan “Veri Madenciliği: Yapay Sinir Ağı ve Doğrusal Regresyon Yöntemleri ile Fiyat Tahmini” başlıklı tez aşağıdaki jüri üyeleri tarafından 17.08.2017 tarihinde yapılan tez savunma sınavında başarılı bulunmuş ve Yüksek Lisans Tezi olarak kabul edilmiştir.


Doç. Dr. Arzu ORGAN
Jüri Başkanı


Prof. Dr. İrfan ERTUĞRUL
Jüri Üyesi


Yrd. Doç. Dr. Hüseyin ŞENKAYAS
Jüri Üyesi

Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun 13/09/2017 tarih ve 34/24 sayılı kararıyla onaylanmıştır.

Prof. Dr. Mehmet
Vefa NALBANT
Enstitü Müdürü


Bu tezin hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde, bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini, alıntı yapılan alıřmalara atfedildiđini beyan ederim.

İmza

Sait Uęur GÜLTEKİN

ÖNSÖZ

İkinci el araç piyasasında; satıcı ve alıcı tarafın doğru fiyatlandırma ve hızlı alım satım için öncelikle mümkün olduğunca çok tecrübeye veya bu tecrübeyi sağlayabilecek donanıma sahip aracılık hizmetine ihtiyaçları bulunmaktadır. Bu ikisinin eksikliğinde ise vakit kaybı oluşmaktadır.

Bu bağlamda veri madenciliğinin önemini ve verinin kalitesi ile olan ilişkisini ortaya koymak adına yapılan bu çalışmada doğrusal regresyon ve yapay sinir ağları yöntemleri karşılaştırılmıştır. Bu karşılaştırma sonucunda ikinci el otomobil piyasasına, konuya ilgi duyan araştırmacılara ve alım satım yapan kişi veya kurumlara katkı yapmaya çalışılmaktadır. Dolayısı ile elde edilen bu sonuçların faydalı olmasını temenni ederim.

Çalışmanın en başından beri destekleyen ve yönlendiren sayın Doç. Dr. Arzu ORGAN'a, Prof. Dr. İrfan ERTUĞRUL'a bilgi ve deneyimlerini benimle paylaşan Fatma ETEMAN'a ve Volkan ETEMAN'a sonsuz teşekkürlerimi sunuyorum.

Bu çalışmamı, annem Emine GÜLTEKİN'e babam Ali GÜLTEKİN'e ve kardeşim Duygu GÜLTEKİN'e ithaf ediyorum.

ÖZET

VERİ MADENCİLİĞİ: YAPAY SİNİR AĞI VE DOĞRUSAL REGRESYON YÖNTEMLERİ İLE FİYAT TAHMİNİ

Gültekin, Sait Uğur

Yüksek Lisans Tezi

İşletme Anabilim Dalı

Sayısal Yöntemler Programı

Temmuz 2017, 160 Sayfa

Veri madenciliği kavramı, finans piyasaları için son derece önemlidir. Çünkü yeterli veri ile bir mal veya hizmetin fiyatı tahmin edilebilir ve o mal veya hizmeti satın almak için harcanan zaman kayda değer miktarda azaltılabilir. Bu tezde ikinci el otomobil piyasasında yer alan araçların fiyatlarının veri madenciliği ile tahmini üzerine uygulama çalışması yapılmıştır. Bu çalışmada veri madenciliği aşamaları kullanılarak problem tanımı yapılmış, veri ön hazırlığı içerisinde veri temizliği yapılmış, veri keşfi ile veriler düzenlenmiş, modellenmiş, oluşturulan model değerlendirmeye alınmış ve model yerleştirme ile veri kullanılacak olan algoritmaların çalışma prensibine uygun hale getirilmiştir. Sonrasında doğrusal regresyon ve yapay sinir ağı yöntemleri ile değerlendirilmiştir. Değerlendirmeden çıkan sonuçlar ile ikinci el otomobil piyasasında yer alan araçların fiyatlarına yönelik tahmini veriler karşılaştırılmıştır. İkinci el araç fiyat tahmininde elde edilen bulgulardan biri, yapay sinir ağları ile yapılan tahminlerin sapma miktarlarının genellikle doğrusal regresyondan daha iyi sonuç verdiğiidir. Bir diğer bulgu ise doğru verinin girilmesi ile sapma miktarlarının kayda değer seviyede azaldığıdır.

Anahtar Kelimeler: Veri Madenciliği, Doğrusal Regresyon, Yapay Sinir Ağları.

ABSTRACT
**DATA MINING: A PRICE PREDICTION WITH ARTIFICIAL NEURAL
NETWORK AND LINEAR REGRESSION MODELS**

Gültekin, Sait Uğur

Master's Thesis

Department of Business Administration

Numerical Methods Programme

July 2017, 160 Pages

Concept of data mining is crucial for the finance market. Because cost of a good or a service can be estimated and the time which is spent to purchase that good or service can be reduced significantly with sufficient data. In this thesis, an application study was carried out on the estimation of the prices of the vehicles in the second hand car market. In this work with problem definition was made by using data mining stages, data cleaning was done in data preparation, data was arranged by the data exploration, modelling was done, created model was evaluated, and data was adapted by model deployment to the working principles of the algorithms that would be used. Then, it was evaluated by the methods of linear regression and artificial neural network. Results from the evaluation were compared with the estimated data for the prices of the vehicles in the second hand car market. Findings obtained in the second hand vehicle price forecasts show that the amount of the deviations made with artificial neural networks give generally better results than those made with linear regression. Another finding is that the amount of deviation decreases significantly by entering correct data.

Keywords: Data Mining, Linear Regression, Artificial Neural Networks.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
İÇİNDEKİLER.....	iii
TABLolar DİZİNİ.....	v
ŞEKİLLER DİZİNİ.....	vi
GİRİŞ.....	1

BİRİNCİ BÖLÜM VERİ MADENCİLİĞİ

1.1. Veri Madenciliği Tanımı.....	9
1.2. Veri Madenciliğinin Tarihçesi.....	9
1.3. Veri Madenciliğinin Aşamaları.....	11
1.3.1. Problem Tanımı.....	11
1.3.2. Veri Ön Hazırlığı.....	11
1.3.2.1. Veri Temizleme.....	12
1.3.2.1.1. Kayıp Değerler.....	12
1.3.2.1.2. Gürültülü Veri.....	13
1.3.2.2. Veri Entegrasyonu.....	15
1.3.2.3. Veri Seçimi.....	16
1.3.2.4. Veri Dönüştürme.....	17
1.3.2.5. Veri İndirgeme.....	17
1.3.2.6. Ayrıklaştırma ve Konsept Hiyerarşisi Oluşturma.....	20
1.3.3. Veri Keşfi (Data Exploration).....	20
1.3.3.1. Geçmiş Açıklamak.....	20
1.3.3.1.1. Tek Değişkenli Keşif.....	21
1.3.3.1.2. İki Değişkenli Keşif.....	23
1.3.3.1.2.1. Kategorik – Kategorik Veri Keşfi.....	24
1.3.3.1.2.2. Nümerik (Sürekli) – Kategorik Veri Keşfi.....	26
1.3.3.1.2.3. Nümerik (Sürekli) – Nümerik (Sürekli) Veri Keşfi.....	28
1.3.3.4. Modelleme (Modeling).....	30
1.3.3.5. Model Değerlendirme (Model Evaluation).....	31
1.3.3.6. Model Yerleştirme (Deployment).....	31
1.4. Veri Madenciliğinde Sık Kullanılan Yollar, Ortaklıklar ve Bağıntılar.....	31
1.4.1. Veri Madenciliğinde Sık Karşılaşılan Modeller.....	31
1.4.2. Basit Konseptler ve Yol Haritaları.....	32
1.5. Geleceği Tahmin Etmek.....	32

İKİNCİ BÖLÜM VERİ MADENCİLİĞİ TEKNİKLERİ

2.1. Karar Ağacı İle Sınıflandırma.....	34
2.2. Kural Bazlı Sınıflandırmalar.....	36
2.3. Bayes Ağları (Bayesian Networks).....	37
2.4. K En Yakın Komşu.....	39
2.5. Yapay Sinir Ağları.....	41
2.5.1. Yapay Sinir Ağları Ağ Yapısı.....	46
2.5.1.1. İleri Beslemeli Sinir Ağları (Feedforward Neural Networks).....	46
2.5.1.2. Tekrarlayan Ağlar (Recurrent Network).....	48
2.5.1.3. Kohonen Sinir Ağı.....	49
2.6. Destek Vektör Makinaları.....	49
2.6.1. Doğrusal Olarak Ayrılabilen Destek Vektör Makinaları.....	51
2.6.2. Doğrusal Olarak Ayrılamayan Destek Vektör Makinaları.....	51

2.7.	Kaba Kümeler	52
2.8.	Genetik Algoritmalar	52
2.8.1.	Seçim (Selection)	54
2.8.2.	Genetik Değişim (Crossover).....	54
2.8.3.	Mutasyon (Mutation)	54
2.9.	Performans Tahmini Değerlendirmesi	54
2.10.	Regresyon.....	55
2.10.1.	Regresyonda Alt Küme Seçimi.....	55
2.10.2.	Regresyon Ağaçları.....	57
2.11.	Kümelendirme	57
2.12.	Boyut Azaltma (Dimensionality Reduction).....	61
ÜÇÜNCÜ BÖLÜM		
VERİ MADENCİLİĞİ: YAPAY SİNİR AĞI VE DOĞRUSAL REGRESYON YÖNTEMLERİNİN İKİNCİ EL ARAÇ PİYASASININ TAHMİNİ ÜZERİNE UYGULANMASI		
3.1.	Uygulamanın Tanıtımı: İkinci El Araç Alımı	62
3.1.1.	İkinci El Araç Fiyat Tahmini İle İlgili Çalışmalar	62
3.1.2.	Uygulamanın Önemi	63
3.1.3.	Uygulamanın Amacı	63
3.1.4.	Uygulamanın Kapsamı.....	63
3.1.5.	Uygulamanın Yöntemi	64
3.2.	Verilerin Weka Programına Yüklenmesi	65
3.3.	İkinci El Araç Alımı İçin Hurriyetoto.com Örneği	66
3.4.	İkinci El Piyasasında Satışa Sunulan Araçların İstatistiksel Verileri.....	68
3.5.	Sınıflandırma İşleminin Gerçekleştirilmesi	71
3.6.	Doğrusal Regresyon Uygulamasının Gerçekleştirilmesi	71
3.7.	Yapay Sinir Ağı Uygulamasının Gerçekleştirilmesi.....	72
3.8.	Elde Edilen Verilerin Modeller Üzerine İşlenmesi.....	75
SONUÇ		120
KAYNAKLAR		125
EKLER		137
EK – 1		137
ÖZGEÇMİŞ		161

TABLolar DİZİNİ

Tablo 1. Eşit Frekanslara Ayırma	14
Tablo 2. Ortalama İle Pürüzsüzleştirme.....	14
Tablo 3. Kutu Sınırları İle Pürüzsüzleştirme.....	15
Tablo 4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları (Cerny, 2001: 4,5)	45
Tablo 5. En çok satışta bulunan ikinci el araç modelleri	68
Tablo 6. Korelasyon Performanslarının Karşılaştırılması.....	76
Tablo 7. Ortalama Mutlak Hata ve Mutlak Hata Yüzdelerinin Karşılaştırılması	77
Tablo 8. Opel Astra Yıllara Göre Fiyat Tahmini	79
Tablo 9. Renault Megane Yıllara Göre Fiyat Tahmini	81
Tablo 10. Renault Clio Yıllara Göre Fiyat Tahmini	83
Tablo 11. Tofaş Şahin Yıllara Göre Fiyat Tahmini	85
Tablo 12. Volkswagen Polo Yıllara Göre Fiyat Tahmini	87
Tablo 13. Ford Fiesta Yıllara Göre Fiyat Tahmini	89
Tablo 14. Fiat Linea Yıllara Göre Fiyat Tahmini	91
Tablo 15. Honda Civic Yıllara Göre Fiyat Tahmini	93
Tablo 16. Volkswagen Golf Yıllara Göre Fiyat Tahmini	95
Tablo 17. Volkswagen Jetta Yıllara Göre Fiyat Tahmini	98
Tablo 18. BMW 3 Serisi Yıllara Göre Fiyat Tahmini	99
Tablo 19. Tofaş Doğan Yıllara Göre Fiyat Tahmini.....	102
Tablo 20. Renault Symbol Yıllara Göre Fiyat Tahmini.....	103
Tablo 21. Fiat Fiorino Yıllara Göre Fiyat Tahmini.....	105
Tablo 22. BMW 5 Serisi Yıllara Göre Fiyat Tahmini	107
Tablo 23. Tofaş Kartal Yıllara Göre Fiyat Dağılımı.....	109
Tablo 24. Hyundai Accent Yıllara Göre Fiyat Dağılımı.....	111
Tablo 25. Opel Vectra Yıllara Göre Fiyat Dağılımı	113
Tablo 26. Ford Tourneo Yıllara Göre Fiyat Tahmini	115
Tablo 27. Peugeot 206 Yıllara Göre Fiyat Tahmini.....	117

ŞEKİLLER DİZİNİ

Şekil 1. Veri Madenciliği Haritası (Sayad, 2016).....	8
Şekil 2. Veri Entegrasyon Yapısı (Doan, McCann, 2003: 1).....	16
Şekil 3. Veri İndirgeme Teknikleri (Kalegele ve diğerleri, 2011: 2).....	18
Şekil 4. Veri Küpü Örneği (Urbanek, 2015, p.4).....	19
Şekil 5. Tek Değişkenli Keşif Türleri (Online: https://www.researchgate.net/file.PostFileLoader.html?id=567002b35f7f7176358b4585&assetKey=AS%3A306896769093632%401450181299197 2016: p.2).....	21
Şekil 6. Frekans Tablosu (Sayad, 2016: 1)	22
Şekil 7. Normal Çubuk Grafik (Allison 2016: 24).....	24
Şekil 8. Yığılmış Çubuk Grafiği (Allison 2016: 24).....	25
Şekil 9. Kombinasyon Grafiği (Hardin ve Diğerleri, 2016: 23)	26
Şekil 10. Hata Çubuklu Çizgi Grafiği (Shaw, Most, 1990: 1421).....	27
Şekil 11. Nümerik-Kategorik Veri Kombinasyon Grafiği (IBM, 2014: 6).....	28
Şekil 12. Saçılım Grafiği Örneği (Medeiros-Riberio ve diğerleri, 1998: 354).....	29
Şekil 13. Doğrusal Korelasyon Örnekleri (Butler, 1985: 139,140)	30
Şekil 14. Karar Ağacı Yapısı (Breslow, 1997: 3)	36
Şekil 15. Bayes Ağı Örneği (Korb ve Nicholson, 2010: 31)	39
Şekil 16. K en yakın komşu örneği (Garcia ve diğerleri, 2008: 3)	41
Şekil 17. Basit Bir Nöron Yapısı (Online: 21.04.2016, http://www.biyodoc.com/sinir%20sistemi/4.PNG)	43
Şekil 18. Yapay Sinir Ağı Yapısı (Dawson, Wilby, 1998: 49).....	44
Şekil 19. Bir Nöronun Grafik Yapısı (Kumar, 2016: 159)	44
Şekil 20. İleri Beslemeli Sinir Ağı Yapısı (Kumar, 2016: 160).....	47
Şekil 21. Kısmen Birbirine Bağlı Tekrarlamalı Sinir Ağı (Medsker, Jain, 2001: 12)	48
Şekil 22. Tamamen Birbirine Bağlı Tekrarlamalı Sinir Ağı (Medsker, Jain, 2001: 12).48	
Şekil 23. Destek Vektör Makinaları Düzlem Üzerinde Gösterimi (Aggarwal, Singh, 2015: 246)	51
Şekil 24. Hiyerarşik Algoritmalar (Andritsos, 2002: 9).....	58
Şekil 25. Arff Dosya Görünümü	65
Şekil 26. Kümülatif Görselleştirmeler	66
Şekil 27. Örneklem Uzayının Görünümü.....	66
Şekil 28. Markaların Sayısallaştırılması	67
Şekil 29. Marka İstatistikleri	68
Şekil 30. Renk İstatistikleri	70
Şekil 31. Yıllara göre dağılım grafiği	70
Şekil 32. Doğrusal Regresyon Birinci Kısım	71
Şekil 33. Sınıflandırıcı Modeli	72
Şekil 34. Çalışma seti üzerinde geliştirme	72
Şekil 35. Sonuç Kısmı.....	72
Şekil 36. Yapay Sinir Ağının Görselleştirilmesi.....	73
Şekil 37. Sınıflandırıcı Model	74
Şekil 38. Sonuç kısmı.....	75
Şekil 39. Opel Astra Tahmin Genel Görünümü.....	78
Şekil 40. Opel Astra Tahmin Daraltılmış Görünüm	79
Şekil 41. Opel Astra Fiyat Farkı Görünümü	79
Şekil 42. Renault Megane Tahmin Daraltılmış Görünüm	81
Şekil 43. Renault Megane Fiyat Farkı Görünümü	81
Şekil 44. Renault Clio Tahmin Daraltılmış Görünüm	83
Şekil 45. Renault Clio Fiyat Farkı Görünümü	83

Şekil 46. Tofaş Şahin Daraltılmış Görünüm	85
Şekil 47. Tofaş Şahin Fiyat Farkı Görünümü	85
Şekil 48. Volkswagen Polo Daraltılmış Görünüm	87
Şekil 49. Volkswagen Polo Fiyat Farkı Görünümü	87
Şekil 50. Ford Fiesta Daraltılmış Görünüm	89
Şekil 51. Ford Fiesta Fiyat Farkı Görünümü	89
Şekil 52. Fiat Linea Tahmin Daraltılmış Görünüm	91
Şekil 53. Fiat Linea Tahmin Daraltılmış Görünüm	91
Şekil 54. Honda Civic Tahmin Daraltılmış Görünüm	92
Şekil 55. Honda Civic Fiyat Farkı Görünümü	93
Şekil 56. Volkswagen Golf Tahmin Daraltılmış Görünüm	95
Şekil 57. Volkswagen Golf Fiyat Farkı Görünümü	95
Şekil 58. Volkswagen Jetta Tahmin Daraltılmış Görünüm	97
Şekil 59. Volkswagen Jetta Fiyat Farkı Görünümü	97
Şekil 60. BMW 3 Serisi Tahmin Daraltılmış Görünüm.....	99
Şekil 61. BMW 3 Serisi Fiyat Farkı Görünümü	99
Şekil 62. Tofaş Doğan Tahmin Daraltılmış Görünüm	101
Şekil 63Tofaş Doğan Fiyat Farkı Görünümü.....	101
Şekil 64. Renault Symbol Tahmin Daraltılmış Görünüm.....	103
Şekil 65. Renault Symbol Fiyat Farkı Görünümü.....	103
Şekil 66. Fiat Fiorino Tahmin Daraltılmış Görünüm.....	105
Şekil 67. Fiat Fiorino Fiyat Farkı Görünümü	105
Şekil 68. BMW 5 Serisi Tahmin Daraltılmış Görünüm.....	106
Şekil 69. BMW 5 Serisi Fiyat Farkı Görünümü	107
Şekil 70. Tofaş Kartal Tahmin Daraltılmış Görünüm.....	109
Şekil 71. Tofaş Kartal Fiyat Farkı Görünümü	109
Şekil 72. Hyundai Accent Tahmin Daraltılmış Görünüm.....	111
Şekil 73. Hyundai Accent Fiyat Farkı Görünümü	111
Şekil 74. Opel Vectra Tahmin Daraltılmış Görünüm	113
Şekil 75. Opel Vectra Fiyat Farkı Görünümü	113
Şekil 76. Ford Tourneo Tahmin Daraltılmış Görünüm.....	115
Şekil 77. Ford Tourneo Fiyat Farkı Görünümü	115
Şekil 78. Peugeot 206 Tahmin Daraltılmış Görünüm.....	117
Şekil 79. Peugeot 206 Fiyat Farkı Görünümü.....	117

GİRİŞ

Dünya sürekli olarak büyüyüp gelişmekte, bu gelişmeye paralel olarak üretilen veri miktarı da hızlı bir biçimde artmaktadır. Veriler her geçen gün yaşamla daha fazla ilgili olmakta ve yaşamın vazgeçilmez unsurlarından biri olmaktadır. İlk zamanlarda yüksek harcamalar ve kaynak gerektiren veri depolama işlemleri şu anda ev hayatının içerisine kadar girmiş durumdadır. İnternetin de gelişmesi ile beraber bu verilere ulaşma süresi milisaniyelerle ölçülmeye başlanmıştır.

Bu kadar yüksek veri miktarı ve veri depolama ve işleme faaliyetlerinin ulaşılabilirliğinin artması birtakım fırsatları da beraberinde getirmiştir. İnsanlar biriken bu verinin içerisinden; hastalıkları tespit edip önceden önlemini alma ya da potansiyel hasta olacak kişileri tespit edebilme fırsatı bulabilmiş, terör saldırılarını henüz gerçekleşmeden engelleyebilmiş, müşterilerin bir sonraki alışverişlerinde ne alacağını tahmin edebilmiş, geleceğe dair daha isabetli önlemler alıp risklerden kaçınabilmiş, geçmişte yaşanan birçok olayı isabetli bir şekilde açıklayabilmiş, ortaya çıkabilecek fırsatları önceden sezebilmiş ve bunun gibi birçok işlemi gerçekleştirebilmiştir. Hatta bir adım daha ileri giderek bir takım yeni icatlar ve keşifler de gerçekleştirebilmiştir.

İnsan doğası gereği olarak günlük yaşamın belirsizliği dolayısı ile sürekli olarak bir adım önde olma isteği duyar. Yaşamı boyunca riski minimuma indirmeye çalışır. Görebildiği tüm fırsatlardan yararlanmak ister. Kendine ayırmak istediği vakti mümkün olduğunca arttırmaya çalışır. Bu ve bunun gibi sebeplerden dolayı veri madenciliğinin gelecekte olabilecek olayları tahmin edebilmesi, gözle görülmeyen ya da görülse bile önemsenmeyen fırsatları görebilmesi, daha önce tespit edilememiş olan ilişkileri tespit edebilmesi ve bütün bunları çok hızlı bir biçimde yapabilmesi nedeniyle tercih sebebi olmuştur.

Veri madenciliği; veriden bilgi çıkarımı, bilgi keşfi veya model çıkarımıdır. Yüksek boyutlu ham veriden bilgi çıkararak bu yöntem; kısa sürede çok fazla veriyi işleyebilmesi, veri artarken güncellemeleri kısa sürede yapabilmesi ve yüksek doğruluklu sonuçlar vermesi nedeniyle tercih edilmektedir. Veriden işe yarayan modeller çıkararak yöntemlere tarihsel olarak çeşitli isimler verilmiştir. Bunlar; veri madenciliği, veri çıkarımı, bilgi keşfi, bilgi hasatı, veri arkeolojisi ve veri model işlemedir. Veri madenciliği terimi daha çok istatistikçiler, veri analistleri ve bilgi sistemleri yöneticileri tarafından kullanılmaktadır (Fayyad ve diğerleri, 1996: 38).

Üretilen veri miktarının artışı her geçen gün katlanarak artmaktadır. Örneğin bir uzay teleskopunun bir günde topladığı veri neredeyse insanlık tarihi boyunca öğrenilmiş veri miktarı kadardır. Bu kadar verinin sadece insanlar tarafından işlenmesi ve incelenmesi mümkün olmamaktadır. Veri madenciliği teknikleri toplanan bu yüksek miktardaki verileri bir araya getirerek, temizleyerek gereken analizleri yapar. Bu sadece yıldızları haritalandırma alanında kullanılmaz. Aynı zamanda uydulardan alınan görüntüler ile herhangi bir uydunun yörüngesinden ne kadar saptığını da hesaplayarak gelecek tehlikelere karşı gerekli önlemlerin alınabilmesini de sağlar. Aynı zamanda genetik biliminde de kullanılan veri madenciliği DNA ve RNA haritalandırılmaları ile birlikte genetik sebeplerle meydana gelen hastalıklar tespit edilebilmiş ve çözümleri konusunda gerekli araştırmaların başlatılmalarına olanak sağlamıştır. Bu örnekler farklı bilim dalları için arttırılabilir.

İşletmelerde ve finans piyasalarında ise veri madenciliği farklı değişkenleri kullanarak; müşterinin kredi profilini ve kredi kullanabilmesi durumunu, kredi kartı ile yapılan alışverişlere bağlı olarak farklı bölgelerden gelen alışverişleri kredi kartı hırsızlığı olarak tanımlayarak müşterinin para kaybetmesini engellemek için ödemeleri durdurması veya müşteriye mesaj ya da çağrı yoluyla ödemeyi doğrulatması, müşteri açısından bir mal veya hizmetin fiyatının piyasadaki verileri değerlendirerek en avantajlı olanın bulunması gibi birçok avantajları mevcuttur.

Avantajları gibi veri madenciliğinin birtakım dezavantajları da mevcuttur. Veri madenciliği bazı durumlarda anlaşılabilir yapıya ile insanları korkutabilmektedir. Çok fazla veri toplaması nedeniyle kişilik haklarının tehlikeye atılması gibi sonuçlar doğurabilmekte, bu verilerin kötü amaçlı insanların eline düşmesi ile büyük sanal şantaj olaylarına dönüşebilmesi ihtimali olmaktadır. Ayrıca son yıllarda özellikle reklam çalışmaları için toplanana verilerin, kullanıcıların girdikleri veri sitelerinin reklam kısımlarına yansımaları, daha önceden alışveriş yaptığı ürünleri ya da ürünlerin benzerlerinin bu reklamlarda gösterilmesi, daha önceden girmiş oldukları internet sitelerine benzer önerilerin ortaya çıkması kullanıcılar tarafından tepkiyle karşılanmış ve Avrupa'da ve çeşitli ülkelerde bu veri toplama faaliyetleri için belirli kısıtlamalar ve büyük cezalar ile veri toplayan kuruluşların daha dikkatli davranmaları üzerinde baskı oluşturmaya başlamıştır.

Veri madenciliği teknikleri üzerinde yapılmış olan bu araştırma, dört bölümden oluşmakta olup ilk bölümde veri madenciliği tanımı, tarihçesi, aşamaları, veri

madenciliğinde sık kullanılan yollar, ortaklıklar, bağıntılar ve geleceği tahmin etme başlıkları incelenmiştir.

İkinci bölümde veri madenciliği teknikleri tanıtılmış ve hiyerarşik bir ağaç yapısına sahip olan karar ağacı ile sınıflandırma, eğer- öyleyse yapısına sahip olan yüksek seviyeli ve kolay yorumlanabilen kural bazlı sınıflandırmalar, bayes teoremi üzerine kurulmuş olan istatistiksel sınıflandırıcı bayes ağları, örüntü tanıma alanında kullanılan k en yakın komşu tekniği, biyolojik sinir ağları temel alınarak geliştirilen ve kendi kendine öğrenebilen yapay sinir ağları, doğrusal düzlem üzerinde yer alan sınıflar arasındaki en uzun mesafeyi bulmaya çalışan destek vektör makinaları, objeler arasında ilişki bulmaya yarayan kaba kümeler, büyük veri içeren ve optimizasyon problemleri üzerinde uygulanan genetik algoritmalar, sayısal verileri tahmin eden regresyon, verileri benzer daha küçük kümelere ayırarak işlenmesini kolaylaştıran kümelendirme, yüksek miktardaki veriyi sıkıştırarak işlenmesini kolaylaştıran boyut azaltma teknikleri incelenmiştir.

Üçüncü bölümde ise veri madenciliği tekniklerinden olan yapay sinir ağları ve doğrusal regresyon yöntemleri ile ikinci el otomobil piyasası üzerine fiyat tahmin işlemi gerçekleştirilmiş ve bu işlem gerçekleştirilirken öncelikle doğrusal regresyon ve yapay sinir ağları yöntemlerinin korelasyon değerleri, ortalama mutlak hata ve ortalama mutlak yüzde hata değerleri hesaplanmıştır. Bu işlemlerden sonra ortalama mutlak hata ve ortalama mutlak yüzde hatası en düşük olan yöntemin fiyat tahmini üzerinde değerlendirmelerde bulunulmuştur. Sonuç bölümünde ise, genel bir değerlendirme yapılarak gelecekte yapılabilecek çalışmalara değinilmiş ve öneriler sunulmuştur.

BİRİNCİ BÖLÜM

1. VERİ MADENCİLİĞİ

Bilgisayar sistemleri ile üretilen veriler tek başlarına değersizdir, çünkü çıplak gözle bakıldığında bir anlam ifade etmezler. Bu veriler belli bir amaç doğrultusunda işlendiği zaman bir anlam ifade etmeye başlar. Bilgi bir amaca yönelik işlenmiş veridir. “Ham veri”ye veya yalnız geçmişte ne olduğunun bir görüntülemesi olan “enformasyon”a dayalı karar almak mümkün değildir. Geçmişte yaşanan kötü bir tecrübeden kaynaklanan kaybın engellenmesi de mümkün değildir. Önemli olan geçmişe ait olaylara dair gizli bilgilerin keşfedilmesi, ileriye yönelik durumsal öngörüler veren modeller ile önceden tedbir almamızı sağlayacak bir yönetim anlayışına geçmek ve olası kayıpları öngörebilmektir. Bu yüzden büyük miktardaki verileri işleyebilen teknikleri kullanabilmek büyük önem kazanmaktadır. Bu ham veriyi bilgiye veya anlamlı hale dönüştürme işlemleri veri madenciliği ile yapılabilmektedir. Veri madenciliği, bu gibi durumlarda kullanılan büyük miktardaki veri setlerinde saklı durumda bulunan örüntü ve eğilimleri keşfetme işlemidir (Savaş, S ve diğerleri. 2012: 2).

Veri madenciliği; büyük veri tabanlarından ya da veri setlerinden işe yarar bilgi çıkarımıdır. (Hand, 2001: 27) Veri madenciliği yerine; bilgi çıkarımı, veri tabanlarında bilgi keşfi, veri arkeolojisi ve veri örüntü analizleri gibi terimlerde kullanılmaktadır.

Veri madenciliği insanlığın varoluşundan beri vardır. İnsanların çevrelerini haritalandırarak tehlikeli hayvanların veya av hayvanlarının nerede yoğunlukta olduğunu tahmin edebilmeleri, havanın kokusuna göre yağmur yağıp yağmayacağını tahmin edebilmeleri gibi bilgiler tecrübelerin toplanmış olduğu birer veri madenciliği örnekleridir. Antik Mısır’da yıldızların ve ayın konumuna göre gelgitleri hesaplayan Mısırlılar hem matematik biliminin hem de veri madenciliğinin modern anlamda temellerini atmışlardır. Gerçek anlamda veri madenciliğinin başlaması ise bilgisayarın icadı sonrası veri depolama maliyetlerinin azalması ve veri miktarının analizciler tarafından tek başına incelenmesi işleminin imkânsızlaşmaya başlamasına denk gelir. Bu da 1990’lı yıllara denk gelmiştir. 1960’larda şirketin son beş yıllık finansal verileri incelenirken, 1980’lerde geçen yılın mart ayında belirli bir markette hangi ürünlerin satıldığı konusu incelenmiştir. 1990’larda geçen yıl mart ayında tüm marketlerde hangi ürünlerin satıldığı konusu incelenmiştir. Şimdilerde ise gelecek ay markette satılacak ürünlerin miktarları hesaplanmaya çalışılmaktadır. Veri madenciliğinin bu kadar

gelişmesi ve hala gelişmeye devam etmesinin nedeni ise analistler tarafından görülmeven veya önemsenmeyen ilişkileri de ortaya çıkarabilmesidir.

Veri madenciliğinin uygulanabilmesi için yığın halinde verilerin elimizde bulunması ön koşuldur. Veri madenciliği farklı formatlarda çok sayıda kütükte yığın halindeki veriler arasında gizli bir şekilde bulunan mesajları çekip çıkarmamıza yarayan bir araçtır. Veri madenciliği çeşitli açılardan geleneksel istatistiksel yöntemlerle önemli farklılıklar gösterir. Özellikle zaman içinde verinin azlığının değil, çokluğunun bir sorun olması ve bilgisayarların veri saklama ve işleme hızlarındaki inanılmaz artışların sonucunda veri madenciliğinin önemi her geçen gün artmış ve artmaktadır (Oğuzlar, 2003: 75)

Veri madenciliğinin amaçları:

- Toplanan bu verileri inceleyerek araştırmacının normalde gözüne çarpmayacak ya da önemli olarak görmediği farklı eğilimleri, bilgileri, fırsatları ya da riskleri bilgisayar programı yardımı ile ortaya çıkarmaktır.
- Zamandan tasarruf etmektir. Normalde araştırmacının aylarını hatta yıllarını alacak hesaplamaları ve incelemeleri çok kısa süre içerisinde yaparak zamandan tasarruf sağlar.
- Veriyi araştırmacının anlayabileceği formata sokmaktır. Buda verinin görselleştirilmesi ile olur.
- Verinin üzerinde anlık güncelleştirmelerin kolaylıkla yapılabilmesini sağlamaktır. Veri bilindiği üzere anlık olarak ve sürekli artan bir yapıya sahiptir. Veri madenciliği programları güncellenen veriyi ekstra bir çaba göstermeye gerek kalmadan kolaylıkla işleyebilir.

Veri madenciliğinin önemi; en başta veri üzerinde analiz yapmak için bir istatistikçiye ihtiyaç duyulmamasıdır. Geleneksel yöntemlere göre çok daha hızlı çalışmakta ve sonuç alınabilmektedir. Veri madenciliği sonrası çıkan sonuçların değerlendirilmesi için gereken istatistik bilgisi minimum düzeyde olmaktadır.

Veri madenciliğinin avantajları:

- Şirketlerin geçmiş verileri temel alarak model kurmasını sağlayarak yeni satış kampanyaları oluşturmalarını sağlar.
- Hedef müşteri kitlelerine göre kampanya oluşturulmasını sağlar.
- Müşterilerin alışveriş alışkanlıklarını takip ederek kişiye özel kampanyalar gerçekleştirilebilir.
- Potansiyel dolandırıcılık olaylarını ortaya çıkarmaya yardımcı olur.

- Üretim süreci içerisinde hatalı çalışan makineleri tespit etmeyi sağlar.
- Devletin vatandaşların finansal harcamalarını kontrol ederek suç teşkil edebilecek durumları tespit etmesini sağlar.

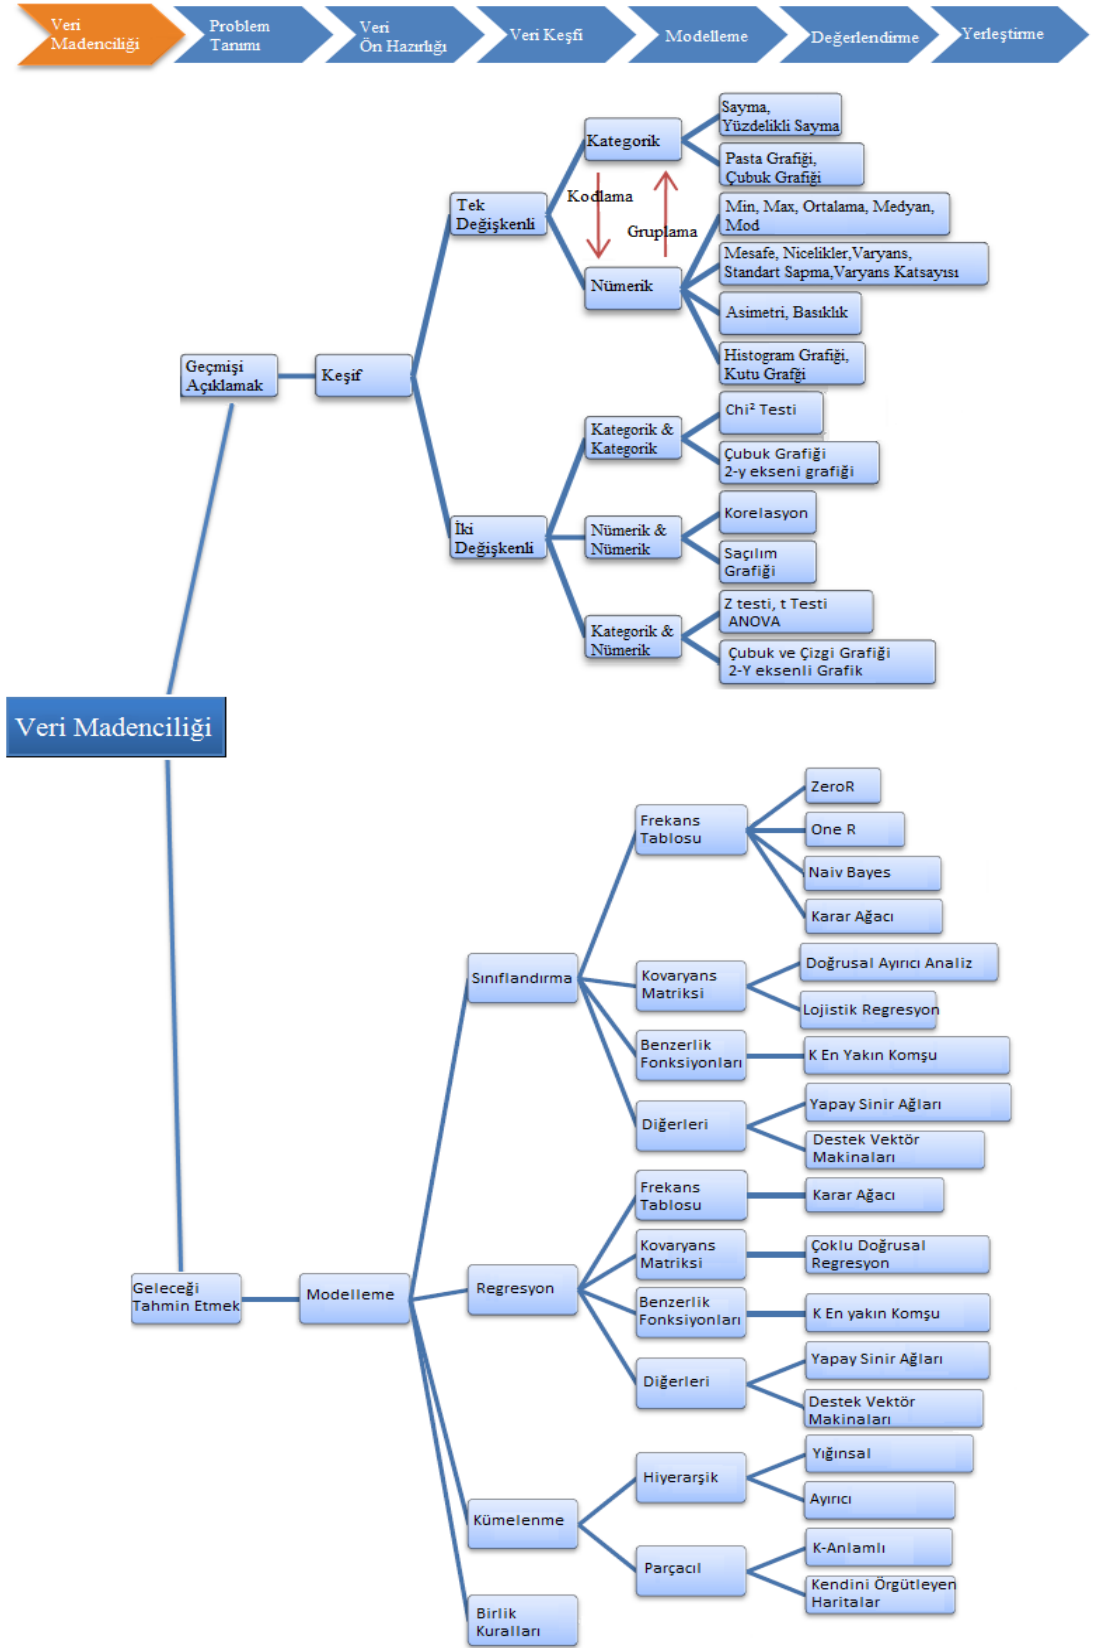
Veri madenciliğinin dezavantajları:

- Kişisel bilgilerin güvenliğini tehlikeye atabilir. Özellikle facebook, twitter gibi sosyal medya ağlarında yer alan verilerin kişilerin aleyhine bir tehdit unsuru olarak kullanılması ihtimali doğar.
- Kişilerin internet sitelerine girmiş olduğu özel verilerin çalınması ile kimlik numarası, kredi kartı numaraları gibi önemli verilerin güvende olması sorunu ortaya çıkar.
- Çok fazla veri ve değişkenin olması sapmalara ve yanıltıcı sonuçların alınmasına yol açabilir.
- Veri yanlış kullanılabilir.
- Verinin doğruluğunda sorunlar olabilir.

Veri madenciliği süreçlerini ve veri madenciliği haritasını bir bakıma Şekil 1’de gösterebiliriz. Şekil 1’de olduğu gibi, veri madenciliği süreci; problem tanımı, veri ön hazırlığı, veri keşfi, modelleme, değerlendirme ve yerleştirme olmak üzere beş aşamadan oluşur. Veri madenciliği sürecinde çözülmesi gereken en önemli şey problemin tanımlanmasıdır. Eğer çözümlenmesi gereken problem düzgün bir biçimde tanımlanmaz ise geriye kalan süreçler ne kadar iyi yönetilirse yönetilsin; istenilen sonuçlar elde edilemez. Problem tanımından sonra veri ön hazırlığı gerekmektedir. Veri ön hazırlığında ise veri temizlenir, dönüştürülür, indirgenir ve ayrıştırılır. Veri keşfi ise veri üzerinde istatistiksel ve görsel teknikler uygulanmasıdır. Veri modellemesi ise verinin hangi yöntem ile modellenmesi gerektiğine karar verir. Örneğin eğer veri kategorik ise sınıflandırma, sürekli ise regresyon analizi yöntemi kullanılarak modelleme gerçekleştirilebilir. Değerlendirme ise modelin geliştirilme sürecidir. Bu süreçte model üzerindeki eksiklikler giderilmeye çalışılır. Model yerleştirme veya yayınlama aşamasında ise oluşturulan modelin yeni bir veriyi tahmin etmede uygulanmasıdır. Gerekliliklere göre yerleştirme ya da yayınlama aşaması, bir rapor haline getirilebilecek kadar basitleştirmek veya yenilenebilir veri madenciliği süreci olarak tutmak için karmaşık halde tutulabilir.

Veri madenciliği süreç olarak ikiye ayrılabilir (Şekil 1). Birincisi geçmişini açıklamak, ikincisi ise geleceği tahmin etmektir. Geçmişte yapılan çalışmalarını dikkate almadan

gelecekte olacak ya da olabilecek olayları ya da durumları tahmin etmek mümkün olmayacaktır. Geçmiş tahmin etmek için veri içerisinde bir keşfe çıkmak gerekir. Keşif tek değişkenli analiz ve iki değişkenli analiz olarak ikiye ayrılır. Tek değişkenli analiz kategorik ve nümerik (sayısal) olmak üzere ikiye ayrılır. Kategorik verinin kodlanması ile nümerik veri, nümerik verinin ise gruplandırılması ile kategorik veri elde edilir. Kategorik ve nümerik veri arasındaki geçişler bu şekilde sağlanır. (Sayad, 2016)



Şekil 1. Veri Madenciliği Haritası (Sayad, 2016)

1.1. Veri Madenciliği Tanımı

Veri madenciliği basit bir tanımla veriden bilgi çıkarımıdır. Aslında veri madenciliği daha doğru bir tanım olarak “veriden bilgi madenciliği” olarak da adlandırılır. Bunun kısaltılmışı olarak da “bilgi madenciliği” olarak adlandırılır.

Veri madenciliğini tanımlamak için veriyi içerisinde maden damarları olan bir dağ, veri madencisini insan ve elinde dağ kazmak için kullanacağı aletleri ise veri madenciliği araç ve teknikleri olarak adlandırabiliriz. Herhangi bir araç ya da teknik kullanmadan yani çıplak elle kullanışlı olan veriyi aramak neredeyse imkânsızdır. Fakat bu araç ve teknikleri kullanarak kullanışlı verinin nerede olduğu tespit edilip kolayca çıkarılabilir.

Bilgisayarların gelişmesi ve veri depolama maliyetlerinin kayda değer düzeyde düşmesi ile veri miktarı önemli bir düzeyde artmıştır. Bu artışla analiz yapacak olan kişinin başa çıkabilmesi neredeyse imkânsız hale gelmiştir. Günümüz teknolojisinde veri çok hızlı değişen ve gelişen organik bir yapıya dönüşmüştür. Veri artış oranı her yıl insanlığın tüm tarihi boyunca öğrendiği tüm bilgiler kadar olmaya başlamıştır.

Veri madenciliği zamana karşı yapılan bir yarış gibidir. Veri madencisi yüksek doğruluk ile birlikte hızlı bir biçimde verinin içerisinde yer alan fırsatları görmek zorundadır ve büyük veri setleri içerisinde bu tarz bir yapılanmanın görülmesi neredeyse imkânsızdır. Bu imkânsızlık veri madenciliği araç ve tekniklerinin geliştirilmesini zorunlu kılmıştır. Geliştirilen bu araç ve tekniklerin amaçları hızlı bir biçimde veriyi temizlemek, sınıflandırmak, analizi yapmak ve kullanıcının anlayacağı şekilde görselleştirmektir.

Veri madenciliği disiplinler arası bir yapıya sahip olmakla beraber; bankacılık, finans, sağlık, eğitim, mühendislik, biyoloji, güvenlik ve astronomi gibi birçok alanda etkili bir biçimde kullanılmaktadır.

1.2. Veri Madenciliğinin Tarihçesi

Veri madenciliği aslında insanlık tarihi ile birlikte var olmuştur. Fakat gerek verinin az olması gerekse kullanılan araç ve tekniklerin kısıtlı olması bu işlemleri kolaylaştırmıştır. Örneğin vahşi hayvanların yaşadıkları bölgelerden insanlar ilk zamanlarda uzak durmaya çalışmışlardır. Fakat sonraları bu hayvanların ateşten korktuğunu görünce büyük ateşler yakmaya başlamışlardır. Zamanla insanlığın tecrübelerinden elde ettiği bu gibi kazanımların ve tecrübelerin artması ile birlikte karşılaşılan sorunlar gittikçe zorlaşmaya başlamış ve tek kişinin tek başına başa çıkamayacağı bir hal almıştır.

Veri madenciliği terimi ise bilgisayar bilimi alanı içerisinde ilk olarak 1980’lerde bir disiplin olarak adlandırılmıştır. 1990’ların başlarında veri madenciliği süreç olarak veri tabanlarından bilgi keşfi (knowledge discovery in databases – KDD) olarak adlandırılan sürecin bir alt dalı olarak ortaya çıkmıştır (Coenen, 2004: 1).

Veri madenciliği birden fazla disiplinin birleşerek bir blok oluşturması ile oluşmuştur. Bu bloğun içerisinde ilk zamanlarda veri tabanı yönetim sistemleri, yapay zekâ sistemleri ve makine öğrenme vardı (Venkatadri, Reddy, 2011: 19). Daha sonra gelişerek ve çeşitlenerek günümüzdeki halini almıştır.

Veri madenciliğini bugüne getiren önemli gelişmeler ise; istatistik altyapısı olarak 1763’te Thomas Bayes’in ortaya attığı Bayes Teoremi ile başlar. Sonrasında 1805’te Adrien – Marie Legendre ve Carl Friedrich Gauss güneşin gezegenlerin ve göktaşlarının büyüklüklerini hesaplamak için regresyon analizi yöntemini kullanmışlardır.

Bilgisayar çağı ile birlikte 1936’dan itibaren büyük miktarlarda verinin depolanması ve işlenmesi mümkün olmaya başlamıştır. 1936’da Alan Turing modern bilgisayarın temellerini atarak global bir hesaplama sistemi ortaya atmıştır. 1943’te Warren McCulloch ve Walter Pitts yapay sinir ağlarının konsept yapısının bir modelini oluşturmuşlardır. Bu yapıda nöronların üç yeteneği vardı. Bunlar girdileri almak, girdileri işlemek ve çıktılar ortaya çıkarmaktı. 1965’te Lawrence J. Fogel Karar Bilimi A.Ş. isimli şirketi kurdu. Bu şirket ile evrimsel programlama ile gerçek hayatta karşılaşılan problemleri çözmeye çalıştı. 1970’lerde karmaşık veri tabanı sistemlerinin gelmesi ile birlikte terabayt hatta petabayt düzeyinde veri depolama mümkün olmaya başladı. Fakat çok boyutlu veri olarak oldukça limitliydi. 1975’te John Henry Holland genetik algoritmanın temellerini attı.

1980’lerde HNC veri tabanı madenciliğinin ticari haklarını aldı. Bu ticari hakların alınmasının sebebi veri tabanı madenciliğinin iş istasyonları isimli ürünü koruma amaçlıydı. 1989’da veri tabanlarından bilgi keşfi (knowledge discovery in databases – KDD) terimi Gregory Piatetsky tarafından icat edildi. 1990’larda veri madenciliği terimi veri tabanı toplulukları tarafından ilk olarak ortaya atılmaya başlandı. Satış şirketleri ve finansal camia tarafından veriyi analiz ederek müşteri sayısını arttırma, trendleri keşfetme, dalgalanmaları ve faiz oranlarını tahmin etme, stok fiyatlarını ve müşteri taleplerini inceleme amacıyla kullanıldı. 1992’de Bernhard E. Boser, Isabelle M. Guyon ve Vladimir N. Vapnik destek vektör makinaları üzerinde bir gelişme öngörerek doğrusal

olmayan örneklerde de uygulanabilmesini sağladılar. 1993'te Gregory Piatetsky – Shapiro bilgi keşfi külçeleri (Knowledge Discovery Nuggets - KDnuggets) isimli araştırmacıları birbirine bağlayacak bir haber bülteni kurdu. 2001'de veri bilimi terimi 1960'lardan beridir kullanılmasına rağmen ilk defa bağımsız bir disiplin olarak tanımlandı. 2003'te Michael Lewis tarafından Moneyball isimli bir kitap yayınlandı. Bu kitapta Oakland Athletics takımı istatistiksel analiz yöntemlerini kullanarak; elde edilen verilerle olması gerekenden daha az değerli olan oyuncularını bularak diğer takımların üçte biri ücret ödeyerek 2002 ve 2003'te elemelere kadar ulaşabilmişlerdir.

2015'te Dj Patil beyaz sarayın ilk baş veri bilimcisi olmuştur. Şimdilerde ise en aktif olarak araştırılan metot derin öğrenme (deep learning) dir. Bu teknik diğer tekniklere göre çok daha karmaşık ilişkileri ortaya çıkarabilmekte ve çözebilmektedir. (Li Ray, 2017)

1.3. Veri Madenciliğinin Aşamaları

Veri madenciliği aşamaları problem tanımlama, veri ön hazırlığı, veri keşfi, modelleme, değerlendirme ve yerleştirme olmak üzere altı aşamadan oluşur.

1.3.1. Problem Tanımı

Problem tanımı gerek veri madenciliği için olsun, gerekse çözümü aranan herhangi bir sorun için olsun hayati öneme sahiptir. Eğer problem tanımı düzgün yapılmaz ise kuşkusuz ki bulunacak sonuçların herhangi bir anlamı kalmayacaktır.

1.3.2. Veri Ön Hazırlığı

Günümüz veri tabanları yüksek derecede gürültüye duyarlı, kayıp ve yüksek boyutlarına bağlı olarak tutarsızdır ve kaynakları çoğul ve heterojendir. Düşük kaliteli veri bizi düşük kaliteli bir veri madenciliğine yönlendirecektir. Bunun sonucunda verinin ve veri madenciliğinin kalitesini arttırmak için veriyi kullanmadan önce ne tür ön hazırlıklar yapabiliriz sorusu ortaya çıkmıştır. Veri hazırlama ve işleme aşaması veri madenciliğinin %80'ini oluşturmaktadır.

Birden çok veri hazırlama tekniği bulunmaktadır. Bunların belli başlıları; veri temizleme, veri ilişkilendirme, veri dönüştürme ve sadeleştirme dir.

Veri ön hazırlığı şu aşamaları içerir:

- Veri Temizleme (Data Cleaning): Gürültüyü ve gereksiz bilgiyi temizler
- Veri Entegrasyonu (Data Integration): Birden fazla kaynaktan yer alan veriler birleştirilir.

Not: Bu iki aşama ön hazırlık aşaması olarak geçer. Sonuç olarak ortaya çıkan veri; veri ambarlarında saklanır.

- Veri Seçimi (Data Selection): Veri Ambarlarından verilen görevle alakalı olarak verinin seçilmesi.
- Veri Dönüşümü (Data Transformation): Verilerin form verileri haline dönüştürülmesi ve madencilğe uygun hale getirilmesi. (Örn: Dönem verilerinin toplanması)
- Veri İndirgeme (Data Reduction): Verilerin boyutlarının ve karmaşıklığının azaltılması için gerekli yöntemlerin uygulandığı aşama.
- Ayırıklaştırma ve Konsept Hiyerarşisi Oluşturma (Data Discretization and Concept Hierarchy Generation): Veri ayırıklaştırma teknikleri devamlı özellik taşıyan sayısal niteliklerin belirli aralıklarla kesilmesi ile kesikli hale getirilmesini sağlar. Konsept hiyerarşi ise bu değerleri belirli bir hiyerarşi içerisinde düzenler. (Han, Kamber, 2006: 86 – 87)

1.3.2.1. Veri Temizleme

Veri toplamanın ve analiz etmenin yanında veri kalitesi, her aşamada hissedilen dikenli bir yol olarak bütün büyük organizasyonların karşısında durmaktadır. Yanlış ya da alakasız verinin varlığı analiz sonuçlarını önemli derecede çarpıtmaktadır ve genellikle potansiyel kazançların üstünü örtmektedir. Bunun sonucunda geçtiğimiz yıllarda veri temizleme üzerinde çeşitli araştırmalar yapılmış ve otomatik ve yarı otomatik birçok sistem geliştirilmiştir. Bu sistemler hataları tespit edip düzeltmeye çalışmaktadır (Hellersitein, 2008: 1).

Veri temizleme gürültülü ve gereksiz bilgiyi temizlemek üzere oluşturulmuş süreçtir. Veri temizleme verinin kalitesini arttırmak için verideki gereksiz ve hatalı kısımları belirleyerek yok etmeye çalışır (Rahm, Do, 2000: 3). Veri temizleme sürecinde en önemli iki aşama kayıp veriler ve gürültülü verilerdir.

1.3.2.1.1. Kayıp Değerler

Veri kalitesindeki önemli problemlerden birisi de kayıp verilerdir (Batista, Monard, 2003: 519). Kayıp değerlerin birden fazla nedeni olabilir. Bunlar; ekipman arızaları, diğer kaydedilen verilerde bulunan tutarsızlıklar, yanlış anlaşılardan dolayı veri girilememesi, belirli verilerin önemli olarak görülmemesi ve bu nedenle gerekli özenin gösterilmemesi ve geçmişin ya da verideki değişikliklerin girilmemesi olarak gösterilebilir.

Kayıp değerlerin giderilmeye çalışılması madencilik süreci üzerinde zaman harcanan aşamalardan biri olduğundan, çalışmadan elde edilecek verimi azaltır. Kayıp değerler üzerinde sonraki süreçlerde çalışma yapılması çok zor olacağından, veri ön hazırlığı sürecinde yapılmalıdır. (Kaiser, 2014: 42).

Kayıp verilerle baş edebilmek için; kayıp değerlerin olduğu satırları silme (case deletion), bilinen bütün değerlerin ortalamasını kullanarak kayıp değerleri doldurma (mean imputation), orta sayı (median imputation) ve K en yakın komşu metodu (KNN) kullanılarak kayıp değerleri doldurma yöntemleri kullanılabilir (Acuna, Rodriguez, 2004: 640 – 641).

1.3.2.1.2. Gürültülü Veri

Gürültü; ölçülen değerlerde yer alan rastgele hata ya da varyans değerlerdir (Han, Kamber, 2006: 62). Gürültü uygulanmak istenen veri madenciliği görevi üzerinde olumsuz etkide bulunabilir. Gürültülü veri gerek duyulan depolama hafızasını artırır ve veri madenciliği analizini olumsuz olarak etkiler. Ayrıca donanım aksaklıklarını, programlama hatalarını, beraberinde getirebilir (Sunithaa, Rujua, Srinivasa, 2013: 575). Veri madenciliği sürecinin gerektirdiği süreyi kayda değer bir biçimde arttıracak gibi çıkan sonuçlar üzerindeki etkisi ile tatmin edici olmayabilir.

Veri üzerindeki gürültü elle inceleme ve silme, kutulama (gruplama), regresyon ve kümeleme yöntemleri ile giderilebilir.

- **Elle İnceleme ve Silme;**

Gürültülü veride tipik veri hataları kısaltmaların yanlış kullanılmasından, veri giriş hatalarından, aynı kaydın birden fazla defa kaydedilmesinden (duplicate records), kayıp değerlerden, söylenen verilerin yazım ortamına geçirilirken oluşan hatalardan, süresi dolmuş kayıtlardan, form veride zorunlu olarak girilmesi gereken; fakat uygun olmayan veriler yerine rastgele bir değer ya da evrensel bir sabit girilmesinden vs. oluşur.

Oluşan bu aykırılıklar ve aksaklıklar tespit edilerek silinmelidir. Fakat bu işlemler çok fazla zaman almakta ve veri madenciliği sürecine geçişi kayda değer bir biçimde yavaşlatmaktadır.

İstatistikçiler genellikle veriyi analiz ederken şüpheli işlemleri hem kabul eden hem de reddeden yaklaşımların her ikisini de inceledikleri için yapılacak daha az iş vardır. Eğer sonuçlar arasında çok küçük farklılıklar varsa aykırı değerlerin de az olduğu

söylenbilir. Eğer bu etki büyükse bir alternatif bulunması gerekir (Sunithaa, Rujua, Srinivasa, 2013: 575).

- **Kutulama;**

Kutulama; sürekli değerleri (continuous-valued) daha önceden belirlenmiş kutu sayısı ile ayrıklaştıran en basit yöntemdir (Liu ve diğerleri, 2002: 401). Birden çok ayrıklaştırma ya da kesikli hale getirme yaklaşımı mevcuttur. Bunlardan en çok kullanılanları eşit-genişlik ve eşit-frekans olmak üzere ikiye ayrılmıştır (Moreno ve diğerleri, 2007: 224).

Eşit-genişlik ve eşit-frekans yöntemleri; belirli aralık sayısı ile birlikte veriyi aynı boyutta ya da aynı sayıda kayıt ile gruplara ayırmaya çalışır. Diğer metodlar ise daha çok sınıflandırma sorunlarında kullanılırlar (Moreno ve diğerleri, 2007: 224).

Bu metot çevre değerlerin komşuluk ilişkileri ile kutulanması şeklindedir. Alınan değerler öncelikle sıralanır. Sıralanan bu değerler kutular ya da buketler halinde sınıflandırılır. Kutulandırma metodu komşu değerleri kapsadığı için sadece yerel bir pürüzsüzleştirme sağlar. Diğer kutulandırma metotları üç şekilde uygulanır. Bunlar eşit frekanslara ayırma, kutuları ortalama ile pürüzsüzleştirme, kutu sınırları ile pürüzsüzleştirme.

Bu yöntemleri bir örnek üzerinde açıklayacak olursak; elimizdeki veri değerlerinin parasal değerlerinin, 4, 8, 15, 21, 21, 24, 25, 28, 34 olduğunu varsayalım.

a- Eşit Frekanslara Ayırma

Tablo 1'deki gibi veriler eşit sayıda kutular içerisinde dağıtılır.

Tablo 1. Eşit Frekanslara Ayırma

Kutu 1:	4, 8, 15
Kutu 2:	21, 21, 24
Kutu 3:	25, 28, 34

b- Kutuları Ortalama İle Pürüzsüzleştirme

Tablo 2'deki gibi bu yöntem ile kutulara yerleştirilen değerlerin ortalamaları alınarak kutuya yazılır.

Tablo 2. Ortalama İle Pürüzsüzleştirme

Kutu 1:	9, 9, 9
---------	---------

Kutu 2:	22, 22, 22
Kutu 3:	29, 29, 29

c- Kutu Sınırları İle Pürüzsüzleştirme

Tablo 3'teki gibi kutu içerisinde yer alan gürültülü değerler kutu sınırı ile değiştirilir.

Tablo 3. Kutu Sınırları İle Pürüzsüzleştirme

Kutu 1:	4, 4, 15
Kutu 2:	21, 21, 24
Kutu 3:	25, 25, 34

- **Regresyon**

Veri, regresyon analizinde olduğu gibi belirli bir fonksiyon ile pürüzsüzleştirilebilir. Doğrusal regresyon en iyi satırı bularak iki veya daha fazla değeri birbiri ile ilişkilendirir. Böylece değerlerden birisi ile diğeri tahmin edilebilir. Birden çok doğrusal regresyon ise doğrusal regresyonun geliştirilmiş halidir. Bunda ise ikiden fazla niteliği içererek çok boyutlu bir yapı oluşturur (Han, Kamber, 2006: 63).

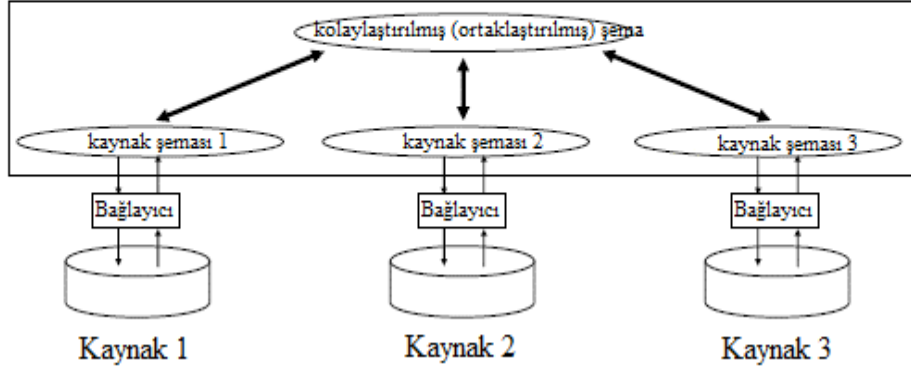
- **Kümeleme**

Aykırı değerler kümeleme yöntemleri ile tespit edilebilir. Birbirine benzer ve yakın değerler kümelerine ayrılarak; bu kümelerin dışında kalan değerler aykırı değer olarak değerlendirilir (Han, Kamber, 2006: 64). Özellikle k anlamlı kümeleme (k-means clustering) kullanılarak küme sayısının belirlenmesi ile aykırı değerleri belirlemek daha kolay olur.

1.3.2.2. Veri Entegrasyonu

Veri analiz tekniğinin veri entegrasyonu gerektirmesi gayet doğaldır. Çünkü veri entegrasyonu birden fazla kaynaktan yer alan, tutarlı hale getirerek veri deposunda ve veri ambarlarında yer alan verileri birleştirerek bir araya getirir. (Han, Kamber, 2006, p.67) Bir başka deyişle veri entegrasyon sistemleri; farklı kaynaklarda yer alan veriyi birleştiren ve kullanıcıya birleşmiş bir şekilde gösteren sistemlerdir. Bu birleşik gösterim global bir şema olarak temsil edilir ve tüm verinin birbiri ile bağdaştırılmış halini sunarak kullanıcı tarafından sorgulanabilir hale getirir (Lenzerini, 2002: 234). Veri entegrasyonundaki

amaç kaynak veriler arasındaki heterojenliği en aza indirip birleştirerek homojen bir yapı oluşturup verinin incelenmesini kolaylaştırmaktır.



Şekil 2. Veri Entegrasyon Yapısı (Doan, McCann, 2003: 1)

Veri entegrasyonu için kaynak ve hedef veri arasında doğabilecek hataları en aza indirebilmek ve entegrasyonu başarı ile tamamlayabilmek için kaynak ve hedef veriler arasında global bir şema kurarak haritalandırmak gerekir (Bkz: Şekil 2).

Genel olarak haritalandırma sistemleri yapay zekâ kullanır. Otomatikleştirilmiş şema haritalandırma sistemleri ilk olarak; veriler arasındaki ipuçlarını tespit etmeye çalışır. Bu ipuçlarından (şema elemanları arasındaki dilsel benzeşmeler, veri değerleri veya sütunlarda yer alan veri türleri) faydalanarak ikinci olarak; gözlemlere dayanarak haritalandırmayı gerçekleştirir (Halevy ve diğerleri, 2006: 10).

Veri entegrasyonu sürecinde ortaya çıkan sorunlar; düzen entegrasyonu ve obje eşleştirmedir. Birden çok veri tabanında yer alan bilgilerin birbiriyle uyum sağlayabilmesi için bu verilerin birbirleriyle eş değer olması gerekir. Buda obje tanımlama problemini ortaya çıkarır. Örnek olarak bir veri tabanında müşteri_adi olarak geçen dizi adı bir başka veri tabanında müşteri_numarasi olarak geçebilir. Bunlar aynı niteliği ifade edebilirler. Buda düzen entegrasyonunda hatalara yol açar.

Fazlalık ise diğer önemli bir sorundur. Bir nitelik bir başka nitelikten türetilmişse bunlar fazlalık oluşturabilirler. Bazı fazlalıklar korelasyon analizleri ile tespit edilerek giderilebilirler.

1.3.2.3. Veri Seçimi

Analiz için gerekli olan verinin seçildiği aşamadır (Zaiane O. R., 1999: 4). Veri seçimi analizin sonucunu doğrudan etkileyen ve analiz üzerindeki en büyük etkiye sahip

aşamadır. Veri seçimi problem tanımı yapılırken ortaya çıkan gereklilikler üzerine yapılır. Veri seçiminin etkili bir biçimde gerçekleştirilmesi analiz yapılırken oluşabilecek olan hataları ve analiz süresini kısaltır.

1.3.2.4. Veri Dönüştürme

Dönüştürme aşamasında veriler madenciliğe uygun olacak şekilde form verilerine dönüştürülürler. Veri dönüştürme pürüzsüzleştirme, birleştirme, genelleştirme, normalleştirme ve nitelik yapılandırma yöntemlerinden oluşur.

- **Pürüzsüzleştirme;**

Veriden gürültünün çıkarılmasına dayanır. Kutulama, regresyon ve kümeleme metotlarını içerir.

- **Birleştirme;**

Toplama veya birleştirme işlemlerinin veriye uygulanmasıdır. Bu metot ile günlük satışların toplanması ile aylık toplam miktarlar elde edilebilir.

- **Genelleştirme;**

Düşük seviyeli ya da ilkel verinin yüksek seviyeli konsept hiyerarşiler kullanılarak değiştirilmesidir. Örnek olarak yaş değişkeni daha yüksek bir hiyerarşi içerisinde gençlik, orta yaş veya yaşlı olarak ayrılabilir (Han, Kamber, 2006: 70-71).

- **Normalleştirme;**

Ölçülen nitelik değerlerin belirlenen küçük bir aralık içerisine çekilmesidir. Örnek olarak 0.0-1.0 gibi.

- **Nitelik Yapılandırma;**

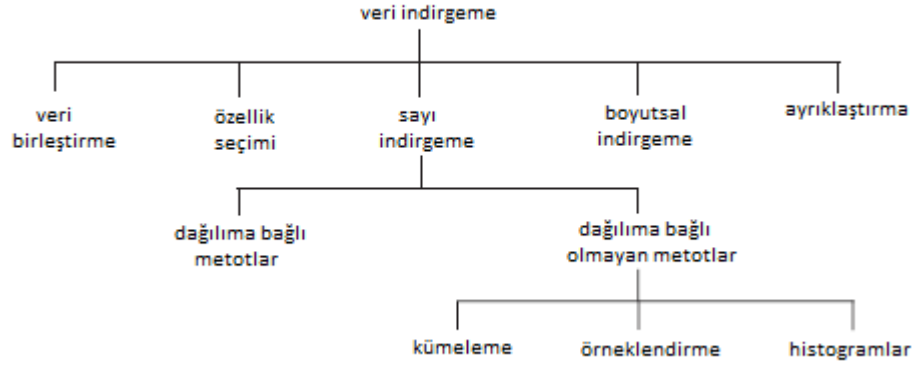
Madencilik işleminin gerçekleştirilmesine yardımcı olabilmek için yeni niteliklerin yapılandırıldığı ve eklendiği süreçtir.

1.3.2.5. Veri İndirgeme

Veri indirgeme teknikleri; büyük veri tabanlarında saklanan bilginin birleştirilip kaynaştırılarak kullanışlı, daha küçük bilgi külçeleri haline getirmek için uygulanır (Agarwal, Rao, 2014: 1). Kullanıcılar genellikle çok büyük veri ile adeta boğulmuş olur ve bu veriyi yorumlayabilmek için çok kısa bir vakte sahiptirler. Problemin çözümünü bulmak zamansal bir meseledir (Bingham ve diğerleri, 1995: 1). Çünkü yapılacak olan bu inceleme süresince mevcut veri tabanına sürekli yeni veriler ekleniyor olacaktır ve analiz sonuçlarını etkileyebilecek birçok veri de bu verilerin içinde yer alabilir. Dolayısı

ile oluşturulacak sistemin en kısa sürede hazırlanabilmesi ve incelenebilmesi gerekmektedir. Bir şirketin verilerini incelediğimizi düşünecek olursak şirketin veri ambarındaki bilgilerin çok fazla olduğu hemen dikkatimizi çekecektir. Karmaşık veri analizleri ve bu kadar büyük veri içerisinde yapılacak olan veri madenciliği uygulaması çok uzun sürecektir ve bu da analizin kullanışsız veya olanaksız olduğunu ortaya çıkaracaktır.


Veri indirgeme teknikleri daha küçük boyutlu veri setlerini ortaya çıkarırken, orijinal veri entegrasyonunu sağlamaya çalışır. İndirgenmiş bu veri setleri daha etkili, aynı veya neredeyse aynı analitik sonuçları verir. Veri indirgeme stratejileri; veri küpü toplama (veri toplama –data aggregation-), nitelik alt kümesi seçimi, boyutsal indirgeme ve sayısal indirgeme olmak üzere sınıflandırılır. (Bkz: Şekil 3)



Şekil 3. Veri İndirgeme Teknikleri (Kalegele ve diğerleri, 2011: 2)

- **Veri Küpü Toplama;**

Veri analiz uygulamaları tipik olarak farklı boyutlarda yer alan verileri bir araya toplayarak olağandışı ilişkileri bulmaya çalışır. Bunlar veri değerlerini toplar, istatistiksel veriyi çıkarıp, bir kategoriye bir diğer kategori ile kıyaslar (Gray ve diğerleri, 1997: 29). Geniş veri tabanları üzerindeki karmaşık girdiler içeren bu uygulamalar; yanıt sürelerinin kısa olması gerektiğinden girdi optimizasyonu kritik bir öneme sahiptir. Kullanıcılar tipik olarak verileri çok boyutlu veri küpleri olarak görürler. Veri küpünün her hücresi önem taşıyan bir alanın verilerinin toplanması ile oluşur (Harinarayan ve diğerleri, 1996: 205).



Şekil 4. Veri Küpü Örneği (Urbanek, 2016, p.4)

Veri küpleri girdileri filtrelemek, verilerin toplanma kapsamını kontrol etmek, sipariş ve sıralama için kullanmak ve ilişkileri en iyi şekilde açıklamak için kullanılırlar. Veri küpleri bir bakıma zekâ küplerine benzer, zekâ küplerinde olduğu gibi her yüzeyi ayrı bir özelliği (rengi) temsil ederek bu yüzlerin birbirini ile olan ilişkileri gösterilmeye çalışılır (Bkz: Şekil 4).

- **Nitelik Alt Kümesi Seçimi;**

Nitelik alt kümesi seçimi sadece daha hızlı model oluşturmayı ve özellik sayısını azaltmayı değil de ayrıca; gereksiz, alakasız ve gürültülü nitelikleri de azaltarak daha basit ve daha anlaşılabilir sınıflandırma modelleri ve daha iyi sınıflandırma performansı sağlar (Singhi, Liu, 2006: 849).

- **Boyutsal İndirgeme;**

Boyutsal indirgeme; veriyi haritalandırarak daha az boyutlu bir hale getirmek suretiyle, bilgilendirici olmayan verinin bu veri setinden ayrılması ile bir alt uzay oluşturulmasıdır (Borges, 2010: 276).

- **Sayısal İndirgeme;**

Sayısal indirgeme; orijinal veriyi alternatif veri gösterimleri ile değiştirir (Kadam, Thakore, 2012: 906). Sayısal indirgeme iki sebepten yapılır. Bunlar; depolamadan kazanmak ve masrafları azaltmaktır (işlemci gibi). Bir diğeri ise veri ön hazırlığı olarak verideki gürültüyü gidermektir (Kalegele ve diğerleri, 2011: 2). Sayısal indirgeme; veriyi

alternatif, daha küçük gösterimlerle parametrik model olarak deęiřtirir, bunlar veri yerine sadece parametreleri depolar. Örnek olarak regresyon ve logaritmik doğrusal fonksiyon modelleri ya da parametrik olmayan kümeleme, örneklendirme (sampling), histogram grafikleri (çubuk grafikleri) kullanır.

Kümelemede veriler, objeler olarak sınıflandırılarak daha az yer kaplanması sağlanır. Örneklendirmede ise örnekler gruplara ayrılarak (genç, orta yaş, yaşlı gibi) tek tek deęerler yerine bu grup deęerleri girilir. Histogramlarda ise aynı deęerler çubuk grafikler üzerinde gösterilir.

1.3.2.6. Ayrıklaştırma ve Konsept Hiyerarřisi Oluřturma

Ayrıklaştırma teknikleri deęerler sayısını azaltmak için sürekli deęiřkenleri belirli aralıklara ayırarak kesikli hale getirir. Konsept hiyerarři ise verilen sayısal deęiřkenleri bir hiyerarři arasında parçalayarak; alt seviye konseptlerde gösterir. Örneęin üst seviye bir konseptte genç, orta yaşlı, yaşlı olarak ayrılırken alt seviyede, yaş gruplarına göre ayrılabilir (Murty, 2016: 3).

1.3.3. Veri Keřfi (Data Exploration)

Veri keřfi; veriden bilgi çıkarma işlemidir. Bunun için neyi aradıęımızı bilmemize gerek yoktur (Idreos ve dięerleri, 2015: 277). Veri keřfi veri setleri içerisine yapılan derinlemesine incelemedir. Bu işlem yapılırken hatalardan kaçınmak için dikkatli ve organize olmak gerekir. (Meals ve Dressing, 2005: 2). Veriler genellikle tablolar ve grafikler řeklinde gösterilir. Bu tablolar ve grafiklere bakarak veri keřfi yapılabilir; fakat bu hem çok uzun sürecektir hem de etkili olmayacaktır. Veri keřfi araçları bu iři insan gibi gerçekleřtirmeye çalıřır. Fakat ilginç olan veya olmayan tüm kombinasyonları tarar. Etkili bir veri keřfi için insanın makine ile ortak çalıřması gereklidir.

Veri keřfini geçmiři açıklama bařlığı altında açıklayabiliriz.

1.3.3.1. Geçmiři Açıklamak

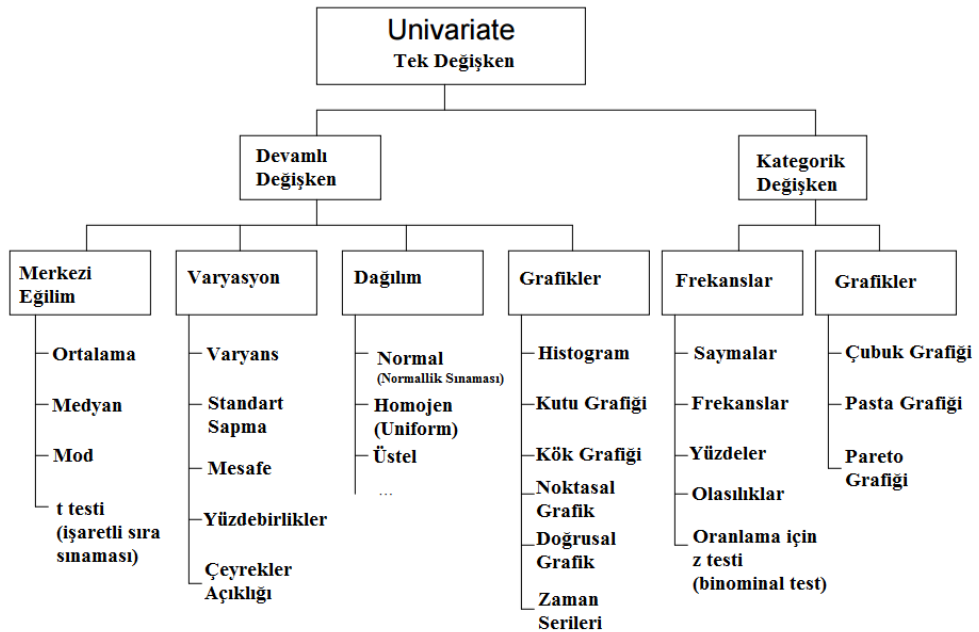
Veri madencilięi; řekil 1'de gösterildięi üzere iki bölümde deęerlendirilir. Veri madencilięinin ilk ařaması olan geçmiři açıklama konusunu bir nevi tarih dersi gibi deęerlendirebiliriz. Tarih dersinde ya da günlük yařantımızda da söylenegeldięi üzere geçmiřini bilmeyen insanların geleceęe dair olan tahminleri hatalarla dolu olacaktır. Tecrübesiz veya geçmiřte yařadıklarından ders çıkarmayan bir insanın gelecekte yapmayı planladıęı eylemlerin sonuçlarının tahmin ettięi gibi çıkması pek mümkün olmayacaktır.

Veri madenciliği sürecini de bir insanın hayatı gibi ikiye ayırabiliriz. Bunlar geçmiş açıklamak ve geleceği tahmin etmektir. Veri madenciliği işi ile uğraşan analistler öncelikle geçmişteki verileri ele alıp bunlar üzerinde model oluşturmalıdır. Bu modeller üzerinde yapılan testler ile hangi modelin daha uygun olduğu belirlenmelidir. Elde edilen sonuçlar ile yapay tahminler yaratılmalı ve bu tahminlerin sonuçları karşılaştırılmalıdır. Elde edilen tahminler gerekli şartları sağlıyor ve veri madenciliğinin amacına uygun olarak daha önceden ortaya çıkmamış bağlantıları ve fırsatları tanımlayabiliyorsa ve doğruluk oranları yüksek ise model başarılı olmuş denilebilir. Bu aşamadan sonra ise modelin gelecek için öngördüğü veriler üzerinden tahminler yapılır.

Geçmiş açıklamak keşif ile mümkündür. Veri keşfi verinin istatistiksel ya da görsel olarak incelenmesi ile daha ileri analizlere hazırlanması anlamına gelmektedir. Veri keşfi tek değişkenli ve iki değişkenli olmak üzere ikiye ayrılır.

1.3.3.1.1. Tek Değişkenli Keşif

Tek değişkenli veri keşfi; her seferinde verinin bir özelliğini inceler. Bu değişkenler kategorik veya nümerik olabilirler. Nümerik değerler kutulama yöntemi ile kategorik hale dönüştürülebilir. Tek değişkenli keşfin türleri Şekil 5'te gösterilmiştir.




Şekil 5. Tek Değişkenli Keşif Türleri (Online:

[https://www.researchgate.net/file.PostFileLoader.html?id=567002b35f7f7176358b4585&assetKey=AS%3A306896769093632%401450181299197 2016: p.2\)](https://www.researchgate.net/file.PostFileLoader.html?id=567002b35f7f7176358b4585&assetKey=AS%3A306896769093632%401450181299197%2016%3A2)

- **Kategorik deęişkenler;**

Kategorik ya da ayrıklı deęişkenler bir veya birden fazla kategoriye sahiptirler. İki farklı kategorik deęişken türü vardır. Bunlar nominal ve ordinal olmak üzere ikiye ayrılır. Örnek olarak müzik türü bir nominal deęerdir. Herhangi bir müzik listelenmiş türler arasında yer alabilir. Var olan müzik jazz, rock, hip-hop gibi müzik türlerinin herhangi birisi içerisinde olabilir. Fakat müzik türlerinin birbiri arasındaki üstünlüğü söz konusu değildir. Yani rock müzik türünün jazz müzik türüne göre üstünlüğü yoktur. Bu veriler sınıflandırıcı ölçekte ölçülmüş verilerdir. Ordinal kategorik deęişkenler ise sıralayıcı ölçekte ölçülmüş verilerden oluşur. Bu deęişkenlerde bir sıralama, yani deęişkenler arasında bir üstünlük söz konusudur. Uzun-kısa veya yaşlı-genç şeklinde kategorileri içeren deęişkenler ordinal deęişkenlere örnek olarak gösterilebilir. Ordinal kategorik deęer yine listelenmiş türler arasında gerçekleştirilir. Fakat veri setleri dizilmiştir (Seo, Gordish-Dressman, 2007: 12 – 13). Frekans tablosu ise kategorik verilerin ne kadar sıklıkla kullanıldıklarını göstermek için kullanılırlar.



Şekil 6. Frekans Tablosu (Sayad, 2016: 1)

Sınıflayıcı ve sıralayıcı ölçek ile elde edilen veriler numerik (evli=0, bekar=1 gibi) hale getirilebilir. Ancak bu rakamların matematiksel bir anlamı olmadığı için toplama, çıkarma gibi matematiksel işlemler gerçekleştirilemez. Bu nedenle kategorik veriler iki şekilde değerlendirilebilirler; bunlardan birincisi deęişkende yer alan kategorilerin

frekansları (tekrar/sıklık sayıları) ve bu sayıların yüzdelik değerleridir. İkinci yöntem ise birinci yöntemde elde edilen frekans sayılarının histogram grafikleriyle; frekans yüzdelilerinin iste pasta grafiğiyle gösterilmesidir (Bkz: Şekil 6).

- **Devamlı (Sürekli) Değişkenler;**

Devamlı (sürekli) ya da nümerik değişkenler; sonlu ya da sonsuz aralıkta yer alan kesiksiz ya da sürekli değişkenler bütünüdür. Eşit aralıklı ölçek ve oranlı ölçek ile toplanan iki tür nümerik değişken vardır. Bunlardan birincisi; aralık (interval), diğeri ise oran (ratio)dır. Aralık değerini içeren setler yorumlanabilirler; fakat gerçek bir sifıra sahip değildirler. Aralık halindeki veriler toplanıp çıkarılabilirler; fakat anlamlı bir şekilde çarpılamaz veya bölünemezler. Örnek olarak hava sıcaklık değerini ele aldığımızda hava sıcaklığının bir önceki günün iki katı sıcak olduğunu söyleyemeyiz. Oran değerleri ise gerçek bir sifıra sahiptir ve toplanıp çıkarılabilir, çarpılıp bölünebilirler; örnek ağırlık. Nümerik değişkenlerin analizinde kullanılan yöntemler dört ayrı ana başlık altında toplanır. Bunlar:

- Merkezi Eğilim: Min, max, ortalama, medyan, mod, t testi (işaretili sıra sınaması-sign rank test)
- Varyasyon: Mesafe, nicelikler, varyans, standart sapma, varyans katsayısı, yüzdebirlikler (percentiles), çeyrekler açıklığı (interquartile range)
- Dağılış: çarpıklık, savrukluuk, normal, homojen (uniform), üstel (exponential)
- Grafikler: çubuk grafiği, kutu grafikleri, kök grafiği (stem plot), noktasal grafik (dot plot), doğrusal grafik (line chart), zaman serileri grafikleridir. (time series plot)

Ayrıca nümerik verileri kategorik verilere dönüştürmek için kutulama yöntemleri ve kategorik verileri de nümerik verilere dönüştürmek için kodlama yöntemleri kullanılır. Kutulama metodu daha önceki konuda ayrıntılı olarak açıklanmıştır.

Kodlama yöntemi ise analog sinyallerin dijitale dönüştürülmesi işlemidir. Alınan analog sinyallerde elektrik yükü ikili sistem üzerinden değerlendirilir. Elektrik yükü var ise kodlamada “1” sinyal yok ise kodlamada “0” olarak değerlendirilir.

1.3.3.1.2. İki Değişkenli Keşif

İki değişkenli analiz bir değişkenin bir başka değişken ile ilişkisinin araştırıldığı analiz tekniğidir. Bu araştırma sonucunda elde edilen sonuçlar karşılaştırılarak aralarında

ilişki var olup olmadığı, varsa eğer ilişkinin ne kadar güçlü olduğu tespit edilmeye çalışılır. (Sayad, 2016) İki değişkenli analizler;

- Kategorik – kategorik
- Sürekli (nümerik) – Kategorik
- Sürekli (nümerik) – Sürekli (nümerik)

Olmak üzere üçe ayrılırlar.


1.3.3.1.2.1. Kategorik – Kategorik Veri Keşfi

Kategorik verilerin karşılaştırılması adına üç metot uygulanmaktadır. Bunlar; yığılmış sütun grafik (stacked column chart), kombinasyon grafiği (combination chart) ve ki-kare testidir.

- **Yığılmış Sütun Grafik (Stacked Coloumn Chart);**

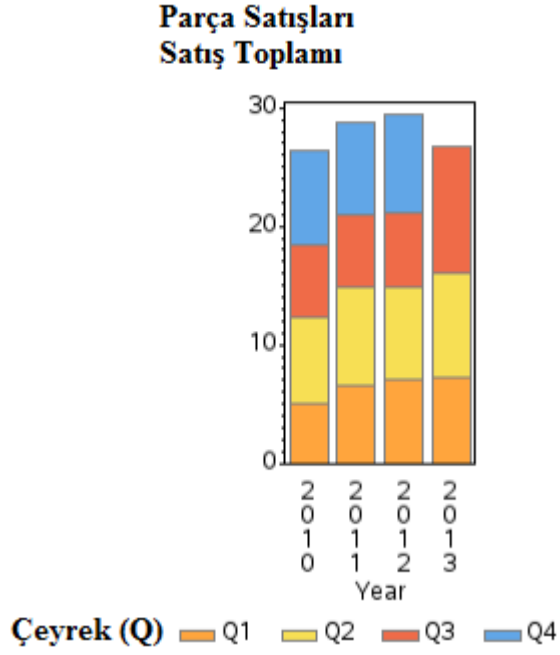
İki değişkenli karşılaştırmalarda basit çubuk grafiklerin yetersiz kalacağı hatta görsel olarak yanlış yönlendirebileceği durumlar ortaya çıkabilir (Allison, 2012: 23). Bu gibi durumlarda yığılmış sütun grafikleri kullanılır. Bu grafiklerde birden fazla değişken aynı anda gösterilebilir.

Parça Satışları 2013 3. Çeyrek Satış Toplamı



Şekil 7. Normal Çubuk Grafik (Allison 2012: 24)

Şekil 7’de görüldüğü üzere 2013 ün üçüncü çeyreğinde yapılan satışlar sadece bir değişkene bağlı olarak gösterilmiştir.




Şekil 8. Yığılmış Çubuk Grafiği (Allison 2012: 24)

Şekil 8’de görüldüğü üzere yine satış rakamları gösterilmiş; fakat çeyrek verilerinin tamamı tek grafikte gösterilmiştir. Şekil 10’da gösterildiği şekilde gösterilmeye çalışılırdı dört ayrı grafik oluşturulacak; hem çok fazla yer kaplayacak hem de karşılaştırma açısından eksiklikler meydana gelecek ve bu grafiklerin birbiri ile karşılaştırılması zaman alacaktı. Fakat yığılmış çubuk grafiği bu karmaşayı ve zaman kaybını ortadan kaldırmıştır.

- **Kombinasyon Grafiği (Combination Chart);**

Kombinasyon grafiği; grafiğin farklı türlerde veri içerdiğini göstermek için birden fazla yöntemin kullanılması ile oluşturulur (Sayad, 2016). Bu şekilde birden fazla yöntem kullanılırken bu farklılıkların ön plana çıkarılması için grafik üzerinde farklı grafik türleri kullanılabilir.

Dünya GSMH'sının Zaman İçerisinde Değişimi



Şekil 9. Kombinasyon Grafiği (Hardin ve Diğerleri, 2016: 23)

Şekil 9’da çubuk grafiklerin kombinasyonu ile bir kombinasyon grafiği oluşturulmuştur. Kombinasyon grafikleri farklı veri türlerinin bir arada gösterilmesi açısından oldukça kullanışlıdır.

- **Chi-kare Testi;**

Chi kare analizi ilişkisel kuralların istatistiksel önemini tespit etmekte kullanılır (Alvarez, 2003: 1). Ayrıca chi kare testi kategorik veriler arasındaki ilişkiyi belirlemek için kullanılabilir (Sayad, 2006: 1).

Bu yöntem frekans tablosu içinde yer alan bir veya birden fazla kategoriler için; beklenen frekanslar (e) ve gözlemlenen frekanslar (n) arasındaki farklılık üzerine kurulur.


1.3.3.1.2.2. Nümerik (Sürekli) – Kategorik Veri Keşfi

Nümerik veriler ile kategorik verileri karşılaştırılmasında beş farklı yöntem uygulanır. Bunlar; hata çubuklu çizgi grafikleri, kombinasyon grafikleri, z-testi ve t-testi ve varyans analizi (ANOVA)dir.

- **Hata Çubuklu Çizgi Grafikleri;**

İstatistiksel verileri gösterirken hata oranlarını da beraberinde göstermek önemlidir (Shaw, Most, 1990: 1419). Karar vericiler grafikler üzerindeki hata paylarını görebilirse daha sağlıklı karar verebilirler. İstatistiksel hesaplamalar yapılırken;

değerler ile birlikte hata payları da bulunur. Çizgi grafiklerinin üzerinde hata oranına göre +/- yönde hata işaretleri konularak bu grafikler oluşturulur.

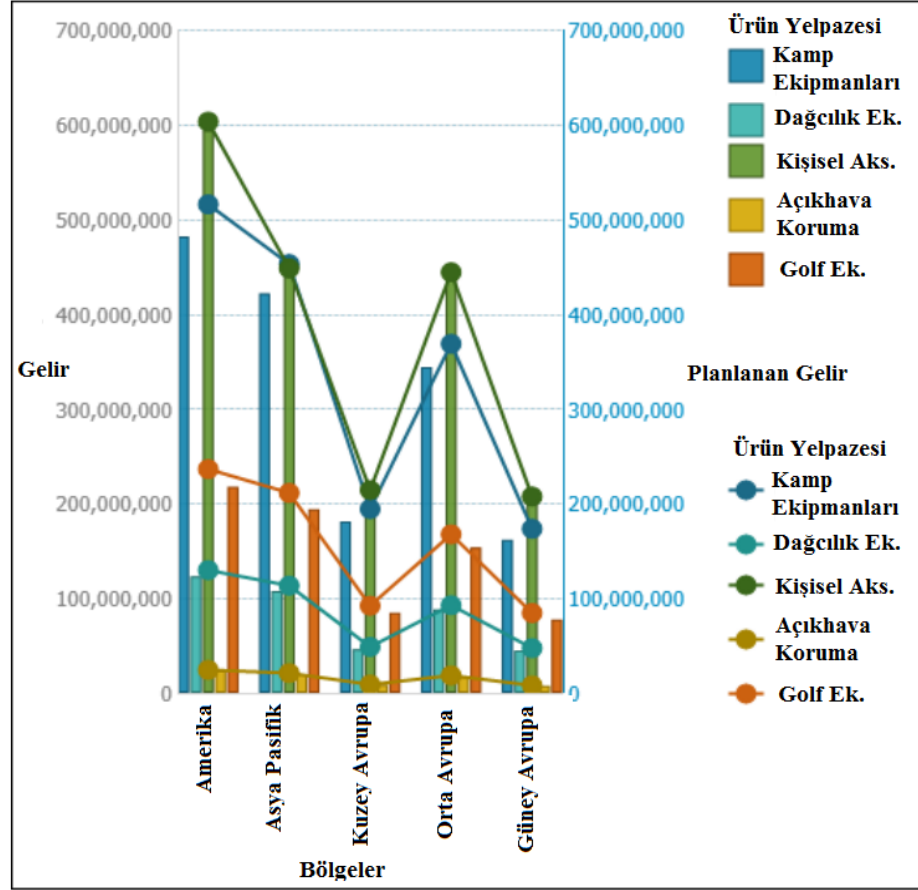


Şekil 10. Hata Çubuklu Çizgi Grafiği (Shaw, Most, 1990: 1421)

Şekil 10’da da görüldüğü gibi her değerle birlikte değer hesaplanmış olan hata payı da işleme konularak grafiğe yansıtılmıştır. Böylece karar verici alınabilecek olan sonucun maksimum ve minimum değerlerini görebilmekte ve buna göre karar verebilmektedir.

- **Kombinasyon Grafiği (Combination Chart);**

Daha önce de anlatıldığı üzere kombinasyon grafikleri farklı türlerdeki verileri birden fazla yöntem kullanarak gösterebilir. Dolayısı ile nümerik ve kategorik verileri de karşılaştırmak için kullanılabilir.



Şekil 11. Nümerik-Kategorik Veri Kombinasyon Grafiği (IBM, 2014: 6)

Şekil 11’de görüldüğü üzere kategorik veri olan bölgeler ile nümerik veri olan ürün satış rakamlarını bir arada gösteren bir kombinasyon grafiği oluşturulmuştur. Bu grafikte; çubuk grafik ve çizgi grafik beraber kullanılarak bir kombinasyon oluşturulmuştur.

- **Z-testi ve T-testi;**

Z testi ve T testi temelde birbirinin aynısıdır. İki grubun ortalamasının istatistiksel olarak birbirinden farklı olup olmadığını değerlendirirler.

- **Varyans Analizi (Analysis of Variance –ANOVA);**


Varyans iki veya daha fazla grubun ortalamasının istatistiksel olarak birbirinden farklı olup olmadığını değerlendirir. Her değişken ve seviye için elde edilen veri kombinasyonu varyans analizi ile incelenir (Penny ve diğerleri, 2007:166).

1.3.3.1.2.3.Nümerik (Sürekli) – Nümerik (Sürekli) Veri Keşfi

Nümerik verilerin birbiri ile karşılaştırılmasında iki farklı yöntem uygulanır. Bunlar; saçılım grafiği ve doğrusal korelasyon katsayısıdır.

- **Saçılım Grafiği (Scatter Plot);**

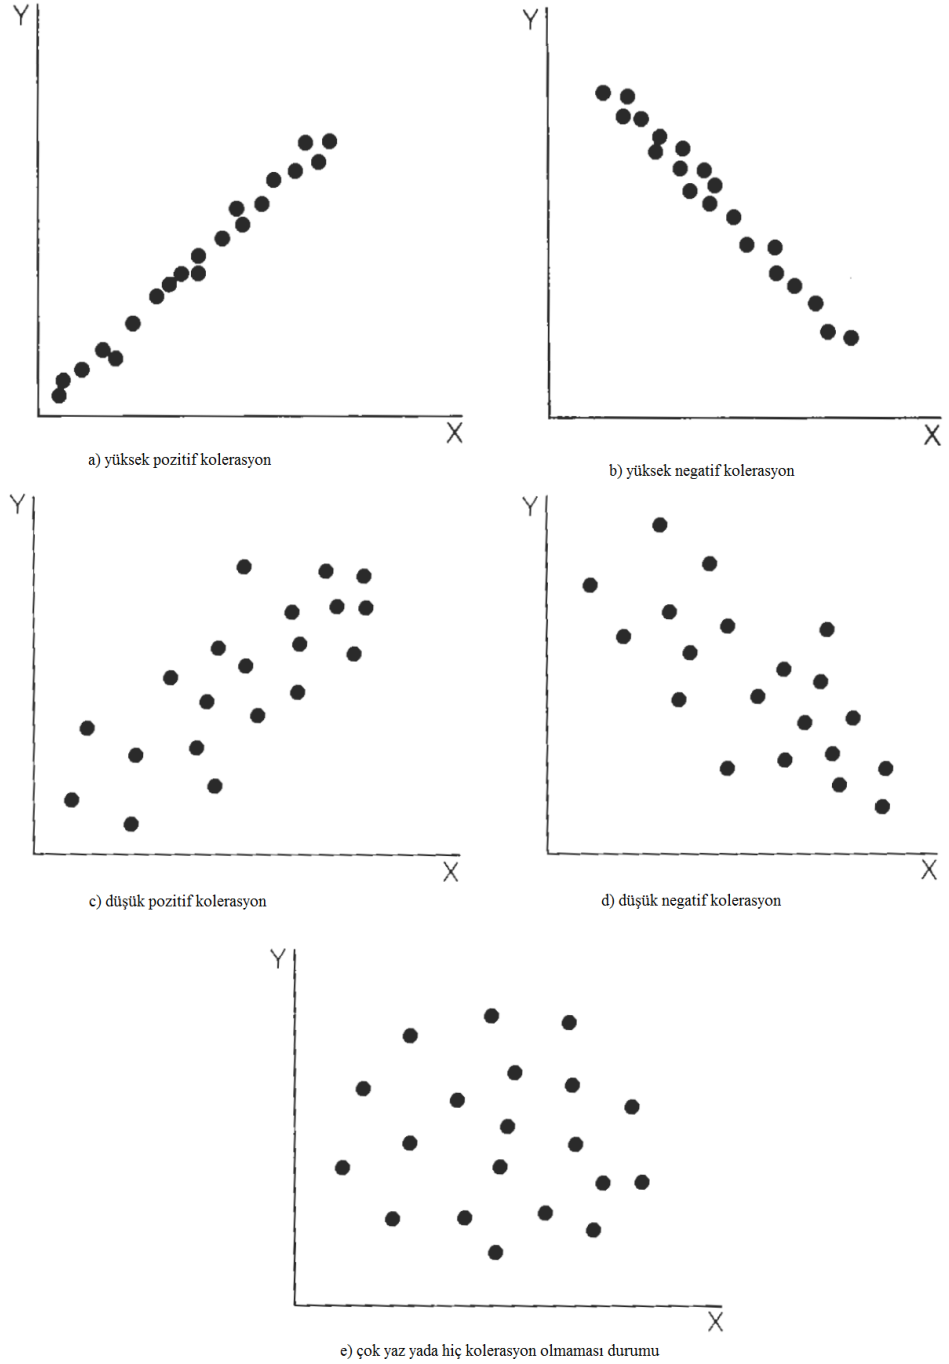
Gerçek anlamda ilk oluşturulan iki boyutlu grafik saçılım grafiğidir. Tüm istatistiksel grafikler arasında en çok yönlü, çok biçimli ve genellikle kullanışlı olan grafikdir (Friendly, Denis, 2005: 103). Bilimsel çalışmaların çoğunda saçılım grafiği kullanılmaktadır. Saçılım grafiği X düzlemi ile Y düzlemi üzerinde yer alan noktaları gösteren grafiklerdir (Bkz: Şekil 12).



Şekil 12. Saçılım Grafiği Örneği (Medeiros-Riberio ve diğerleri, 1998: 354)

- **Doğrusal Korelasyon (Linear Correlation);**

İki rastgele değişken arasındaki doğrusal ilişkiyi ölçer (Zou ve diğerleri, 2003: 618). Bu doğrusal ilişkiyi bulurken 1 ile -1 arasında ilişki değerler ortaya çıkar. İlişkisel değer "1" ise kusursuz bir pozitif doğrusal korelasyon elde edilirken; "-1" ile kusursuz bir negatif doğrusal korelasyon elde edilir (Bkz: Şekil 13).



Şekil 13. Doğrusal Korelasyon Örnekleri (Butler, 1985: 139,140)

1.3.4. Modelleme (Modeling)

Bir veri madenciliği modeli ilişkisel bir tablo olarak kabul edilir (Han, Kamber, 2006: 693). Veri madenciliğinin amacı ilişkisel tablolar olarak gösterilen bu modelleri işleyerek verinin bu modellere en uygun hale gelmesini sağlamaktır. Veri modele uygun hale gelince madencilik sürecinden geçirilir ve elde edilen sonuçların tutarlılığına göre modellerde değişiklikler uygulanır. Modellemede dikkat edilecek en önemli hususlardan

birisi ise madencilik işlemleri uygulanmadan önce verinin uygulanacak madencilik modeline olan uyumluluğudur. Eğer veri uygun olmayan madencilik tekniği ile çözümlenmeye çalışılırsa; doğruluk oranı çok düşük çıkacak ve yapılacak değişiklikler yanlış kararlar alınmasına sebep olacaktır.

1.3.5. Model Değerlendirme (Model Evaluation)

Değerlendirme; veri madenciliğinin anahtar noktalarından biridir. İki amaca hizmet etmektedir. Birincisi; modelin son halinin ne kadar iyi çalıştığı (ya da bu modelle çalışıp çalışılmayacağı), ikincisi ise öğrenme metodlarının bir parçası olarak çalışma verisini en iyi temsil edecek olan modeli bulmaktır (Souza ve diğerleri, 2002: 1). Model değerlendirme; model verisinin üçe parçalanması ile oluşur. İlk parça çalışma seti olarak adlandırılır. Bu set üzerinde model uygulanır. Genellikle veriyi temsil edecek küçük boyutlu bir örneği olarak kabul edilir. İkinci parça ise doğrulama setidir. Çalışma seti üzerinde yapılandırılan modeller doğrulama seti üzerinde uygulanarak tutarlılığı ve performansı kontrol edilir. En iyi performans elde edilinceye kadar doğrulama seti üzerinde çalışmalara devam edilir. Üçüncü ve son parça ise test setidir. Bu sette ilk iki sette olmayan farklı örnekler bulunur. Bu set üzerinde yapılan incelemeler modelin gelecekte göstereceği performans potansiyelini ortaya koyar.

1.3.6. Model Yerleştirme (Deployment)

Daha önceki süreçlerde elde edilen veriler ile ortaya çıkan nihai modelin yeni veri üzerine uygulanması aşamasıdır. Model yerleştirme, aktiviteleri ele alarak veri madenciliği modelinden elde edilen bilgiyi organize ederek sunulabilir hale dönüştürür (Rupnik, Jaklic, 2009: 375). Model yerleştirme sürecinin kullanıcı dostu olması gerekir. Elde edilen bilginin düzgün biçimde sunulabilmesi için bunların model aracılığıyla tablolara ve grafiklere aktarılması gerekir.

1.4. Veri Madenciliğinde Sık Kullanılan Yollar, Ortaklıklar ve Bağıntılar

1.4.1. Veri Madenciliğinde Sık Karşılaşılan Modeller

Kayıt setleri, alt diziler ya da alt yapılar veri dizilerinde en çok karşılaştığımızdır. Örnek olarak envanterimizde yer alan eşyalardan kalem ve kâğıt alışveriş listelerinde sürekli beraber yer alıyorsa bunlar sık kullanılan modellerdendir. Alt dizi olarak da ilk olarak bilgisayar alan birinin sonrasında hoparlör satın alması örnek olarak gösterilebilir. Alt yapılar ise kayıt setleri ile alt dizilerin birleşimi ile ortaya çıkar. Sık karşılaşılan bu yolları tespit etmek; ortaklıkları, bağıntılarını ve bilgiler arasındaki diğer ilginç ilişkileri

ortaya çıkarabilir. Aynı zamanda bu modeller sınıflandırma, kümeleme ve diğer veri madenciliği görevlerinde de yardımcı olur.

1.4.2. Basit Konseptler ve Yol Haritaları

Veri madenciliği; daha çok veri seti içerisinde tekrar eden ilişkileri arar. Aynı zamanda bu analizler müşterilerin alışveriş yapma alışkanlıklarını da tespit eder. Pazar sepeti analizi adı verilen bu analiz ile müşterilerin alışveriş verileri incelenir. Bu inceleme sonucunda reklam stratejileri, yeni katalogların dizaynında kullanılabilir. Bir başka strateji ise sıklıkla beraber satılan ürünler tespit edilerek, müşteriye birlikte satmaya çalışarak müşteriye cesaretlendirmektir. Örnek olarak bilgisayar satın almaya karar veren birisine anti virüs sisteminin belirli bir indirimle verilmesi bu kişiyi bilgisayar almak için belki %3'lere varan bir oranla cesaretlendirecek fakat bilgisayarı aldıktan sonra anti virüsü alması konusunda %50'lere varan düzeyde cesaretlendirecektir. Burada önemli olan verilen destek ve aşıladığı kendine güvendir.

Genel bakımdan ilişki bazlı madencilik iki aşamadan oluşmaktadır.

1. Tüm sıklıkla kullanılan kayıt setlerini bulmak,
2. Bulunan kayıt setleri arasında güçlü ilişkisel kurallar bulmaktır.

Pazar sepeti analizleri sık karşılaşılan model analizlerinden sadece biridir. Bununla birlikte farklı model analizleri, ilişki kuralları ve korelasyon ilişkileri bulunmaktadır. Sık karşılaşılan modeller şu kriterlere göre sınıflandırılır.

1.5. Geleceği Tahmin Etmek

Geçmiş açıklama konusunda gerek veri görselleştirmeleri ile gerekse verileri karşılaştırma ile karar vericilerin geçmişte alınabilecek kararları nasıl elde edebilecekleri konusunda fikir sahibi olmaları için yöntemler belirlenmiş ve uygulanmıştır.

Şimdi ise geçmişten elde edilen bu yöntemler ve tecrübeler ile asıl amacımız olan geleceği tahmin etme konusunda gerekli altyapıya sahip olunduğu söylenebilir.

Geleceği tahmin etme konusunda ise veri madenciliği teknikleri devreye girmektedir. Bunlar sınıflandırma, tahmin, regresyon, kümelene ve ilişkisel kurallar olmak üzere beş ana başlık altında toplanabilir.

Sınıflandırma konusu altında karar ağacı ile sınıflandırma, kural bazlı sınıflandırmalar, Bayes ağları, K en yakın komşu, yapay sinir ağları, destek vektör makinaları, kaba kümeler ve genetik algoritmalar yer almaktadır. Tahmin konusu altında performans tahmini değerlendirmesi yer alacaktır. Regresyon konusu altında regresyonda

alt küme seçimi ve regresyon ağaçları yer alacaktır. Ayrıca kümelenme, ilişkisel kurallar ve boyut azaltma teknikleri incelenecektir.

İKİNCİ BÖLÜM

2. VERİ MADENCİLİĞİ TEKNİKLERİ

Veri madenciliğinin ilk ve en önemli aşaması olan veri ön hazırlığı, veri madenciliği sürecinin %80'ini oluşturmaktadır. Bu süreç tamamlandıktan sonra veriden bilgi çıkarımı sürecine hazır hale gelir. Veri madenciliği teknikleri uygulanarak çıktıların kullanıcıların anlayabileceği şekilde sunulması gerekir. Bu bölümde veri madenciliği tekniklerinden olan; karar ağacı ile sınıflandırma, kural bazlı sınıflandırmalar, bayes ağları, k en yakın komşu, yapay sinir ağları, destek vektör makinaları, kaba kümeler, genetik algoritmalar, performans tahmini ve değerlendirme, regresyon, kümelendirme ve boyut azaltma teknikleri konularında bilgi verilmiştir.

2.1. Karar Ağacı İle Sınıflandırma

Karar ağaçları basit ama güçlü bir çoklu değişken analizidir (Deville, 2006: 1). Karar ağaçları doğal bir süreç içerisinde sınıflandırma prosedürünü açıklar (Quinlan, Rivest, 1989: 228). Karar ağaçları akış şeması şeklindeki ağaç yapılarını içerir. Hiyerarşik bir yapıya sahiptir. Ağacın her bir düğümü ya bir sınıf adını belirtmekte ya da mümkün olan sonuçlara göre örneklem uzayını bölmekte kullanılır (Utgoff, 1989: 162). Karar ağaçları geleneksel istatistiksel analiz formlarında (çok değişkenli doğrusal regresyon analizleri gibi), veri madenciliği araç ve tekniklerinde (yapay zekâlar) kullanılırlar. Karar ağaçları algoritmalar tarafından oluşturulmuş farklı yöntemlerle veriyi dallar halinde bölümleyen bir yapıya sahiptir. Bu bölüm form olarak baş aşağı oluşturulmuş bir ağaç yapısı olmakla beraber, en üst kısımda kök (ebeveyn) düğüm yer alır. Baş aşağı oluşturulmuş karar ağaçları aynı zamanda böl ve fethet yöntemini kullanırlar (Murthy ve diğerleri, 1994: 4).

Bu analiz tekniği basit tek boyutlu ve karar ağacı yapısını gösterecek şekilde oluşturulur. Karar ağacı aynı zamanda sürekli ve kategorik veriyi gösterebilir. Bir karar ağacı üç ögeden oluşur. Bunların birincisi karar düğümüdür ve test değişkenini belirtir. İkincisi bir uç veya daldır ve olası değişken sonucuna uygundur. Üçüncüsü ise bir yaprak ya da cevap düğümüdür. Nesnenin ait olduğu sınıf bilgisini içerir (Amor ve diğerleri, 2004: 421). Düğüm gösterimi tüm veri seti kayıtlarını, alanları ve alan değerlerini gösterir. Kuralları oluşturan alanlar ya da sütunlar giriş verileri olarak adlandırılırlar. Kurallara ayırma işlemi ardı ardına gerçekleştirilerek ters bir ağaç gibi dalların, alt dalları oluşturduğu hiyerarşik bir sistem oluşturur.

Karar ağaçları son 50 yıldır kullanılmasına rağmen (ilk karar ağacı çalışmalarından birisi televizyon yayıncılığı çalışmasında 1956'da Belson tarafından kullanılmıştır.), yeni

birçok karar ağacı türü geliştirilmiştir ve yıllar geçmesine rağmen hala veri madenciliği ve makine öğrenmede ilgi çekici sonuçlar sunmaya devam etmektedir (Deville, 2006: 5).

Örnek olarak geliştirilen bu uygulamalardan birisi rastgele ormanlar (random forests)'dir. Rastgele ormanlar bir çoklu ağaç yapısıdır. Bu yapı rastgele yazılmış örnek veriler, girişler ve tekrar ağırlıklandırma teknikleri ile birden çok ağaç geliştirir ve bunlar birleştiğinde karar ağacı yapısı üzerinde daha güçlü tahminler ve tanımlar oluşturur.

Karar ağaçları diğer modelleme teknikleri ile de uyum içerisinde çalışırlar. Regresyon ağaçları karar ağaçları yapısı ile aynı fakat daha karmaşık bir yapıya sahiptir. Regresyon ağaçlarında karar ağaçları gibi yapılar oluşturulurken birden fazla değişken baz alınır.

Karar ağaçları aynı zamanda kategorik veri setleri indirgeyerek seçilen hedef değerleri ya da değişkenleri aralıklar haline getirebilir ve sıralayabilirler. Bunu yaparken kural uygulamaları üzerinden çalışırlar. Bankacılık uygulamalarında kişileri yaş aralıklarına, cinsiyetlerine göre sınıflandırarak bunları kurala dönüştürebilirler. Örnek olarak eğer müşterinin yaşı otuz veya otuz yaşından küçük ise ve erkek ise elektronik postaya cevap verecektir (Rokach, Maimon, 2005: 167).

Karar ağaçları çok değişkenli analizlerin bir türüdür. Çok değişkenli analizlerin hepsi bizim tahmin, açıklama, tanımlama ya da bir çıktıyı sınıflandırmamıza izin verir (Deville, 2006: 8).

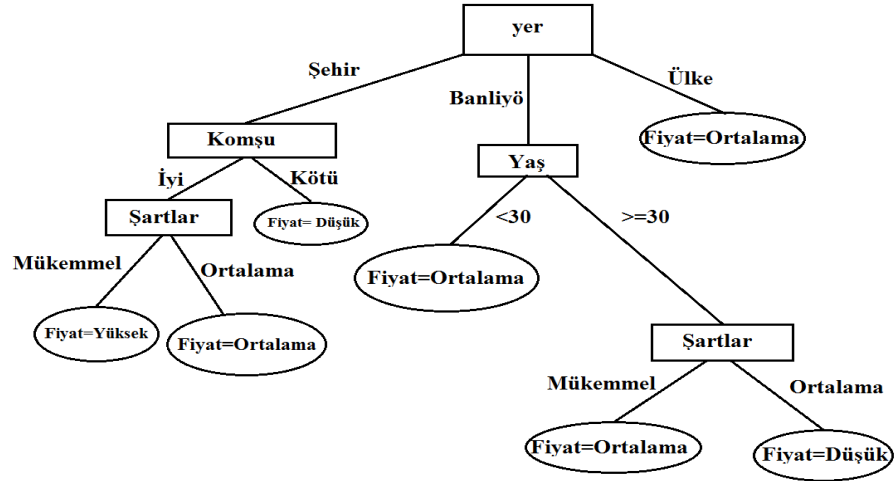
Karar ağaçlarının altında yatan güç; kullanım kolaylığı, farklı veri seviye ve ölçüm türleri ile sağlamlığı ve yorumlanabilir olmasıdır. Karar ağaçları işlenmemiş veriyi yükseltilmiş veriye dönüştürür ve iş dünyasının, mühendisliğin, bilimsel sorunların çözümünde kolay, basit ve insanlar tarafından anlaşılabilir kurallar bütününe çevirir.

Karar ağaçları girilen değerler ile hedef değerler arasında güçlü ilişkiler bulmaya çalışır. Birbiri ile yakın ilişki içerisinde olan değerler, bir araya gelerek dalları oluşturur.

Güçlü bir girdi çıktı ilişkisi, girdi değerinin tahmin etme yeteneğini de geliştirir. Güçlü bir ilişki hedefin karakteristiğini ortaya koyar. Bu şekilde ilişkilerin hedef değerleri tahmin edebilmesi normaldir.

Karar ağaçları; kolay anlaşılabilir yapıya sahiptir. Tek tablo üzerinde çalışır ve her seferinde bir nitelik için çalışır. En çok kullanılan veri madenciliği tekniğidir. Parçala ve yönet stratejisine dayanır. İki farklı bölme ya da parçalama yöntemi vardır. Bunlar; normal bölümler: değer sayısı kadar bölüme ayrılır ve rakamsal bölümler: $x > a$ veya $x < a$ şeklinde sürekli değişkenler üzerinden hesaplanır. Paralel bir düzlem üzerinde iki boyutlu olarak bölümlenme yapabilirler.

Karar ağaçları aynı zamanda çok büyük çalışma verileri üzerinde ters etki yapar (Rokach, Maimon, 2005: 184). Ağacın ne kadar budanması gerektiğini öğrenebilmenin yolu veriyi test etmektir, bu da deneme yanılma yöntemi ile olacağından çok fazla zaman alabilir. Budama gürültülü veriden kurtulma yoludur. Karar ağaçlarına bir örnek Şekil 14’te gösterilmiştir.



Şekil 14. Karar Ağacı Yapısı (Breslow, 1997: 3)

2.2.Kural Bazlı Sınıflandırmalar

Yüksek seviyeli, kolay yorumlanabilen eğer-öyleyse tarzı sınıflandırma kurallarını biçimlendirirler. Kurallar ağırlıklı olarak iki kısımdan oluşur, bunların birisi öncül (left hand side) diğeri ise izleyendir (right hand side). İzleyen parça kuralın eğer kısmını öncül değeri ve tahmini değerleri baz alan durumları oluşturur (Han, Kamber, 2006: 319). Öncül parça ise kural tarafından ortaya konulan herhangi bir örneğin izleyen parça tarafından sağlanıp sağlanmadığını belirler. Bu kurallar farklı sınıflandırma algoritmaları tarafından oluşturulabilir. Bu algoritmaların en çok bilinenleri karar ağaçları ve sıralı kapsama kuralıdır.

Bu sistemde;

Kural: (Koşul) → y

Burada,

Koşul niteliğin bağlacıdır.

$$(A_1=v_1) \text{ ve } (A_2=v_2) \text{ ve...ve } (A_n=v_n)$$

y sınıf etiketidir.

LHS: Öncül kural veya koşul

RHS: Kural sonucu

dur.

Örnek:

$(Kan\ Türü = Sıcak) \wedge (Kuluçkaya\ Yatma = Evet) \rightarrow Kuşlar$

$(Vergilendirilebilir\ Gelir < 50K) \wedge (Geri\ iade = Evet) \rightarrow Kaçınma = Hayır$

Oluşturulan sınıflandırma kuralı mükemmelse doğruluk “1” olur. Bu değere ulaşıldıktan sonra kural oluşturmaya son verilmelidir. Ayrıca doğruluk verilen eşik değere ulaştığında veya çalışma seti daha fazla parçalanamadığı zaman kural oluşturmaya son verilmelidir.

Kural bazlı sınıflandırmalar ihtiyaç duyulan birçok özelliğe sahiptir. Kural setleri kısmen insanların anlayabileceği kolaylıktadır ve kural öğrenme sistemleri birçok problemde karar ağaçlarından çok daha iyi performans verir (Qin ve diğerleri, 2009: 1633).

Kural bazlı sınıflandırmalar karar ağaçları gibi yüksek derecede açıklayıcıdır. Yorumlanması ve oluşturulması kolaydır. Yeni örnekleri hızlı bir biçimde sınıflandırabilir. Performansı karar ağaçları ile karşılaştırılabilecek düzeydedir ve kolaylıkla kayıp değerler ve sayısal niteliklerle başa çıkabilir.

2.3. Bayes Ağları (Bayesian Networks)

Bayes sınıflandırma tekniği Bayes Teoremi'nin üzerine kurulmuştur. Bayes sınıflandırıcıları istatistiksel sınıflandırıcılardır. Bayes ağları değişken veri setleri arasındaki olasılıksal ilişkileri gösteren doğal ve etkili bir metottur (Cooper, 1990: 393). Bir bayes ağı yakın öncülleri verilen grafikte yönlendirilmiş her düğüm (node) için bir olasılık dağılımı oluşturur. Bir bayes ağ sınıflandırıcısı kategorik veri içeren bir veri seti üzerindeki ortak olasılık dağılımını temsil eder. İki parçadan oluşur. Bunlardan birincisi, düğümlerden oluşan yönlendirilmiş G aksilik grafiği ve yaylar ve koşullu olasılık tablolarıdır. Düğümler; değerlerin direk bağımlılıklarını içeren yayları temsil eder. Bayes ağındaki yayların yoğunluğu karmaşıklığı ölçer. Seyrek bayes ağları ise basit olasılıksal modelleri (naive bayes ve gizli markov modelleri), yoğun bayes ağları ise yüksek karmaşıklığa sahip modelleri temsil eder. Bundan dolayı bayes ağları olasılıksal modellemede esnek bir yöntemdir.

Bayes ağları Spiegelhater, Franklin ve Bull tarafından 1989'da Heckerman tarafından 1990'da hastalık teşhislerinde, Dean tarafından 1990'da harita öğrenmede, Charniak ve

Goldman tarafından 1989 ve 1990'da dil anlama konusunda ve birçok konuda kullanılmıştır (Charniak, 1991: 50).

Bayes ağlarının en önemli özelliği ağın kendi kendine optimal çözümü vermesidir. Eğer ağın tavsiye ettiği şekilden farklı bir yol seçerseniz, ya ağda yer alandan daha fazla bilgiye sahipsiniz ya da rasyonel olmayan bir karar veriyorsunuz demektir.

Bayes ağları tahmin, finansal risk yönetimi, portföy tahsisi, sigorta model ekosistemi, sensör fizyonu, izleme ve alarm gibi birçok alanda kullanılmaktadır.

Örnek olarak bir Bayes ağı hastalıklar ile semptomları arasındaki olasılıksal ilişkileri gösterebilir. Verilen semptomlarla ağ farklı hastalıkların bulunma olasılığını hesaplayabilir.

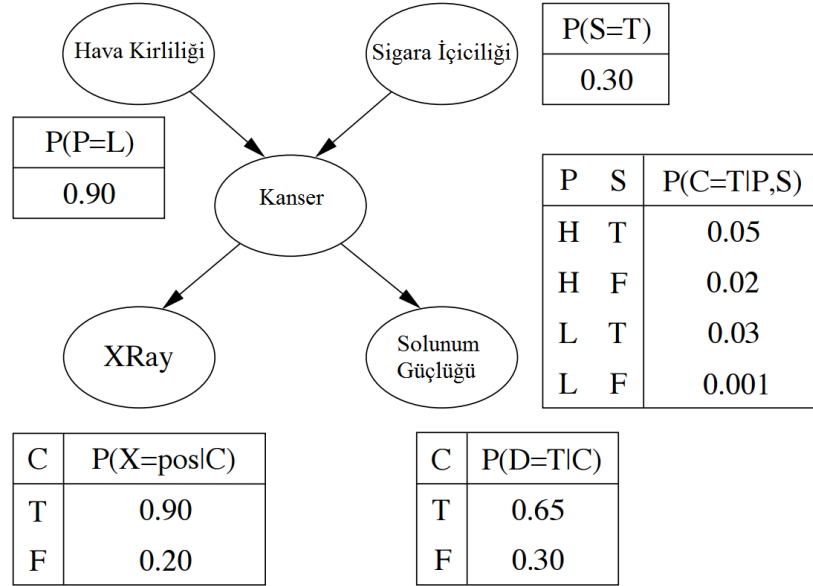
Bayes ağlarında kullanılan ağ yapısı bir Yönlendirilmiş Aksilik Grafiğidir. (DAG - Directed Acyclic Graph) (Chickering, 1995: 87). Bu ağlar miktarları, gizli değişkenleri, bilinmeyen parametreleri ve hipotezleri gözleyebilir. Sınırlar koşulsal bağımlılıkları temsil ederler. Düğümler temsili değerlere bağlı değildirler. Değerler koşulsal olarak birbirinden bağımsızlardır. Yönlendirilmiş aksilik grafikleri daha çok fizik ve vizyon toplulukları tarafından kullanılmakta iken yönlendirilmemiş aksilik grafikleri ise yapay zekâ (artificial intelligence), istatistik ve makine öğrenme alanlarında yoğun olarak kullanılmaktadır (Ruggeri, Kenett, Faltin, 2007: 1).

Bayes ağı kesin olmayan çevre hakkındaki yapıyı gösterir. Bayes ağlarında bu düğümler rastgele değişkenleri temsil eder; $U = \{X_1, \dots, X_n\}$ olmak üzere U 'nun tüm durumları için ortak olasılık dağılımını temsil eder. U için tanımlanan bir bayes ağı aynı zamanda U için tanımlanmış bir ortak olasılık dağılımıdır (Heckerman, 1995: 5).

Bir durumun bir başka durum üzerinde direk etkisi olması durumu dikkate alınması gerekir. Örnek olarak insan vücudunda hastalık bulunması veya bulunmaması test sonucunun pozitif ya da negatif çıkması üzerinde direk etkiye sahiptir. Bayes teoremi bu durum üzerinde olasılıksal çıkarım yapmaya çalışır. Yine aynı örneği dikkate alırsak test sonucunun pozitif çıkması bir dizi zincirleme reaksiyona bağlı olarak ortaya çıkar. Bunlardan bazıları; kişinin daha önce sigara içip içmediği, daha önce bronşit olup olmadığı ya da akciğer kanseri olup olmadığıdır (Neapolitan, 2003: 3).

Ağın yapısı ya da topolojisi değişkenler arasında nitel ilişkileri kapsamalıdır. Özellikle iki değişkenin birbirine bağlanması için birbiri üzerinde etkiye sahip olması gerekmektedir. Linkler ile de etkinin yönü belirtilmelidir (Korb, Nicholson, 2010: 31). Ağ yapısı karar ağaçlarının yapısı ile aynı özelliktedir.

Genel olarak Bayes ağları ortak olasılık dağılımlarının bir temsili sayılırlar. Bu temel varsayım modellenen yapının şeklinden ve kullanışlı bir altyapının olmasından kaynaklanmaktadır.



Şekil 15. Bayes Ağı Örneği (Korb ve Nicholson, 2010: 31)

Şekil 15'te görüldüğü üzere bir bayes ağı verilmiştir. Bu ağ aynı zamanda bir yönlendirilmiş aksilik grafiğidir. Görüldüğü üzere akciğer kanserini etkileyen iki etmen vardır. Bunlardan biri hava kirliliği, diğeri ise sigara içiciliğidir. Hava kirliliği kanseri %90 etkilerken sigara içiciliği %30 etkilemektedir. Yönlendirilmiş aksilik grafiği hava kirliliği ve sigara içiciliğini kansere yönlendirmiş; kanser ise sonucu iki öğeye bağlamıştır. Akciğer kanseri olanların XRay çekimlerinde pozitif sonuçla %90 ihtimalle kanser oldukları tespit edilebilmiş ve solunum güçlüğü olanların %65'inin de akciğer kanseri olduğu ortaya çıkarılmıştır.

Bayes ağlarını tanımlayan iki bileşen vardır. Bunlar yönlendirilmiş aksilik grafiği (Directed Acyclic Graph) ve olasılıksal tablo gösterimleridir. Şekil 15'de yer alan tabloda kirlilik ve sigara içme oranları dikkate alındığında; kirliliğin yüksek olduğu yerlerde sigara içen kişilerin binde beşinde akciğer kanseri görülürken, kirliliğin düşük olduğu yerlerde sigara içmeyen kişilerin on binde birinde akciğer kanseri görülmüştür.

2.4.K En Yakın Komşu

K en yakın komşu metodu 1950'lerin başlarında bulunmuştur. Bu yöntem büyük veri setleri karşısında emek yoğunluklu görünüyordu. Bu sebepten 1960'lara kadar popülerlik kazanamadı. 60'larda bilgisayar gücü kullanılabilir hale geldiğinde güç kazanmaya

başladı. Bu tarihten itibaren yoğun olarak örüntü tanıma alanında kullanılmaktadır (Han, Kamber, 2006: 348).

K en yakın komşu algoritmasının amacı; veri noktaları birden fazla sınıfa ayrılmış olan veri tabanlarında yeni bir örnek nokta ile sınıflandırmayı tahmin etmektir (Sutton, 2012: 1).

K en yakın komşu metodunun arkasındaki düşünce doküman içerisindeki k en yakın komşuları bulmak ve bu metodu kullanarak kategori adaylarını ağırlıklandırmaktır (Li, Yu, Lu, 2003: 2).


K en yakın komşu yöntemi bir örnek tabanlı ya da tembel öğrenme çeşididir. Fonksiyon sadece yerel olarak benzetilir ve bütün hesaplamalar sınıflandırmaya kadar ertelenir. K en yakın komşu algoritması en eski ve en kolay örüntü tanımlama algoritmasıdır (Weinberger ve diğerleri, 2009: 207).

K en yakın komşu sınıflandırıcıları herhangi bir ön hazırlık gerektirmeden örneklem üzerinde uygulanır (Keller ve diğerleri, 1985: 581).

En yakın komşu sınıflandırması her örneğin n boyutlu bir uzayda yer aldığını varsayar. Öğrenme aşamasında her örnek hatırlanır. Yeni bir nokta sınıflandırıldığında, k-en yakın komşu bulunan noktaya olan ağırlığı ölçülerek yeni noktanın sınıfsal değeri belirlenir. Daha fazla doğruluk için, en fazla ağırlık en yakın noktalara verilir.

Çalışma örnekleri çok boyutlu özellik uzayında yer alan vektörlerdir ve her birinin sınıf etiketleri vardır. Çalışma aşamasında algoritma çalışma örneklerinin özellik vektörlerini ve sınıf etiketlerini depolamayı içerir.

Sınıflandırma aşamasında k bir kullanıcı tanımlı değişken olmakla beraber etiketsiz bir vektördür (bir sorgu ya da test noktası). Bu vektör k çalışma örnekleri içerisinde en yoğun olan noktaların yakınına etiketlenir.



Şekil 16. K en yakın komşu örneği (Garcia ve diğerleri, 2008: 3)

Şekil 16’da yer alan örnekte $K = 3$ olarak belirlenmiştir. Buna göre mesafe fonksiyonları kullanılarak sınıflandırılmak istenen noktaya en yakın üç noktanın uzaklığı bulunmuştur.

2.5.Yapay Sinir Ağları

Şirketler on yıllardır veri depolamakta ve bu verileri depolayabilmek için yeni veri ambarları kurmaktadır. Bu veriler kullanılabilir olmasına rağmen çok az şirket bu verilerin gerçek değerini anlayabilmişlerdir. “Yapay Sinir Ağları” (Artificial Neural Networks- ANN) genellikle “Sinir Ağları” olarak adlandırılırlar. Bu yöntem biyolojik sinir ağları temel alınarak kurulan matematiksel modeller ya da hesaplama modelleridir (Singh, Chauhan, 2009: 37). Biyolojik sinir sistemlerinin güçlü fonksiyonelliği nöronların paralel olarak işleyen doğasından gelmektedir. Yapay sinir ağ yapıları hesaplamaları yapay sinir hücreleri (nöron) denen küçük ve basit işlem ünitelerine ayırır (Luk ve diğerleri, 2000: 57). Böylelikle işlemlerin çözülmesi daha hızlı olur. Sistem öğrenebilen bir yapıya sahiptir. Veri akışı sağlanarak bu sistem kendini veriye göre adapte eder ve kendi yapısını dışarıdan veya içeriden gelen bu verilere göre şekillendirir. Yapay sinir ağı sınıflandırıcısı içeriden sinirsel ağlara ait olan nöronlara bağlıdır. Basit bir bakış açısıyla, bir nöron diğer bir nörondan pozitif ve negatif sayısal değerleri alarak işleme koyar ve eğer ağırlıklı değeri öncekinden fazla ise kendisini aktif eder.

Yapay sinir ağları alanı bilgisayarların gelişiminden önce ortaya çıktı. İlk olarak McCulloch ve Pitts tarafından 1943’te insan beyninin fonksiyonlarının modellenmesi fikri ile ortaya çıktı. Bu sistem girdi elemanlarını takip eden eşik mantık işlemlerinden

oluşuyordu. Bu sistemin sorunu ağırlıklar düzeltilmiş ve model örneklerden öğrenme yetisine sahip değildi. 1949'da Hebb değişkenlerin öncül ve sonraki sinaptik değerlerine göre bağlantı ağırlıkları tabanlı bir sistem geliştirmiştir. Hebb'in oluşturduğu bu nöron kuralı ağ literatürüne temel öğrenme kurallarından birisi olarak geçmiştir. 1960'da Widrows ve Hoff ADALINE (Adaptive Linear Element) modelini elemanları ve en küçük ortalama kareleri (Least Mean Square) öğrenme algoritmasını ağırlıkları ayarlamak için ortaya atmışlardır. 1982'de Hopfield sinir ağlarının enerji geri beslemelerinin analizini yapmıştır. Bu analiz geri besleme ağında stabil bir denge ortaya koymuş, bu da ağın simetrik ağırlığını sağlamıştır. 1986'da Rumelhart ağırlıkların çok tabanlı olarak ileri doğru sistemik bir yolla iletilmesini sağlayarak girdi – çıktı çiftlerinin saklı haritalanmasını sağlamıştır. 1994'te Cheng ve Titterington geleneksel istatistiksel model üzerinde detaylı bir sinir ağı araştırması yapmıştır. Bu çalışmada sinir ağı gösteriminin regresyon, temel bileşen analizi, yoğunluk fonksiyonu ve istatistiksel görüntü analizi içerdiğini göstermiştir. 1996'da Warner ve Misra ilgili sinir ağı literatürünü incelemiş, öğrenme algoritmaları ve regresyon ve sinir ağı karşılaştırmalarının notasyonlardan, terminolojilerden ve uygulamalardan oluştuğunu ortaya koymuşlardır. Yine 1996'da Kaastra ve Boyd finansal tahmin ve ekonomik zaman serileri için bir sinir ağı modeli ortaya koymuşlardır. 1997, 2000'de Dewolf ve Francl ekin hastalıklarının tahmininin sinir ağı üzerinden uygulanabilirliğini göstermişlerdir. 1998'de Zhang ve bir grup bilim adamı sinir ağı yöntemi ile finansal tahmin yönteminin genel bir incelemesini yapmış ve model üzerindeki genel paradigmaları istatistiksel olarak incelemişlerdir. 2001'de Sanzogni ve Kerr bir çiftliğin süt üretimini standart ileri beslemeli sinir ağı ile tahmin etmişlerdir. 2004'te Chakraborty ve diğer bilim adamları baklagillerde legüme hastalığının şiddetini tahmin edecek bir sistem geliştirmişlerdir. Bu tarihten sonra sinir ağları hız kazanarak daha farklı alanlarda gelişmeye devam etmiştir (Kumar, 2016: 157, 158).

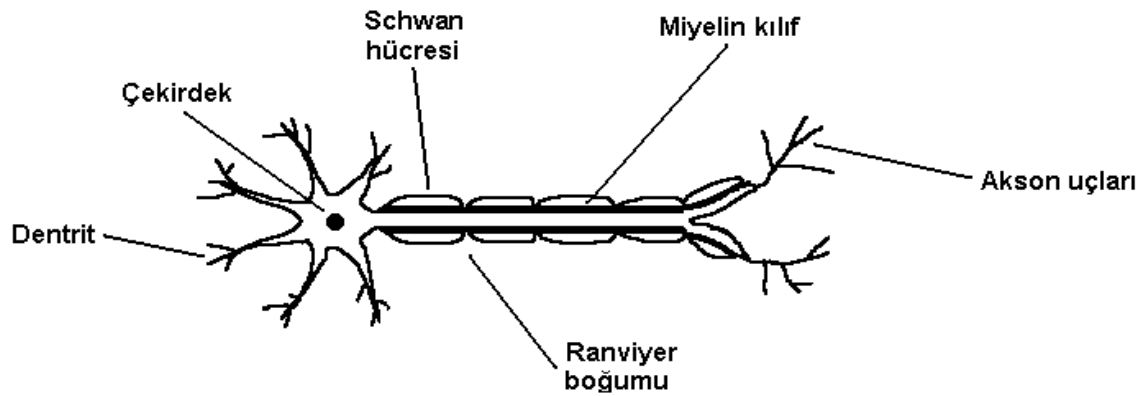
Yapay sinir ağları insan beyninin çalışma sisteminin yapay olarak bir kopyasının oluşturulması çalışmalarından ortaya çıkmıştır. İnsan beyni birçok nöronun (sinir hücresinin) bir araya gelmesi ile oluşmuştur. Yapay sinir ağlarının ise birçok işlemcinin (yapay sinir hücresi) birbirine bağlanması ile oluşturulmuş bir sistem olduğu söylenebilir. Önceleri tıp alanında başlayan çalışmalar yapay sinir ağlarının gelişmesiyle fizik, matematik, elektrik ve bilgisayar alanlarında da kullanılmaya başlanmıştır.

Yapay sinir ağları paralel kurulmuş bir bilgi işleme sistemidir. Yani zekâ gerektiren bilgileri işlemeye çalışan bir sistemdir. Bu sistem tek yönlü işaret bağlantıları ile birbirine


bağlanan işlem elemanlarından oluşur. Yapay sinir ağları ile insan beyninin fonksiyonları arasında benzerlikler bulunmaktadır. Bu yüzden yapay sinir ağları insan beyninin bir modeli olarak adlandırılabilir. Dış şartlara göre davranışlarını değiştirebilir.

Yapay sinir ağlarının anahtar özelliği; tekrarlı bir öğrenme süreci olması, veri setlerinin ağa teker teker tanıtılması ve bu esnada girdi değerlerinin ağırlıkları ile ilişkilendirilmeleridir. Bütün örnekler tanıtıldıktan sonra, işlem genellikle tekrar başlatılır. Öğrenme aşamasında, ağ ağırlıkları ayarlayarak doğru sınıf katmanını girdi bilgilerine dayanarak bulmaya çalışır. Bu sürece başlamak için ağırlık değeri rastgele seçilir ve öğrenme başlar (Rani, 2011: 2). Yapay sinir ağları düğüm adı verilen hesaplama elemanlarından oluşur ve bunlar sinyalleri birbirine bağlı olan yaylar aracılığı ile alırlar. Sinyaller güçlendirilerek yani yayların ağırlıkları arttırılarak ve aktivasyon eşiği özgün düğümler için ayarlanarak örüntü tanıyabilme için eğitilebilir. Yüksek miktarda girdi verisi ile eğitilirken yapay sinir ağları veri seti içerisinde yer alan genelleştirilmiş örüntüleri çıkabilir ve hatırlayabilir. Ayrıca daha önceden görülmeyen model girdilerini ayırt edebilir (Brusic ve diğerleri, 1998: 124).

Girdi düğümlerinin sayısını N olarak ve çıktı düğüm sayısını M olarak belirleyecek olursak; yapay sinir ağlarının uygulanabilmesi bu girdi ve çıktı sayılarına bağlıdır. Fakat gizli katmanda ne kadar düğüm kullanılacağına dair herhangi bir kural bulunmamaktadır. Eğer gizli katmanda çok az düğüm kullanılırsa; problemin genelleştirilmesi konusunda daha önce görülmemiş zorluklarla karşılaşılabilir. Bir diğer taraftan da eğer gizli katmanda çok fazla düğüm var ise; ağ herhangi bir değer taşıyan herhangi bir şeyi kabul edilemez sürede öğrenir (Dawson, Wilby, 1998: 49).

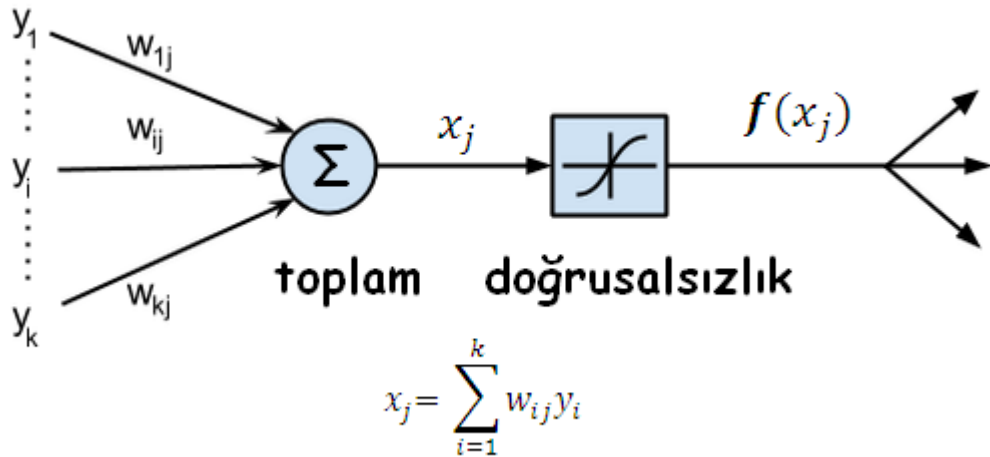


Şekil 17. Basit Bir Nöron Yapısı (Online: 21.04.2016, <http://www.biyodoc.com/sinir%20sistemi/4.PNG>)



Şekil 18. Yapay Sinir Ağı Yapısı (Dawson, Wilby, 1998: 49)

Yapay sinir ağları terminolojisi insan beyninin biyolojik modeli ile yaratılmıştır. Bir sinir ağı birbiriyle bağlantılı hücrelerden oluşur. Bunlar nöronlardır. Nöronlar girdi ya da çıktıdan gelen sinyalleri alarak dönüştürür ya da çıktı hücrelerine iletirler. Bir nöronun fonksiyonu girdi vektörü (y_1, \dots, y_k) 'ya olmak üzere, çıktısı f bir fonksiyonu olmak üzere bir nöronun grafik gösterimi Şekil 19'daki gibidir.



Şekil 19. Bir Nöronun Grafik Yapısı (Kumar, 2016: 159)

Sinir ağları hava durumu tahminlerinde, finans sektöründe imza ve banka notu doğrulamasında, risk yönetiminde, yabancı para çevrimi ve tahmininde, iflas tahmininde, müşteri kredi puanı hesaplamasında, kredi kartı onayı ve dolandırıcılık tahmininde, bono

değerlendirme ve satışında, kredi onaylamasında, ekonomik ve finansal tahminlerde; muhasebede vergi kaçakçılığının belirlenmesinde ve tutarsızlıkların belirlenmesinde; pazarlamada; müşterilerin harcama modelinin çıkarılmasında, yeni ürün analizinde, müşteri karakteristiğinin ortaya konmasında, satış tahminlerinde; insan kaynaklarında çalışanın performans ve davranışının tahmininde, personel kaynak tahmininde, uzay, otomotiv savunma, elektronik, eğlence alanı gibi birçok alanda kullanılırlar (Singh, Chauhan, 2009: 41). Tablo 4'te yapay sinir ağlarının avantajları ve dezavantajları karşılaştırılmıştır.

Tablo 4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları (Cerny, 2001: 4,5)

Yapay Sinir Ağlarının Avantajları	Yapay Sinir Ağlarının Dezavantajları
Yüksek Doğruluk: Sinir ağları doğrusal olmayan problemlerin modellenmesinde klasik yöntemlere göre daha başarılıdır.	Şeffaflık açısından zayıftırlar.
Gürültü Toleransı: Sinire ağları eksik ve kayıp verilere karşı oldukça esnektir.	Deneme ve yanılma yapısına sahiptir. Gizli düğüm sayısı ve eğitim parametreleri sezgiseldir.
Önceki Tahminlerden Bağımsızlığı: Taze veri ile güncellenebilir buda dinamik bir çevre yaratır.	Veriye aç bir yapısı vardır. Ağın eğitimi çok fazla veri gerektirir ki buda bilgisayar ağırlıklı bir çalışma gerektirir.
Bakım kolaylığı: Taze veri ile güncellenebilir bu da dinamik bir yapıya sahip olduğunu ve ağın genelleme yeteneği olduğunu gösterir.	Eğer çok fazla ağırlık düzenlenmeden kullanılırsa, sinir ağı yeni veri oluşturmakta kullanışsız bir hal alır.
Paralel sürücüler üzerine yerleştirilebilir.	Ağın tasarlanmasında belirgin bir kurallar bütünü yoktur.
Sinir ağları üzerinde yer alan elemanlardan birisinde sorun çıksa bile paralel yapısı nedeniyle herhangi bir sorun yaşamadan çalışmaya devam eder.	Sinir ağı tamamen var olan verinin kalitesine bağlıdır. Ağın eğitiminde kullanılan veriler hatalı olursa ağ da hatalı sonuçlar verecektir.


Bir önceki seviyede yer alan nöronların verdiği yerel hatalara karşın daha güçlü ağırlıklarla sorumluluk verilir.	Sinir ağları klasik istatistiksel özellikler açısından zayıftır. Güvenilirlik testleri ve hipotez testleri uygulanamaz.
Bir önceki seviyedeki nöronların hatasıyla sorumluluk yükler.	Hala gelişmekte olan bu alan tam olarak olgunlaşmamıştır.
Örneklerden öğrenerek kendilerini geliştirebilirler.	
Ağırlıklardan ötürü yapay sinir ağları daha güçlüdür.	
Yapay sinir ağları öğrenerek kendi performansını arttırır.	

2.5.1. Yapay Sinir Ağları Ağ Yapısı

Yapay sinir ağı yapıları bağlantı modellerine göre ileri beslemeli yapılar, tekrarlayan ağlar ve kohonen sinir ağları olmak üzere üçe ayrılır.

2.5.1.1.İleri Beslemeli Sinir Ağları (Feedforward Neural Networks)

İlk ve belki de en basit sinir ağı türüdür (Singh, Chauhan, 2009: 38). Bu ağda, bilgi sadece tek yönlü olarak ilerler. Girdilerden gelen bilgi herhangi bir döngüye ya da geri beslemeye maruz kalmadan varsa gizli katmanlardan geçerek ilerler ve çıktıdan sonuç verir (Kumar, 2016: 159). Genel olarak ileri beslemeli sinir ağları istenilenden çok daha yavaş olmakla beraber; bu yavaşlık uygulamalar üzerindeki en büyük darboğazı oluşturmuştur (Huang ve diğerleri, 2004: 985). İleri beslemeli ağ yapısı Şekil 20'de gösterilmiştir.



Şekil 20. İleri Beslemeli Sinir Ağı Yapısı (Kumar, 2016: 160)

İleri beslemeli ağ yapıları tek katmanlı algılayıcı, çok katmanlı algılayıcı ve radyal bazlı fonksiyon ağları olmak üzere üçe ayrılır.

- **Tek Katmanlı Algılayıcı (Single Layer Perceptron [SLP]);**

Sinir ağının en basit formudur. Tek bir nöron içerir ve bu ayarlanabilir sinaptik ağırlığa ve ortalamaya sahiptir. Bu ağ sadece girdi ve çıktı katmanına sahiptir. Çıktı elemanları birbirinden bağımsızdır. Her ağırlık kendi çıktısını etkiler.

- **Çok Katmanlı Algılayıcı (Multi Layer Perceptron [MLP])**


En çok kullanılan sinir ağı yapısıdır. Birçok katmanlı sezginin; sınırsız sayıda girdisi vardır. Bir veya birden fazla gizli katmanı barındırabilir. Girdi katmanında doğrusal kombinasyon fonksiyonları kullanır. Gizli katmanlarda genellikle sigmoid aktivasyon fonksiyonları kullanır. Girdi katmanı ile gizli katman arasında yer alan ilk katman arasında, gizli katmanlar arasında ve son gizli katman ile çıktı katmanı arasında bağlantıları vardır (Kumar, 2016: 160).

- **Radyal Bazlı Fonksiyon Ağları (Radial Basis Function Networks [RBF])**


Radyal bazlı fonksiyon sinir ağları fonksiyon tahmini ve örüntü tanımlamada basit topolojik yapısından ve öğrenmenin nasıl olduğunu göstermesi açısından etkili bir yöntemdir (Yingwei ve diğerleri, 1997: 461).

2.5.1.2. Tekrarlayan Ağlar (Recurrent Network)

Tekrarlamalı sinir ağları; 1990'dan beri yapay sinir ağlarının önemli ve ilginç bir parçasını oluşturmaktadır. Tekrarlamalı sinir ağları tamamen birbirine bağlı ve kısmen birbirine bağlı olabilmekle beraber; ileri beslemeli ağları da kapsar. Kısmen birbirine bağlı ağlarda girdi ve çıktı katmanları belirgin iken tamamen birbirine bağlı olan ağlarda böyle bir belirginlikten söz edilemez (Medsker, Jain, 2001: 12).



Şekil 21. Kısmen Birbirine Bağlı Tekrarlamalı Sinir Ağı (Medsker, Jain, 2001: 12)



Şekil 22. Tamamen Birbirine Bağlı Tekrarlamalı Sinir Ağı (Medsker, Jain, 2001: 12)

Şekil 21'de görüldüğü üzere kısmen birbirine bağlı yapılarda girdi katmanı gizli katman ve çıktı katmanı belirgin olarak görülmektedir. Fakat Şekil 22'de görülen

tamamen birbirine bağılı ağ yapısında girdi katmanı gizli katman ve çıktı katmanı belirgin değildir. Her iki yapı da ileri beslemeli sinir ağı yapısını içermekle beraber; ek olarak kısmen birbirine bağılı yapı kendinden önceki düğüme geri dönüş yapabilirken, tamamen birbirine bağılı yapı kendisine de dönüş yapabilmektedir.

2.5.1.3.Kohonen Sinir Ağı

Kendi kendini organize edebilen haritalandırma ağlarıdır. Haritalandırmanın üç önemli özelliğı vardır; hâkim olduğı her yerde sürekli dir, tersine haritalandırma sürekli dir ve çıktı haritası girdi ile ilgili mümkün olduğunca maksimum veriyi sunar (Dekker, 1994: 354). Bu ağlar herhangi dağılmış verileri belirli düzen içerisine sokma konusunda çok iyi bir araçlardır (Hoffmann, 2005: 177).

2.6.Destek Vektör Makinaları

Destek vektör makinaları (support vector machine –SVM-) bir başka deyişle maksimum kenar boşluğu; bir hiper düzlem konseptidir. Destek vektör makinaları doğrusal düzlem üzerinde yer alan sınıflar arasındaki en uzun mesafeyi bulmaya çalışan yöntemdir. Sadece sınıflandırma konularına uygulanabilmektedir. Fakat destek vektör makine algoritmaları sayısal tahmin için geliştirilmiş bir metottur. Bu metot birkaç destek vektörlerini temel alarak kernel fonksiyonları kullanarak doğrusal olmayan problemler üzerine uygulanır (Witten, Frank, Hall, 2011: 228).

Destek vektör makinaları sınıflandırıcıları dikkate değer bir ilgi görmüştür, çünkü teorik olarak güçlü bir altyapıya sahip ve cezbedici bir tahmin performansına sahiptir. Fakat destek vektör makinalarının farkındalığı henüz düşük düzeydedir. Destek vektör makinaları denetimli (supervised) öğrenme yöntemi ile çalışır (Lessmann S, Voß, 2009: 521). Şu anda destek vektör makinaları daha önce yapay sinir ağlarına gösterilen ilgiye benzer yoğunlukta ilgi görmektedir.

Destek vektör makinaları ve kernele dayalı metotlar olmakla beraber doğru modeller kurmayı başarmışlardır. Fakat bu öğrenme görevi genellikle quadratic programlama gerektirmektedir. Yani büyük veri setleri üzerinde çalışmak çok fazla hafıza kapasitesi ve çok uzun zaman gerektirmektedir. Destek vektör makinaları veri madenciliğinin sınıflandırma, regresyon, kümeleme, ilişkilendirme ve aykırılık tespiti alanlarında kullanılan güçlü bir yöntemdir (Burbidge R, Buxton B, 2001: 13).

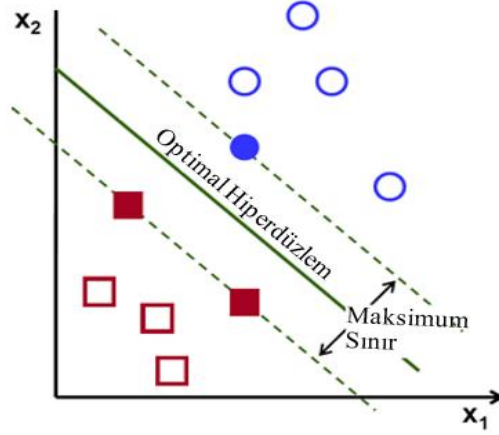
Destek vektör makinaları model tanıma amaçlı ilk algoritmanın 1936’da R. A. Fisher tarafından ortaya atılması ile başladı. 1950’de Aronszajn tarafından Kernellerin tekrar üretilmesi teorisi ortaya atıldı. 1963’de Frank Rosenbaltt doğrusal sınıflandırıcılar olan

çok katmanlı algılayıcıları icat etti (bunlar basit manada ileri beslemeli yapay sinir ağlarıydı). 1963'te Vapnik ve Lerner Genelleştirilmiş Portre Algoritmasını ortaya attı. 1964'te Aizermann, Braverman ve Rozonoer özellik uzayının bir ürünü olarak kernellerin geometrik yorumlamasını yaptılar. 1965'te Cover girdi uzayında ve seyreklikte geniş sınır hiperdüzlemini tartıştılar. Yine aynı yıl benzer optimizasyon teknikleri model tanımlama üzerinde Mangasarian tarafından uygulandı. 1968'de Gürültülü ve ayrılamayan değerlere karşı olarak durgun değişkenlerin kullanılması Smith tarafından tanıtıldı. 1973'te Duda ve Hart girdi uzayında geniş hiperdüzlemi tartıştılar. 1974'te istatistiksel öğrenme teorisi Vapnik ve Chervonenkis ile başladı. Destek vektör makinalarının istatistiksel öğrenme teorisi geliştikten sonra 1979'da Vapnik ile başladığı söylenebilir. 1986'da Hassoun doktora tezini bu konu üzerine yaptı. 1989'da birçok istatistiksel mekanikle ilgili yazılar Anlauf ve Biehl tarafından yazıldı. 1990'da Poggio, Girosi ve Wahba kernellerin kullanımını tartışmaya başladı. 1992'de Bennett ve Mangasarian Smith'in 1968'de yayınlamış olduğu çalışmaları geliştirdiler. 1992 COLT konferansında destek vektör makinaları hemen hemen bugünkü şeklini aldı. 1995'te Cortes ve Vapnik, 1998'de Bartlett ve Shawe-Taylor ve 2000'de yine Shawe-Taylor ve Cristianini konu üzerinde çalışmalar yaptı.

Bir destek vektör makinası istatistiksel öğrenme teorisini temel alan ve doğrusal ve doğrusal olmayan ikili sınıflandırma problemlerini çözebilen bir denetimli öğrenme algoritmasıdır. Buna göre S bir veri seti olsun ve M gözlem sayısına sahip olduğunu varsayalım. $S = \{(x_i, y_i)\}_{i=1}^M$, burada $x_i \in \mathbb{R}^N$ bir girdi vektörünü ve $y_i \in \{-1, +1\}$ ikili sınıflandırma etiketine karşılık gelir. Sınıflandırmanın hedefi S 'ten bir tahmin modeli çıkarmak ve bu modelin x verilen yerde sınıf üyelik karşılığını doğru olarak vermesidir (Lessmann, Voß, 2007: 522 – 523).

Değişkenler arasındaki bağlantıların bilinmediği veri setlerindeki sınıflandırma problemleri için önerilmiş bir makine öğrenme yöntemidir. Sınıflama, regresyon ve aykırı değer belirleme için kullanılabilen denetimli bir öğrenme yöntemidir. Eğitim verisinde öğrenme yaparak yeni veri üzerinde doğru tahmin yapmaya ve genelleştirmeye çalışan makine öğrenmesidir. Bu öğrenme metodunda dağılım hakkında herhangi bir ön bilgi veya varsayım yoktur. Eğitim setlerinde girdiler ve çıktılar eşlenir. Eşler aracılığıyla test setinde ve yeni veri setlerinde girdi değişkeni sınıflayacak karar fonksiyonları elde edilir. Yüksek doğruluk sağlar. Karmaşık karar sınırları modelleyebilir. Çok sayıda bağımsız değişken ile çalışabilir. Fakat olasılıksal tahminler üretemez.

Destek vektör makinalarında doğrusal olarak ayrılabilen sınıflar olduğu gibi doğrusal olarak ayrılamayan sınıflar da vardır. Doğrusal olarak ayrılamayan destek vektörleri konuyu karmaşık hale getirmektedir. Fakat yine de en geniş hiper düzlemi bulmak mümkündür. Ayrıca parametre seçimine oldukça duyarlıdır. Parametre kombinasyonları aralığının her zaman kontrol edilmesi gerekir.



Şekil 23. Destek Vektör Makinaları Düzlem Üzerinde Gösterimi (Aggarwal, Singh, 2015: 246)

Destek vektör makinalarında doğrusal sınırlar iki boyutlu düzlem üzerinde gösterilir (Şekil 23). Bu sebepten ötürü destek vektör makinalarının gösterimi oldukça basittir. Sistem her sınıf arasındaki maksimum ayrışma mesafesine ulaşmaya çalışır. İki sınıfın tam ortasına konuşlanmaya çalışır. Genelde örnek uzayda yer alan noktaların birkaçı bu hiper uzay düzleminin nereden geçeceğini belirler. Bu noktalar haricinde yer alan diğer noktalar silinse bile hiper uzay düzleminin konumu ve yönü değişmez.

Destek vektör makinaları doğrusal olarak ayrılabilen ve doğrusal olarak ayrılamayan destek vektör makinaları olarak ikiye ayrılırlar.

2.6.1. Doğrusal Olarak Ayrılabilen Destek Vektör Makinaları

Örneklem uzayında yer alan doğrusal olarak ayrılabilen iki farklı sınıf arasında sonsuz sayıda hiperuzay düzlemi geçebilir. Fakat destek vektör makinalarının amacı aradaki sınırı maksimize etmektir.

2.6.2. Doğrusal Olarak Ayrılamayan Destek Vektör Makinaları

Örneklem uzayında yer alan sınıf değerleri her zaman birbirinden keskin hatlarla ayrılmamıştır. Bazen iç içe geçmiş veya farklı yerlerde olabilir. Destek vektör makinaları kernel fonksiyonlarının yardımı ile destek vektörlerini kullanarak bunların arasındaki

sınırları maksimize etmeye çalışır. Doğrusal olmayan bu vektör makinalarını bulmak için haritalandırma (mapping) kullanılır.

Sınıfsal elemanlar haritalandırma (mapping) ile gösterilmiş olup adeta fiziki haritalardaki gibi yoğunluklarına göre renklendirilirler.

2.7.Kaba Kümeler

Kaba küme teorisi Polonya'da 1980'lerin başlarında Zdzislaw Pawlak tarafından geliştirilmiştir ve Pawlak doğru olmayan sınıflandırma ve kesin olmayan tecrübelerden elde edilen verinin ifadesinden endişe etmiştir. Basit olarak kaba küme teorisi açıklanması zor olan bilgileri ortaya koymaya çalışır. Örnek olarak sağlık alanında belirli hastalıkların veya çıktılarının arasındaki ilişkileri gösterebilir (Ohrn, Rowland, 2000: 2).

Kaba küme felsefesi evrendeki tüm objelerin birbiri ile belirli bir bilgi bakımından ilişki içerisinde olduğu üzerine ortaya çıkmıştır. Aynı bilgi ile karakterize edilen objeler verilen bilgi açısından benzerdir. Bu benzerlik ilişkisi kaba küme teorisinin matematiksel temelini oluşturur (Pawlak, 2002: 8).

Kaba kümelerin temel avantajı herhangi ek bir veriye ihtiyaç duymadan olasılık ataması yapabilesidir (Rissino, Lambert-Torres, 2009: 56). Veri içerisindeki gizli modelleri bulabilir. Minimum veri setini bulabilir. Kullanılan metotlar paralel bilgisayarlar üzerinde kolayca uygulanabilir. Buda zaman kazanılmasında yardımcı olur. Veri içerisindeki gizli kalıpları bulmada efektif bir yapıya sahiptir.

Kaba kümelerin başarılı uygulamalarından birisi LERS'tir. Bu sistem NASA tarafından yıllardır kullanılmakta olup, kendini kanıtlamıştır (Grzymala-Busse, 2005: 96).

Kaba kümeler; yapay sinir ağlarının ve bilişsel bilimlerin birçok alanında, sağlık, akustik analizlerde, güç sistemlerinin operasyonel problemlerinde, meteorolojik model sınıflandırmalarında, kimya alanında, bankacılık akıllı kontrol sistemlerinde, veri tabanı özellikleri araştırma, üretim kontrol alanlarında, mühendislik, karar destekleme gibi alanlarda kullanılır (Pawlak, 2002: 7). Ayrıca bilgi keşfinin özellik seçimi, özellik çıkarımı, veri indirgemesi, karar ve kural oluşturma ve model çıkarma aşamalarında kullanılır.

2.8.Genetik Algoritmalar

Genetik algoritmalar, optimizasyon problemleri için kullanılan sezgisel bir fonksiyondur. Fonksiyonun sonu (minimum veya maksimum), analitik olarak elde

edilemiyorsa genetik algoritmalar kullanılır. Genetik algoritmalar evrim algoritmaları olarak da adlandırılırlar (Lin, Cao, Wang, Zhang, 2004: 3).

Genetik algoritmalar, Darwinist evrim teorisinin doğal seleksiyon yönteminden etkilenmiştir (Lin, Cao, Wang, Zhang, 2004: 3). Genetik algoritma 1970’te John Holland tarafından geliştirilmiştir. Genetik algoritma biyolojik organizmaların genetik süreçleri üzerine kurulmuştur (Vishwakarma, Kumar, Nath, 2012: 89). Doğada gözlemlenen evrimsel sürece benzer bir şekilde çalışan arama ve eniyileme yöntemidir. Karmaşık çok boyutlu arama uzayında en iyinin hayatta kalması ilkesine göre bütünsel en iyi çözümü arar. Genetik algoritmalar problemlere tek bir çözüm üretmek yerine farklı çözümlerden oluşan bir çözüm kümesi üretir.

Genetik algoritmalar, diğer yöntemler kullanılırken büyük zorluklarla karşılaşılan, oldukça büyük arama uzayına sahip problemlerin çözümünde başarı göstermektedir. Bir problemin bütünsel en iyi çözümünü bulmak için garanti vermezler. Ancak problemlere makul bir süre içinde, kabul edilebilir, iyi çözümler bulurlar (Beniwal, Arora, 2012: 4).

Genetik algoritmalar çeşitli arama ve optimizasyon problemleri üzerinde başarı ile uygulanmıştır. Genetik algoritmalar genel olarak iki farklı yaklaşım üzerine odaklanmıştır. Bunlar; Pitt (Pittsburgh) yaklaşımı (Smith, 1980) geleneksel genetik algoritmasını kullanır. Bu yaklaşımda popülasyon içerisindeki her varlık öğrenme probleminin çözümünü temsil eden kurallara sahiptir. Michigan yaklaşımı (Holland, 1986) genellikle belirgin bir şekilde farklı gelişim mekanizmaları kullanır ki bunda popülasyon kendine has kurallara sahiptir ve her biri öğrenme hedefi üzerinde bir parça çözüme sahiptir (Flockhart, Radcliffe, 1996: 299).

Genetik algoritmaların asıl amacı, hiçbir çözüm tekniği bulunmayan problemlere çözüm aramaktır. Kendilerine has çözüm teknikleri olan özel problemlerin çözümü için mutlak sonucun hızı ve kesinliği açısından genetik algoritmalar kullanılmazlar. Genetik algoritmalar ancak; arama uzayının büyük ve karmaşık olduğu, mevcut bilgiyle sınırlı arama uzayında çözümün zor olduğu, problemin belirli bir matematiksel modelle ifade edilemediği, geleneksel eniyileme yöntemlerinden istenen sonucun alınmadığı alanlarda etkili ve kullanışlıdır. Genetik algoritmalar parametre ve sistem tanılama, kontrol sistemleri, robot uygulamaları, görüntü ve ses tanıma, mühendislik tasarımları, planlama, yapay zekâ uygulamaları, uzman sistemler, fonksiyon ve kombinasyonel eniyileme problemleri ağ tasarım problemleri, yol bulma problemleri, sosyal ve ekonomik planlama problemleri için diğer eniyileme yöntemlerinin yanında başarılı sonuçlar vermektedir.

Genetik algoritmalar üç ayrı aşamada incelenebilir. Bunlar; seçim, geçiş ve mutasyondur.

2.8.1. Seçim (Selection)

Seçim olasılıksal olarak en uygun olanın yaşaması (survival of the fittest) sorunu ile ilgilenir. Bu aşamada en uygun kromozom yaşaması için seçilir. Popülasyonu P ile gösterecek olursak; P içerisinde kromozom seçmemiz gerekir. Bu seçim işleminde uygulanacak metotlar; rulet seçimi, yarışma seçimi olarak iki farklı yöntem uygulanabilir. Rulet seçiminde seçime nispi olarak uygun bir kromozom seçilir:

$$\Pr(c) = \frac{\text{Uygunluk}(c)}{\sum_{c' \in P} \text{Uygunluk}(c')}$$

Bu yöntem rulet çemberinin bir parçasına benzetilebilir. Bunlar uygunluklarına göre boyutlandırılır ve çember çevrilerek kazanan dilim belirlenir.

Bir başka metot ise turnuva seçimi olarak adlandırılır. Bu seçimde rastgele iki kromozom seçilir, karşılaştırılmış olasılık ile az ya da fazla uygun olan kromozom seçilir (Pedersen, 2003: 1-2).

2.8.2. Genetik Değişim (Crossover)

Ayrı ayrı kromozomları P 'den alarak yenilerini oluşturmak için kombine eder (Pedersen, 2003: 1). Genetik değişim fonksiyonu tarafından oluşturulan çocuk, popülasyon tarafından sağlanan ebeveynler tarafından oluşturulur. Tek ya da iki noktalı değişimde olsun, genomların amacı beraber hayatta kalmaktır. Her genin herhangi ebeveynden gelme ihtimali birbirine eşittir (Vishwakarma, Kumar, Nath, 2012: 90).

2.8.3. Mutasyon (Mutation)

Türler içerisinde genetik algoritma rastgele küçük değişiklikler yaparak popülasyonun mutasyona uğramış çocuklar üretmesini sağlar. Bu ölçüm 0 ile 1 arasında değişir. Eğer değer 0 ise herhangi bir değişiklik yapılmamış olacak ve değer 1 ise standart sapma gen aralığının tamamına eşit olduğu anlamına gelir (Vishwakarma, Kumar, Nath, 2012: 90).

2.9. Performans Tahmini Değerlendirmesi

Farklı alanlardan elde edilen veriler gün geçtikte artmakta ve yüksek miktarda veriden anlamlı bilgi çıkarabilen veri madenciliği gittikçe popüler bir hal almaktadır (Tiwari, Manu, Yadav, 2012: 32). Veri madenciliği uygulamaları, saklı olan potansiyel bilgiyi çıkartma alanında gayet başarılı olmaktadır. Veri madenciliği alanında sınıflandırma önemli bir problem olarak görülmüştür ve veriyi sınıflandırma veri madenciliğindeki tipik

görevlerden birisidir. Yüksek miktarda veri sınıflama aracı bulunmaktadır. (Bayes ağları, karar ağaçları v.b.) Sınıflandırmanın hedefi doğru bir şekilde belirlenen sınıf içerisindeki veriyi tahmin etmektir. Örnek olarak sağlık alanında kanser vakalarını inceleyen biyoinformatik alanı kanser olan kişilerin sağlık geçmişlerini ve belirtilerini inceleyerek erken teşhis yöntemleri geliştirmiş ve yaşam sürelerinin uzamasında önemli adımlar atmıştır. Kanser hastalığı yapılan araştırmalar sonucunda hücrelerin anormal bir biçimde çoğalmalarından ortaya çıktığı ve çoğalan bu hücrelerin diğer hücreleri işgal etmesiyle insan hayatında ölümcül sonuçlar doğurduğu ortaya çıkmıştır (kolon, akciğer v.b.) (Nookola, Orsu, Pottumuthu, Mudunuri, 2013: 49).

Performans tahmini değerlendirmesi, farklı veri madenciliği uygulamalarının doğruluk oranları, programın sonuç vermesi için gereken vakit, programın sağlıklı bir şekilde çalışabilmesi için gereken değişken sayısı gibi birçok kıstasın bir araya toplanarak karşılaştırılmasıdır. Yapılan bu değerlendirme ve karşılaştırmalar sonucu en iyi, en hızlı, en az insan gücü isteyen ve en az veri ile yeni tahminleri sağlıklı yapabilen yöntemler benimsenmeye çalışır. Bu karşılaştırmalar yapılırken bazen çok düşük doğruluk veren sonuçlar ortaya çıkabilir. Bunun sebebi genellikle uygulamanın veri setine uygun olmadığı ya da yanlış bir yöntem ile çözülmeye çalışıldığı anlamına gelebilmektedir.

2.10. Regresyon

Regresyon analizi değişkenler arasındaki ilişkiyi inceleyen bir istatistiksel araçtır. Genellikle araştırmacı bir değişkenin bir diğeri üzerindeki nedensel etkisini ortaya çıkarmaya çalışır. Örnek olarak talebe göre fiyat artışı verilebilir (Sykes, 1993: 1).

Regresyon veri madenciliğinde numaraları tahmin eden yöntemdir. Bunlar yaş, kilo, mesafe, ısı, gelir veya satış verileri olabilir. Regresyon; regresyonda alt küme seçimi ve regresyon ağaçları olmak üzere ikiye ayrılır.

2.10.1. Regresyonda Alt Küme Seçimi

Veri odaklı sistemlerin en önemli algoritmik sorunlarından birisi verilen veri seti içerisinde en fazla bilgiyi içeren alt kümeyi seçmektir (Das, Kempe, 2008: 45). Regresyonda en çok kullanılan yöntemlerden biri alt küme seçimidir. Verilen veri yapısına göre $\{(y_n, x_{1n}, \dots, x_{Mn}), n = 1, \dots, N\}$ olmak üzere bazı belirleyici değerler x_1, \dots, x_M elenerek ve y baz alınarak kalan değişkenler ile tahmin yapılır. (Breiman, 1995, p. 373)

Örneğin DNA'yı baz alırsak, boyutu 96 olmasına rağmen 4000 boyut taşır. Bu gibi durumlarda regresyon ya da sınıflandırma yapabilmek için tahmini verilerin içerisinde bir altküme çıkarırız. p tane veri içerisinde k tane alt veriyi seçeriz.

Alt küme seçimi iki nedenden dolayı kullanışlıdır. Bunlar varyans indirgeme ve basitleştirme. Bilindiği üzere her farklı katsayı tahmini regresyon denkleminin varyansına eklenir. Daha az tahmin edilecek katsayı daha az varyansa işaret eder. Fakat çok az değişken kullanımı ise yanılmayı artırır (Breiman, 1995: 373).

Regresyonda alt küme seçiminin amaçları; değişken sayılarını azaltarak maliyeti azaltmak, daha doğru tahmin geliştirebilmek için bilgilendirici olmayan değişkenleri kaldırmak, çok değişkenli veri setini sıkı bir şekilde açıklamak, regresyon katsayılarını standart hatayı en aza indirgeyerek tahmin etmektir (Miller, 1984: 390).

Regresyon alt küme seçimi stratejilerini şu aşamalara bölerek rahatlıkla kategorize edebiliriz. Tahmin edilecek ve olası tahminleyicilere karar vererek bir veri seti içerisinde toplanır. Veriye uyacak değişkenleri alt kümelerini belirlenir. Kaç farklı tahminleyici kullanılacağına karar vererek bir durdurma komutu belirlenir. Regresyon katsayısı tahmin edilir (Miller, 1984: 390).

Regresyonda alt küme seçiminde üç farklı yaygın ve ucuz metod söz konusudur. Bunlar, ileri seçim, geri eleme ve kademeli regresyon prosedürü metodlarıdır (Miller, 1984: 392).

- **İleri Seçim Metodu;**

İleri seçim metodunda herhangi bir girdi değişkeni olmadan başlayarak, her seferinde bir değişken ekleyerek devam edilir. Regresyon denklemine eklenen bu değişkenin denklemin R^2 değerine (denkleme uyumluluk oranı ya da determinasyon katsayısı – coefficient of determination-) en fazla katkısı olan değerden seçilmeye çalışılır. Eşdeğer olarak, seçilen girdi değişkeninin t istatistikleri için en küçük p değerini (ayarlama parametresi, seçim aşamasında durulması gereken noktayı gösterir yani p değeri beş ile sınırlandırılmışsa beş değer seçilerek işlem yapılır) alması gerekir (Fomby, 2008: 3). Bu metotta dışarı çıkarılan değişken tekrar içeri alınmaz ve içeri alınan değişken tekrar içeri alınmaz. Bir başka deyişle bu metod dışarıda önemli bir değişken kalmayana kadar sisteme değişken eklemeye devam eder (Ratner, 2003: 4). İleri seçim metodu yoğun olarak sosyal bilimler alanında kullanılır (Das, Kempe, 2008: 48).

- **Geri Eleme Metodu;**

Geri eleme metodunda ise tüm girdi değişkenleri ile başlanarak her aşamada R^2 'yi en az aşağı çekecek değerler regresyondan çıkarılır. Eşdeğer olarak en büyük p değerinin t istatistikleri için kalması sağlanır (Fomby, 2008: 4). Bu metotta da dışarı çıkarılan değişken tekrar içeri alınmaz ve içeri alınan değişken tekrar içeri alınamaz.

- **Kademeli Regresyon Prosedürü;**

Bu metot ileri seçim ve geri eleme metotlarına benzemektedir. Fakat bir kere içeri girdi mi artık içeridesin ve bir kere dışarı çıktın mı artık dışarıdasın kuralı uygulanmaz. Bu durumdan ötürü değişkenler alınıp tekrar atılabilir ve hatta alınıp atılan bir değişken tekrar geri de alınabilir. Bu alma ve atma işlemleri dışarıda istatistiksel olarak önemli bir değişken kalmayana kadar devam edilir (Fomby, 2008: 4).

2.10.2. Regresyon Ağaçları

Ağaç metotlarının amacı, veriyi en uygun hale gelene kadar tekrarlayan bir şekilde parçalara ayırmaktır (Gordon, 2013: 1). Ayrıca bu parçalanmalar sonucunda ortaya çıkacak hedef veriyi mümkün olduğunca homojen hale getirmek ve aynı zamanda ağacı makul derecede küçük tutmaya çalışmaktır. Bu parçalama işlemi tamamlandıktan sonra ağaç budanarak istenilen boyuta getirilir (De'Ath, Fabricus, 2000: 3178). Ağaç modelleri gözlemlerin gruplar halinde sınıflandırılmaları ve bu sınıflandırılmaların puanlandırılmaları ile oluşturulurlar. Ağaçlar genellikle regresyon (karşılık değişkenleri sürekli) ve sınıflandırma (karşılık değişkeni sayısal ayrık ya da nitel – kategorik) olmak üzere ikiye ayrılırlar (Trnka, 2010: 450).

2.11. Kümelenme

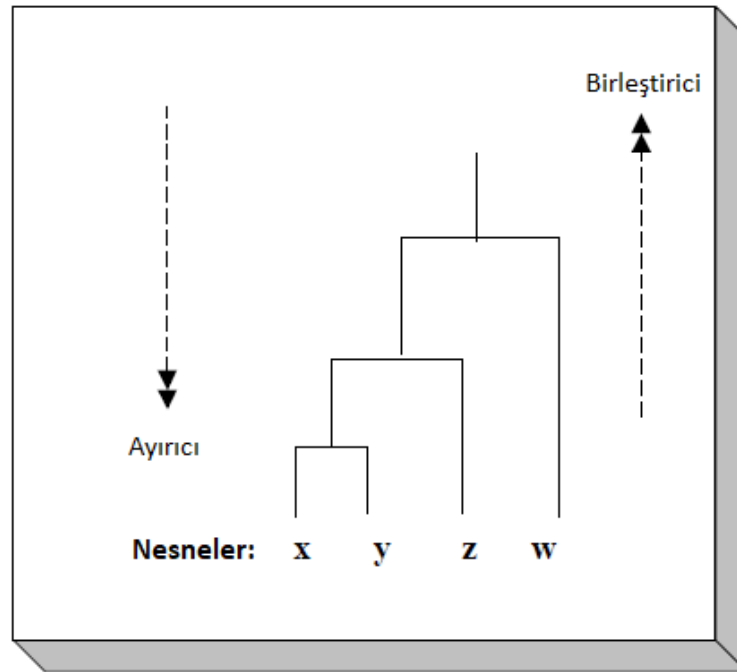
Kümeleme, adından da anlaşılacağı üzere verileri benzer daha küçük bölümlere ayırarak işlenmesini kolaylaştırmaya çalışan bir sistemdir. Bunu yaparken bazı ayrıntılar kaybedilirken karşılığında basitleştirme elde edilir. Kümelenme yapısı itibariyle denetimsiz öğrenme tekniğidir. Kümelenme algoritması yüksek miktardaki veri noktalarını daha küçük gruplar haline getirirken, aynı özellikteki veri noktalarını aynı küme içerisine yerleştirir (Rajagopal, 2011: 3). Veri madenciliği içerisinde kümelenme belki de en önemli araçlardan biridir. Çünkü yapısı itibariyle gerek keşif gerekse doğrulama analizlerinde kullanılabilirler (Trivedi, Pardos, Sarközy, Heffernan, 2011: 129). Bu işlem birçok veri madenciliği görevinde; denetimsiz sınıflandırma ve veri toplama, büyük heterojen veri kümelerini daha küçük homojen alt kümelerine ayırarak, kolay yönetmek, ayrı olarak modellemek ve analiz etmek için gereklidir (Huang, 1997: 34).

1854'te Londra'da meydana gelen kolera salgınında, John Snow hastaların evlerini işaretlediği özel bir harita kullanıyordu. Bu haritanın asıl amacı hastaların yoğunluklu olarak nerede ikamet ettiklerini belirlemektir. Yapılan bu harita sonucunda hastaların çoğunun merkez sokakta bulunan kuyu civarında oturdukları tespit edilmiş ve bu kuyunun kapatılması ile salgın sona ermiştir. Oluşturulan bu harita kümelenme analizlerinin ilki olarak kabul edilir. O zamandan beri kümelenme analizi istatistik, yazılım mühendisliği, biyoloji, psikoloji ve diğer sosyal bilimler alanlarında kullanılmaktadır (Andritsos, 2002: 1).

Kümelenme teknikleri temel olarak beşe ayrılır. Bunlar, hiyerarşik metodlar, bölümlendirme metodları, ızgara tabanlı, kategorik verinin birlikte gerçekleşmesine dayalı metodlar ve değişken bazlı metodlardır.

- **Hiyerarşik Metodlar;**

Hiyerarşik algoritmalar nesnelere ayrıştırırlar. Bu iki metotla olur. Bunlar; aşağıdan yukarıya (agglomerative) veya yukarıdan aşağıya (divisive) olarak ikiye ayrılır. Aşağıdan yukarıya olan sistemde öncelikle her nesne ayrı ayrı kümelerine ayrılarak mesafe ölçümüne dayalı gruplara ayrılır. Bundan sonra aşağıdan başlanarak kullanıcının isteğine bağlı olarak gruplandırılır (Şekil 24). Yukarıdan aşağıya olan sistemde ise bunun tam tersi bir strateji uygulanır. Bu sistemde bir tek gruptan başlanarak daha küçük gruplara ayrılarak daha küçük kümelere ayrılırlar (Andritsos, 2002: 8, 9).



Şekil 24. Hiyerarşik Algoritmalar (Andritsos, 2002: 9)

- **Bölümlendirme Metotları;**

Bölümlendirme metotları bölüm yeniden yerleştirme metodu, olasılıksal kümeleme (probabilistic clustering), k-medoid metodu, k-anlamli (k-means) metot ve yoğunluk bazli bölme metotları olmak üzere beşe ayrılmaktadır.

Bölüm yeniden yerleştirme metodu veriyi birkaç alt kümeye ayırır. Çünkü olabilecek tüm alt kümeleri incelenmek sayısal olarak mümkün olmamakla beraber, belirli açgözlü (greedy) sezgiseller yenilemeli optimizasyonun şekil almasını sağlar. Bu şu manaya gelmektedir, tekrar yerleştirme planları, tekrarlayarak noktaları k kümeleri arasına yerleştirir. Geleneksel hiyerarşik metotların aksine, kümeler oluşturulduktan sonra tekrar ziyaret edilmezler. Tekrar yerleştirme algoritmaları kümeleri giderek artan bir şekilde geliştirirler (Berkhin, 2002: 12).

Olasılıksal yaklaşımda veri, birden çok olasılıksal dağılımın karıştırılması ile oluşan birden çok modelden oluşur (Berkhin, 2002: 13).

K-medoid metodu ve k-anlamli metodun ikisinde aynı temel üzerinde çalışır. Bu iki algoritma veri setlerini gruplar halinde parçalayarak oluşan kümeler içerisinde yer alan veri noktalarının birbirine mümkün olduğunca yakın olmasını sağlamaya çalışırlar.

K-medoid metodunda seçilen noktayı merkez olarak kabul ederek kümelendirmeyi bunun üzerinde şekillendirir. Buna bağlı olarak küme içerisinde yer alan noktalardan biri ile temsil edilir.

K-anlamli algoritmada ise n adet veri nesnesinden oluşan veri setini girdi parametresi olarak verilen k adet kümeyle bölümlenmektedir. Bu işlem sonucunda elde edilen kümelerin birbiri ile maksimum farklı olması ve kendi içerlerinde bu farklılığın minimum olması amaçlanır (Han, Kamber, 2006: 402). K-anlamli algoritma kümelendirme algoritmaları arasında en çok kullanılan algoritmalarından biridir. K-anlamli kümelerin algoritma yapısı dört aşamadan oluşmaktadır.

İlk olarak küme merkezleri belirlenir. Bunun için iki farklı yol izlenir. Birinci yol nesnelere arasından küme sayısı olarak rastgele nokta seçilmesidir. İkinci yol ise merkez noktaların tüm nesnelere ortalaması alınarak belirlenmesidir.

İkinci olarak her nesnenin seçilen merkez noktalara olan uzaklığı hesaplanır. Elde edilen sonuçlara göre tüm nesnelere k adet kümeden kendilerine en yakın olan kümeyle yerleştirilir.

Üçüncü olarak oluşan kümelerin yeni merkez noktaları o kümedeki tüm nesnelere ortalama değeri ile değiştirilir.

Dördüncü ve son olarak ise merkez noktalar değişmeyene kadar ikinci ve üçüncü aşamalar tekrarlanır.

Gelişigüzel şekilli kümelerin keşfedilmesi ile birlikte yoğunluk bazlı algoritmaların (density-based algorithms) geliştirilmesine olanak sağlanmıştır. Bu yöntem genellikle noktaların yoğun olarak bulunduğu bölgeleri baz alarak bir yoğunluk haritası oluşturur (Han, Kamber, 2006: 418). Bu haritalar daha çok fiziki haritalara benzer. Kümelendirme metotları; ızgara tabanlı kümeleme metotları, kategorik verinin birlikte gerçekleşmesi ve değişken bazlı kümeleme metotları olmak üzere üçe ayrılır.

- **Izgara Tabanlı Kümeleme Metotları (Grid-Based Methods);**

Izgara tabanlı kümeleme yaklaşımı ızgara veri yapısı üzerinde çok çözünürlüklü yaklaşım kullanır. Yöntem obje uzayı üzerindeki sonlu sayılı hücreleri bir ızgara yapısı olarak şekillendirir ve oluşan bu şekil üzerinde kümelendirme işlemini gerçekleştirir (Han, Kamber, 2006: 424). Sistem veriyi ızgara şeklinde parçalayarak her ızgara haline getirerek işler ve kümelendirmeyi bu işlem sonucunda yapar.

- **Kategorik Verinin Birlikte Gerçekleşmesi (Co-Occurrence of Categorical Data);**

Kategorik veri olarak adlandırılan veri metrik olarak ölçülemeyen ve sıralanamayan veridir. Araba markalarının isimleri ya da üretilen eşya isimleri bunlara örnek olarak verilebilir (Gibson, Kleinberg, Raghavan, 1998: 311). Bu verileri kümelendirmek için mozaığe benzeyen bir yapı oluşturularak bunun üzerinde değişkenlerin ağırlıklarına bağlı olarak sınıflandırma yapılır.

- **Değişken-Bazlı Kümeleme (Constraint-Based Clustering);**

Değişken bazlı kümeleme analizlerinin amacı kümelendirme işlemine yol göstermektir. Eğer kümelendirme görevi yüksek boyutlu bir düzlemde gerçekleşiyorsa bunlardan anlamlı küme çıkarımı yapmak oldukça zor olacaktır. Birçok uygulamada kümeleme seçenekleri ve değişkenler gerektirir. Bu bilgilere örnek olarak kümenin minimum ya da maksimum boyutu, farklı objelerin ağırlıkları ya da boyutları ve diğer istenen kümelerin karakteristik özellikleri verilebilir. Kullanıcı; önemli boyutlarda ya da

istenilen sonuçlar için gerekli girişleri yaparak ve ipuçlarını vererek etkili sonuçlar alabilir (Han, Kamber, 2006: 444).

2.12. Boyut Azaltma (Dimensionality Reduction)

Çoğu veri madenciliği tekniği tek başına yüksek boyutlu veriye karşı etkili çözümler sunamamaktadır. Bu sorunun çözümü ise var olan yüksek boyutlu verinin azaltılmasına bir başka deyişle indirgenmesine bağlıdır (Danubianu, Pentiu, Danubianu, 2012: 824).

Boyut azaltmada veri kodlama ve dönüştürme teknikleri uygulanarak orijinal verinin azaltılmış veya sıkıştırılmış şekline ulaşılır. Eğer orijinal veri sıkıştırılmış veriden hiçbir kayba uğramaksızın tekrar inşa edilebilirse bu azaltma kayıpsız olarak tanımlanır. Eğer tekrar inşa sonucunda veri kaybı olursa kayıplı denir. Dizi sıkıştırma için birçok iyi ayarlanmış algoritma vardır. Fakat bunlar tipik olarak kayıpsız olmasına rağmen veri üzerinde limitli etkisi vardır (Han, Kamber, 2006: 76).

Veri indirgeme ya da boyut azaltma iki yolla olur bunlardan birincisi özellik çıkarımı diğeri ise özellik seçimidir.

Özellik çıkarımı orijinal verinin özelliklerinden yeni özellik çıkarımı yapma temeli üzerine kuruludur (Dash, Liu, 2009: 958). Özellik seçimi mümkün olduğunda fazla gereksiz ve alakasız özelliği belirleyerek madencilik görevini de dikkate alarak yok etmeyi hedefler. Bunu yaparken de filtreleme (filters) veya balyalama (wrappers) olmak üzere iki farklı yaklaşımı kullanır. Filtreleme seçilen özellik üzerinde bırakacağı ve genel performans üzerindeki etkisini dikkate almaz. Balyalama ise feed-back kullanıcılardan gelen geri dönüşüm üzerinde özellik seçimini ayarlar. Bu nedenden dolayı balyalar kullanım açısından daha iyi sonuçlar verir ve daha çok tercih edilir.

Gen haritası yapısının araştırılması, görüntü işleme, istatistiksel öğrenme ve metin dosyalarının veri madenciliği yönünden incelenmesi boyut azaltmaya örnek olarak verilebilir.

ÜÇÜNCÜ BÖLÜM

3. VERİ MADENCİLİĞİ: YAPAY SİNİR AĞI VE DOĞRUSAL REGRESYON YÖNTEMLERİNİN İKİNCİ EL ARAÇ PIYASASININ TAHMİNİ ÜZERİNE UYGULANMASI

3.1.Uygulamanın Tanıtımı: İkinci El Araç Alımı

İkinci el araç alışı ve satışı özellikle tüketicilerin ilk tercihleri olmasa da ikinci el araçların fiyatlarının sıfır kilometre araçlara nazaran daha ucuz olması, daha az vergi yükü içermesi nedeniyle rağbet görmektedir. Özellikle ülkemizde son getirilen vergi artırımları ile beraber kullanıcıların sıfır kilometre araçlara olan erişimlerinin olumsuz yönde etkilenmesi ile beraber ikinci el araçlara olan talebin artacağı yönünde tahminde bulunmak hiç de zor olmayacaktır.

Yüksek vergi oranları; sıfır kilometre araç alacak olan kullanıcıların ulaşabildikleri araçların daha düşük kaliteli, daha düşük donanıma sahip, daha düşük güvenlik standartlarına sahip olmasına neden olabilecektir. Bu sebeplerden ötürü alıcıların daha düşük model yılına sahip; fakat daha güvenli, daha donanımlı ve almak istedikleri marka ve modellerdeki araçları almalarına olanak sağlayacak bir esnek yapıya sahip olduğu için ikinci el piyasasının tercih edilmesi mümkün olmaktadır.

Buradaki yegâne problem; araçlarını satacak kullanıcıların eskiye göre yeni araç satın alabilmek için sattıkları aracın üzerine daha fazla para ekleyerek sattıkları aracın muadilini alacak olmalarıdır. Bu da ikinci el araç satış fiyatlarını etkileyecektir.

3.1.1. İkinci El Araç Fiyat Tahmini İle İlgili Çalışmalar

Son yirmi yıl boyunca piyasalarda çok önemli gelişmeler meydana gelmiştir. Güçlü iletişim ve e-ticaret alanları yatırımcıların faaliyet alanını önemli düzeyde arttırmıştır. İnternetin gelişmesine ve verilerin artmasına paralel olarak son yıllarda bu konudaki çalışmalarda artış gözlenmiştir. Bu konuda veri madenciliği teknikleri ile yapılmış başlıca çalışmalara baktığımızda, Purohit (1992) çalışmasında, sıfır ve ikinci el araç piyasasını inceleyen bir araştırmada kesitsel zaman serileri ve regresyon kullanmıştır. Kuiper (2008) çoklu regresyon modeli ile General Motors'a ait olan araçların fiyatlarını tahmin etmeye çalışmıştır. Listiani (2009) yüksek lisans tezindeki çalışmasında, destek vektör makinaları ile kiralanan araçların fiyatlarını tahmin etmeye çalışmıştır. Yine Du, Xie ve Schroeder (2009) araç açık arttırma sistemi oluşturmuş; bu sistemde üç ayrı metodu (en yakın komşu, doğrusal regresyon ve zaman serisi analizi) kombine etmiş ve optimizasyon için

de genetik algoritmaları kullanmışlardır. Oprea (2011) doğrusal regresyon ve karar ağacı yöntemlerini kullanarak tahmin yapmaya çalışmıştır. Ho, Romano ve Wu (2012) çalışmalarında araç fiyatlarını karar ağacı ve naif bayes algoritmaları kullanarak tahmin etmeye çalışmışlardır. Vob ve Lessman (2013) topluluk seçimi (ensemble selection) metodolojisi ile arabaların tekrar satılma fiyatlarını tahmin etmeye çalışmışlardır. Pudaruth (2014) ikinci el araç fiyatlarını hesaplamak için doğrusal regresyon, k en yakın komşu metodu, naif bayes ve karar ağacı algoritmalarını kullanarak ikinci el araç fiyatlarını tahmin etmeye çalışmışlardır. Bu tahmin sonuçları tahmini fiyatlarının birbirine yakın olduğunu göstermiştir. Fakat; karar ağacı ve naif bayes algoritmalarının sayısal değerleri sınıflandıramadığı görülmüştür. Peerun, Chummun ve Pudaruth (2015) yapay sinir ağı yöntemini kullanarak ikinci el araç fiyatlarını tahmin etmeye çalışmışlardır. Lin (2015) doktora tezinde fonksiyonel veri analizi ve zaman serileri ile araba fiyatlarını tahmin etmeye çalışmıştır. Ayrıca birçok web portalı bu konu üzerinde çalışma yürütmüş ve yürütmeye devam etmektedir.

3.1.2. Uygulamanın Önemi

Bu uygulama ile ikinci el araç fiyatları tahmin edilmeye çalışılmış ve bu tahminler ışığında araç alacak olan kişi için maksimum kâr elde etmeye çalışılmış ve zaman kaybının minimuma indirgenmesi hedeflenmiştir.

3.1.3. Uygulamanın Amacı

Bu uygulamanın amacı veri madenciliği tekniklerinden sınıflandırma algoritması içerisinde yer alan yapay sinir ağı (multilayer perceptron) ile doğrusal regresyon (linear regression) yöntemleri ile fiyat tahmini yapmaktır. Bununla birlikte ikinci el araç piyasası hakkında bir fikir sahibi olmaktır. Son olarak yapılan bu fiyat tahminlerini karşılaştırarak aradaki farklılıkları incelemek ve hem alıcı hemde satıcı açısından maksimum kâr sağlayarak, zaman kaybını minimuma indirmeye çalışmaktır.

3.1.4. Uygulamanın Kapsamı

Bu uygulamanın kapsamı hurriyetoto.com web sitesinden 14.12.2016 tarihinde alınan; 25.08.2010 – 13.12.2016 tarihlerini kapsayan veriler ile ikinci el araç piyasası hakkında tahmin yürütmektir. Burada dikkat edilmesi gerek nokta; 14.12.2016 tarihinde alınan bu verilere satılan araçlar dahil olmamakla beraber sadece aktif bulunan ilanlar dahildir. Örneklem uzayı büyüklüğü 31.098 adetten oluşmaktadır. Uygulamada kullanılan tüm veriler, Ek-1’de yer almaktadır. Kullanılan değişkenler 11 tane olmak

üzere bunlar; marka, model, model yılı, kasa tipi, vites tipi, renk, garanti durumu, kilometre, yakıt tipi, araç kapı sayısı ve fiyattır.

3.1.5. Uygulamanın Yöntemi

Bu uygulamada doğrusal regresyon ve yapay sinir ağları yöntemlerini kullanarak; weka paket programı üzerinde bir karşılaştırma yapılmıştır. Bu karşılaştırma sonucunda çıkan korelasyon değerleri, ortalama mutlak hata ve ortalama mutlak yüzde hatalar ile birlikte ikinci el araç fiyatları değerlendirilmiştir.

Gerçekleştirdiğimiz bu uygulama Weka paket programı üzerinde çalışmakta olup; uygulamada kullanılan bilgisayarın sistem özellikleri intel i7-6700HQ işlemci 1TB 7200 rpm hard disk ve 16gb DDR4 ram'e sahiptir. Kullanılan program sürümü Weka 3.7'dir. Bu program Yeni Zelanda Wakaito Üniversitesi tarafından geliştirilmiş olup; java platformu üzerinde çalışmakta ve bedava olarak dağıtımına sunulmakta olan bir programdır. Ayrıca en yoğun olarak kullanılan genel kullanıma sunulmuş veri madenciliği uygulamalarından biridir. Bu uygulama ilk geliştirilmeye başlandığı zaman hedef; tarımsal uygulamalar üzerinde çalışmalar yürütmektir. Sonrasında birçok alanda da kullanılmıştır. Weka ismini Yeni Zelanda da yaşayan uçamayan bir kuş türünden almaktadır.

Weka paket programı arff (attribute-relation file format) adlı dosya uzantısını kullanmakla beraber; bunun haricinde başlıcaları csv, xls, xlsx uzantılı excel dosyaları, m uzantılı matlab dosyaları olmak üzere birçok dosya uzantısı da kullanabilmektedir. Bir arff dosyasının görünümü şekil 25'teki gibidir. Program hakkında daha ayrıntılı bilgi için <http://www.cs.waikato.ac.nz/ml/weka/> adresine bakılabilir.

```

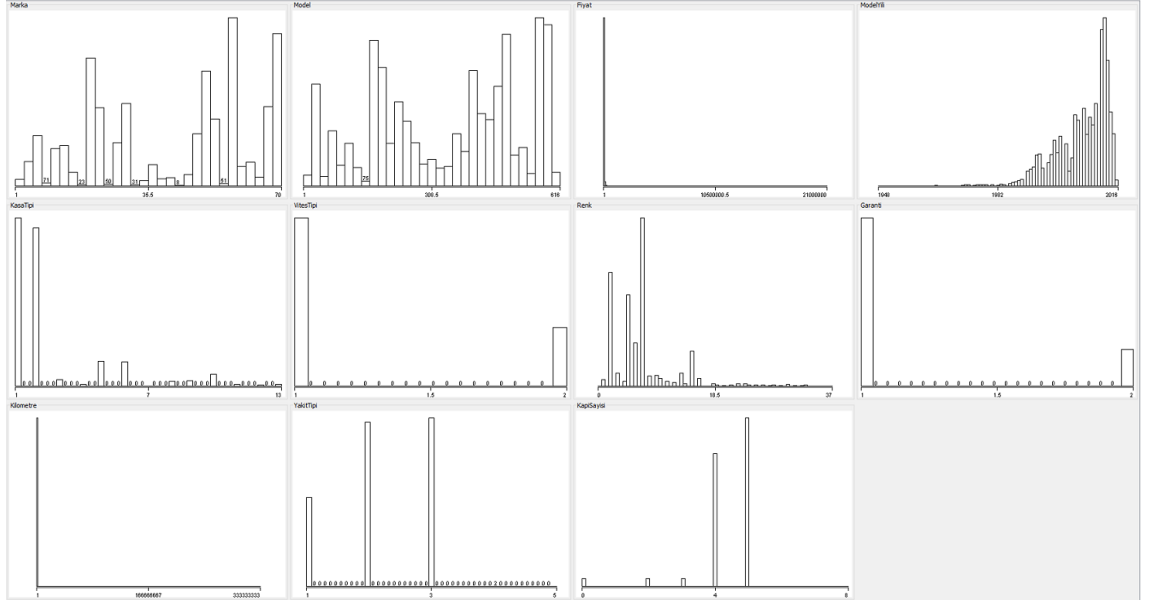
1 @relation WekaExcel
2
3 @attribute Marka numeric
4 @attribute Model numeric
5 @attribute Fiyat numeric
6 @attribute ModelYili numeric
7 @attribute KasaTipi numeric
8 @attribute VitesTipi numeric
9 @attribute Renk numeric
10 @attribute Garanti numeric
11 @attribute Kilometre numeric
12 @attribute YakıtTipi numeric
13 @attribute KapiSayisi numeric
14
15 @data
16 1,1,1700000,2003,1,1,1,1,199200,2,4
17 2,2,13250,1996,2,1,2,1,195000,2,3
18 2,2,11500,1995,2,1,3,1,238000,1,3
19 2,2,17750,2001,2,1,4,1,168000,1,3
20 2,2,11500,1996,2,1,5,1,235400,2,3
21 2,2,11500,1998,2,1,5,1,139400,2,3
22 2,2,10000,1998,2,1,5,1,147000,1,3
23 2,2,12250,1999,2,1,6,1,120000,2,3
24 2,2,14000,2000,2,1,2,1,192000,2,3
25 2,3,13850,1996,2,1,7,1,194000,2,5
26 2,3,11000,1998,2,1,5,1,265000,2,5
27 2,3,14000,1996,2,1,1,1,198000,1,5
28 2,3,12500,1998,2,1,7,1,178000,2,5

```

Şekil 25. Arff Dosya Görünümü

3.2.Verilerin Weka Programına Yüklenmesi

Weka programını çalıştırdıktan sonra ve Explorer sekmesine girdikten sonra “Preprocess” ön hazırlık modülü üzerinde “open file” seçeneğine basarak veriler yüklenir. Aynı panel kullanılarak verilerin bir ön görünümünü elde edilir. Bu panel üzerinden gereksiz görülen veriler filtrelenebilmekte ya da silinebilmektedir. Ayrıca değişkenlerin kümülatif istatistikleri de burada görülebilmektedir (Bkz Şekil 26).



Şekil 26. Kümülatif Görselleştirmeler

Kaydet seçeneğine bastıktan sonra elde edilen arff dosyası Şekil 26’da görüldüğü gibi olmaktadır.

3.3.İkinci El Araç Alımı İçin Hurriyetoto.com Örneği

Kullanılan örneklem uzayında yer alan araçlar; hurriyetoto.com adresinden alınmıştır. Bu veriler 14.12.2016 tarihinde alınmış olup; 25.08.2010 – 13.12.2016 tarihlerini kapsamaktadır. Burada dikkat edilmesi gerek nokta; 14.12.2016 tarihinde alınan bu verilere satılan araçlar dahil olmamakla beraber sadece aktif bulunan ilanlar dahildir. Örneklem uzayı büyüklüğü 31.098 adetten oluşmaktadır.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	Marka	Model	Seri	Fiyat	Model Yılı	Kasa Tipi	Vites Tipi	Renk	Garanti	İlan Tarihi	Kilometre	Yakit Tipi	Kapı Sayısı	
2	Acura	CL	3.2 Type-S	1700000	2003	Sedan	Manuel	Bordo	Hayır	20.11.2016	199200	Benzin	4	
3	Alfa Romeo		145	13250	1996	Hatchback	Manuel	Gri	Hayır	30.08.2016	195000	Benzin	3	
4	Alfa Romeo		145 1.7 16V	11500	1995	Hatchback	Manuel	Metallik gri	Hayır	21.08.2016	238000	Benzin + LPG	3	
5	Alfa Romeo		145 1.6 TS Sportivo	17750	2001	Hatchback	Manuel	Lacivert	Hayır	16.06.2016	168000	Benzin + LPG	3	
6	Alfa Romeo		145 1.7 16V	11500	1996	Hatchback	Manuel	Siyah	Hayır	13.03.2016	235400	Benzin	3	
7	Alfa Romeo		145 1.4 TS STD.	11500	1998	Hatchback	Manuel	Siyah	Hayır	25.03.2015	139400	Benzin	3	
8	Alfa Romeo		145 1.4 TS STD.	10000	1998	Hatchback	Manuel	Siyah	Hayır	1.12.2014	147000	Benzin + LPG	3	
9	Alfa Romeo		145 1.4 TS STD.	12250	1999	Hatchback	Manuel	Kırmızı	Hayır	3.01.2014	120000	Benzin	3	
10	Alfa Romeo		145 1.6 TS L	14000	2000	Hatchback	Manuel	Gri	Hayır	17.10.2016	192000	Benzin	3	
11	Alfa Romeo		146 1.6 L	13850	1996	Hatchback	Manuel	Beyaz	Hayır	6.11.2016	194000	Benzin	5	

Şekil 27. Örneklem Uzayının Görünümü

Öncelikle veri üzerinde temizleme yapmak gerekmektedir. Örnek olarak Şekil 27’de üçüncü satırda yer alan “1.Haz” “1.6” olmakla beraber; excel programının nokta ayırıcını otomatik metin düzenlemede tarih olarak görmektedir. Bu işlemi gerçekleştirebilmek için excel programında ilgili satırı tıklayıp; giriş menüsü üzerinde yer alan hücre biçimlendirme menüsünden hücre biçimini metin olarak gösterdikten sonra gereken değer hücreye tekrar yazılması gerekir.

Bilinmeyen değerler için yer alan “-“ değerlerinin ise yok edilmesi tercih edilmiştir. Veri temizleme işlemlerini gerçekleştirdikten sonra örneklem uzayının; 30.570 adete düştüğü gözlemlenmiştir. Son durumda örneklemin yetmiş adet marka, altı yüz on altı adet model, dört bin sekiz yüz elli model serisi, on üç kasa tipi, iki vites tipi, otuz yedi renk, iki garanti durumu ve beş yakıt tipi içerdiği gözlenmiştir. Fakat model seri sayısının çok fazla olması nedeniyle; hesaplama performansını etkilememek ve sürecin hızlandırılmasını sağlamak açısından model serisine bakılmaksızın fiyatların hesaplanmasının çeşitli fiyatlandırma hesaplamaları açısından daha iyi olabileceği kanaati ile model serisi hanesi silinmiştir.

Yapılan bu işlemler sonucunda; bir sonraki aşama olan verinin sayısallaştırılması aşamasına geçilmiştir. Çünkü gerek yapay sinir ağları gerekse regresyon modelleri sayısal veriler üzerinde çalışabilmektedir. Bu aşamada sırasıyla; markalar, modeller, araç kasa tipleri, vites tipleri, araç renkleri, araçta garanti olup olmama durumu ve araçlarda kullanılan yakıt tipleri sayısallaştırılmıştır.

	A	B	C
1	Acura	1	
2	Alfa_Romeo	2	
3	Aro	3	
4	Audi	4	
5	BMC	5	
6	BMW	6	
7	Bentley	7	
8	Buick	8	
9	Cadillac	9	
10	Chery	10	
11	Chevrolet	11	
12	Chrysler	12	
13	Citroen	13	
14	DFM	14	
15	Dacia	15	
	•		
	•		
	•		

Şekil 28. Markaların Sayısallaştırılması


Şekil 28’de markaların sayısallaştırılması görülmektedir. Markalar birden başlatılarak, yetmiş kadar sayısallaştırılmıştır. Bu şekilde uygulamada kullanılan diğer değişkenler de teker teker sayısallaştırılmıştır. Ayrıca vites tipi değişkeninde markaların

kendi patentlerini taşıyan farklı isimlerle adlandırılan otomatik viteslerine verdikleri özel isimler (triptonik, cvt, ...vb) otomatik başlığı altında toplanarak birliktelik sağlanmıştır.

3.4.İkinci El Piyasasında Satışa Sunulan Araçların İstatistikleri Verileri

Satılan ikinci el araçların marka olarak dağılımları; %13.3 Renault, %10.2 Fiat, %8.6 Volkswagen, %6.9 Opel, %6.6 Hyundai, %6.2 Ford, %6.2 Tofaş, %5.3 Peugeot, %4 BMW, %3.4 Honda, %3.3 Mercedes, %3.2 Citroen, %2.9 Toyota, %2.8 Chevrolet, %2.3 Nissan, %2 Geely, %1.8 Skoda, %1.5 Seat ve %1.2 diğer markalardır. Ayrıca %1.5 ten küçük olan diğer markalar da dahil edildiğinde diğer markaların yüzde cinsinden oranı on ikilere varmaktadır. (Bkz: Şekil 29)

Marka İstatistikleri



Şekil 29. Marka İstatistikleri

İkinci el piyasasında en çok yer alan ilk yirmi araç modeli ise Şekil 29'daki gibidir.


Tablo 5. En çok satışta bulunan ikinci el araç modelleri

Sıra	Marka	Model	Adet	Sıra	Marka	Model	Adet
1	Opel	Astra	1366	11	BMW	3 Serisi	585

2	Renault	Megane	1072	12	Tofaş	Doğan	554
3	Renault	Clio	962	13	Renault	Symbol	476
4	Tofaş	Şahin	939	14	Fiat	Fiorino	427
5	Volkswagen	Polo	846	15	BMW	5 Serisi	350
6	Ford	Fiesta	839	16	Tofaş	Kartal	342
7	Fiat	Linea	822	17	Hyundai	Accent	337
8	Honda	Civic	769	18	Opel	Vectra	332
9	Volkswagen	Golf	700	19	Ford	Tourneo	329
10	Volkswagen	Jetta	604	20	Peugeot	206	323
Toplam:				12974			


Tablo 5'te de görüleceği üzere ilk yirmi aracın veri tabanında yer alan tüm araçlara oranı %42 civarındadır.

Araç renklerinin %30,3'ü beyaz, %20,4'ü gri, %16,5'i siyah, %7,8'i kırmızı, %6,3'ü mavi, %2,4'ü gümüş, %2,4'ü metalik gri, %1,9'u yeşil, %1,8'i bej, %1,2'si bordo, %0,8'i lacivert rengindedir. Beyaz ve beyaza yakın olan gri, metalik gri renklerinin piyasanın %50'sinden fazlasına hâkim olduğu görülmektedir. Özellikle beyaz tonlarının araçta yer alan çizikleri göstermemesine yönelik olan genel kanının bu konu üzerinde etkili olduğu düşünülmektedir. (Bkz: Şekil 30)



Şekil 30. Renk İstatistikleri

İnternet sitesinde ilan edilen ikinci el araçların model yıllarına göre dağılımı Şekil 31'deki gibidir. Özellikle 2011 – 2012 yıllarında en üst düzeye ulaşan ilan sayısı sonrasında düşmeye başlamıştır.



Şekil 31. Yıllara göre dağılım grafiği

3.5.Sınıflandırma İşleminin Gerçekleştirilmesi

Veriyi yerleştirip gerekiyorsa temizleme işlemini gerçekleştirdikten sonra; sınıflandırıcı (classifier) seçimi menüsünden kullanılmak istenen algoritma seçilir. Algoritma seçiminden sonra bu örneklem uzayının çalışma veri seti olarak kullanılması için “use training set” seçimi uygulanarak ve bulunması istenen değişken fiyat seçilerek start tuşuna basılır. Bu şekilde sınıflandırma işlemi gerçekleştirilmiş olur.

3.6.Doğrusal Regresyon Uygulamasının Gerçekleştirilmesi

Sınıflandırıcı seçimi üzerinde yer alan fonksiyonlar sekmesi içerisinde bulunan “LinearRegression” algoritması seçildikten sonra işleme başlanır.

Gerçekleştirilen bu işlemin ilk kısmı Şekil 32’deki gibidir. Bu kısımda modelin çalışma verileri gösterilmektedir. İlk olarak çalışma şemasında yöntemin kullanıldığı algoritma gösterilmektedir. Görüldüğü üzere weka programında sınıflandırıcı sekmesindeki fonksiyonların altında yer alan linearregression algoritmasının kullanıldığı ortaya konulmuştur. İkinci olarak ilişki olarak hangi dosyayı kullandığı, üçüncü olarak örneklem sayısı, dördüncü olarak değişken sayısı ve son olarak test modunun nasıl işlendiği gösterilmiştir.

```
=== Run information ===

Scheme:      weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4
Relation:    WekaExcel
Instances:   30570
Attributes:  11
             Marka
             Model
             Fiyat
             ModelYili
             KasaTipi
             VitesTipi
             Renk
             Garanti
             Kilometre
             YakitTipi
             KapiSayisi
Test mode:   evaluate on training data
```

Şekil 32. Doğrusal Regresyon Birinci Kısım

İkinci kısımda ise sınıflandırıcının modeli gösterilmiş olup; değişkenlerin fiyat üzerindeki ağırlıklandırmaları gösterilmektedir. Bir aracın fiyatı hesaplanıyorsa Şekil 33’te gösterildiği gibi değişkenler ağırlıkları ile çarpıldıktan sonra toplanarak yaklaşık fiyat hesaplaması yapılabilir. En sonda ise modelin ne kadar sürede oluşturulduğu gösterilmektedir.

```
=== Classifier model (full training set) ===
```

```
Linear Regression Model
```

```
Fiyat =
```

```
2051.7748 * Marka +  
-252.5435 * Model +  
1196.3787 * ModelYili +  
23263.5725 * VitesTipi +  
11410.0762 * Garanti +  
2651.3356 * YakitTipi +  
-4254.0971 * KapiSayisi +  
-2386451.784
```

```
Time taken to build model: 0.23 seconds
```

Şekil 33. Sınıflandırıcı Modeli

Şekil 34'te ise çalışma seti üzerindeki geliştirmenin ne kadar süre aldığı gösterilmektedir.

```
=== Evaluation on training set ===
```

```
Time taken to test model on training data: 0.06 seconds
```

Şekil 34. Çalışma seti üzerinde geliştirme

Şekil 35'te ise sonuç kısmı yer almaktadır. Bu kısımda; ise doğruluk değerleri ve standart sapmalar gösterilmektedir. Önemli olan kısım korelasyon katsayısıdır. Bu da 0.0981 değeri olarak bulunmuştur.

```
=== Summary ===
```

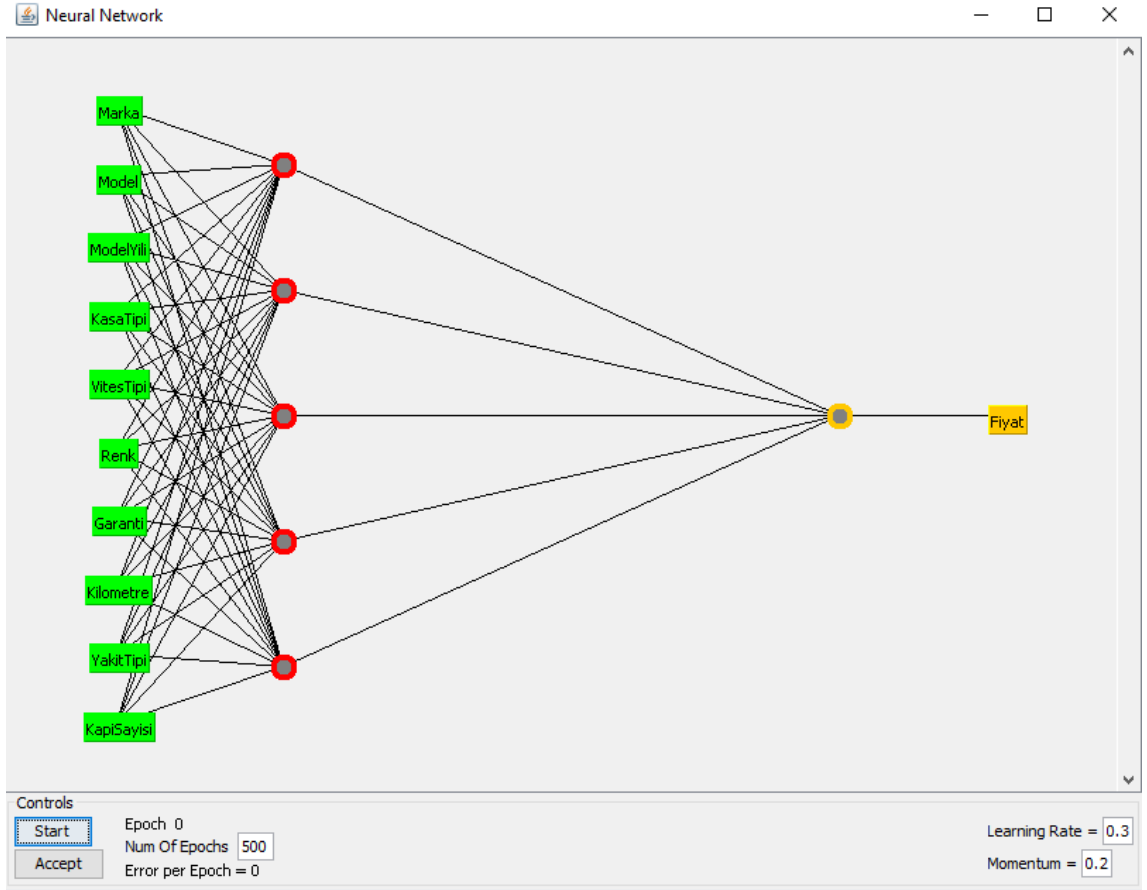
Correlation coefficient	0.0981
Mean absolute error	17964.7609
Root mean squared error	178544.098
Relative absolute error	73.8808 %
Root relative squared error	99.5176 %
Total Number of Instances	30570

Şekil 35. Sonuç Kısmı

3.7.Yapay Sinir Ağı Uygulamasının Gerçekleştirilmesi

Yapay sinir ağı uygulaması da doğrusal regresyon gibi programsal açıdan aynı süreçlerden geçmekle beraber; ekstra olarak yapay sinir ağının görselleştirilmesi de mümkündür. Sınıflandırıcının seçim alanında uygulama yönteminin üzerine tıklayarak

grafik ara yüzünün değerini true olarak değiştirilmesi gerekmektedir. Bu değişiklik sonucunda algoritmanın çalıştırılması ile birlikte şekil 36'daki gibi bir yapay sinir ağı haritası ortaya çıkmaktadır. Şekil 36'da görüldüğü üzere bu yapı girdi katmanı, gizli katman ve çıktı katmanından oluşmaktadır. Eğer istenirse yine algoritma isminin üzerine tıklayarak gizli katmanın daha fazla katmanlara ayrılması sağlanabilir. Bu işlem sonucunda algoritmanın tamamlanacağı süre ve gereken bilgisayar donanımı giderek artacaktır.



Şekil 36. Yapay Sinir Ağının Görselleştirilmesi

Şekil 36'daki işlemi gerçekleştirmek için start tuşuna basıp algoritmanın işlenmesini bekledikten sonra accept tuşuna basmak gerekmektedir. Bu işlem sigmoid aktivasyon fonksiyonu ile yürütülmekte ve ağırlıklandırılmış değerlerin test edilmesi ile birlikte beş ayrı işlem olarak gerçekleştirilmektedir. Sigmoid fonksiyonu yapay nöronlar için kullanılan bir aktivasyon fonksiyonudur. Bu fonksiyon; $\frac{1}{1+e^{-x}}$ şeklindedir.

```

=== Classifier model (full training set) ===

Linear Node 0
  Inputs  Weights
  Threshold -0.9988739029933433
  Node 1 -0.26275650103757253
  Node 2 -0.07426411462442568
  Node 3 0.29861770708861396
  Node 4 0.2758250631532984
  Node 5 -0.22917751951554471

Sigmoid Node 1
  Inputs  Weights
  Threshold -1.0603444076277193
  Attrib Marka -0.36184672797340267
  Attrib Model 0.11151503112361197
  Attrib ModelYili -0.6140544087650348
  Attrib KasaTipi 0.3149680735957536
  Attrib VitesTipi 0.6010849216703539
  Attrib Renk 0.5134790606255698
  Attrib Garanti 0.3214870459942336
  Attrib Kilometre 1.0253698358248038
  Attrib YakitTipi 0.26140192860403394
  Attrib KapiSayisi 0.2634401962437779

Sigmoid Node 2
  Inputs  Weights
  Threshold -1.0504568242245456
  Attrib Marka -0.2745206906523782
  Attrib Model -0.04615961105295603
  Attrib ModelYili -0.6302155089496425
  Attrib KasaTipi 0.605884425618834
  Attrib VitesTipi 0.46271358901769777
  Attrib Renk 0.5522562052769263
  Attrib Garanti 0.27618434429475647
  Attrib Kilometre 1.0472381744218258
  Attrib YakitTipi 0.37985078877202966
  Attrib KapiSayisi 0.036876563877122896

Sigmoid Node 3
  Inputs  Weights
  Threshold -1.1487214891126207
  Attrib Marka 0.1549341916626605
  Attrib Model -0.44884453658246876
  Attrib ModelYili 0.07833580014857626
  Attrib KasaTipi 0.4142382175091831
  Attrib VitesTipi 0.5842831535921709
  Attrib Renk 0.4159924306923524
  Attrib Garanti 0.23566855791359229
  Attrib Kilometre 1.1054102446020497
  Attrib YakitTipi 0.4931246990943562
  Attrib KapiSayisi 0.03328000481022873

Sigmoid Node 4
  Inputs  Weights
  Threshold -1.0125937876472606
  Attrib Marka -0.10984388441252935
  Attrib Model -0.24536203172952145
  Attrib ModelYili -0.906990115799158
  Attrib KasaTipi 0.7058142640726925
  Attrib VitesTipi 0.34586223198203797
  Attrib Renk 0.706723335502938
  Attrib Garanti 0.40198576067358743
  Attrib Kilometre 1.0161698367738448
  Attrib YakitTipi 0.14874966625817018
  Attrib KapiSayisi -0.1542416116831001

Sigmoid Node 5
  Inputs  Weights
  Threshold -1.01638899794818
  Attrib Marka -0.32084827272474614
  Attrib Model -0.05148157920117656
  Attrib ModelYili -0.5269379655067352
  Attrib KasaTipi 0.7484064969815863
  Attrib VitesTipi 0.38222829976445666
  Attrib Renk 0.5490628464135034
  Attrib Garanti 0.2467898581291054
  Attrib Kilometre 1.0397391577003308
  Attrib YakitTipi 0.6079443598957224
  Attrib KapiSayisi -0.14784208254084946

Class
  Input
  Node 0

```

Şekil 37. Sınıflandırıcı Model

Yapay sinir ağı (multilayer perceptron) algoritması ileri beslemeli bir ağ olarak çalışmaktadır. Elle müdahalede bulunulmadığı müddetçe girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Bu ağlar doğrusal olarak modellenemeyen problemlerin çözümünde kullanılmaktadır. Elle müdahale ile ekstra gizli katmanlar eklenebilir. Şekil 37’de yapay sinir ağından elde edilmiş olan sigmoid düğümleri görülmektedir. En son değer doğruluğu en yüksek olan değer olmakla birlikte doğrusal regresyondaki gibi değişkenlerin bu değerlerle çarpılıp toplanması sonucunda istenilen fiyat değeri bulunur.

=== Summary ===

Correlation coefficient	0.111
Mean absolute error	16759.8411
Root mean squared error	178436.013
Relative absolute error	68.9255 %
Root relative squared error	99.4574 %
Total Number of Instances	30570

Şekil 38. Sonuç kısmı

Sonuç olarak Şekil 38’de yapay sinir ağı istatistikleri görülmektedir. Korelasyonun düşük olması, elde edilen tahmin değerleri ile gerçek değerler arasında doğrusal bir ilişkinin olmadığını göstermektedir. Tüm marka ve modellere ait araçların bir arada bulunması ve özellikle yüksek fiyatlı araçların aykırı bir değer gibi diğer araçların fiyatlarının üzerinde kayda değer etkiye sahip olmasındandır. Bu aykırı değerler nedeni ile korelasyon katsayısı düşük çıkmaktadır. Bu nedenle; korelasyon katsayısının yükseltilebilmesi ve daha tutarlı sonuçlar elde edilebilmesi için her marka ve model aracı kendi içerisinde gruplandırıp inceleyeceğiz.

3.8.Elde Edilen Verilerin Modeller Üzerine İşlenmesi

Elde edilen verilerin modeller üzerine işlenebilmesi için; veri içerisinde homojen gruplar oluşturuldu. Çünkü veriler toplu halde işlendiğinde sağlıklı bir değerlendirme ve kabul edilebilir bir korelasyon katsayısı elde edilememekteydi. Bu homojen grupları oluşturabilmek için veriyi araç modellerini temel alarak sınıflandırma tercih edilmiştir. Çünkü araç fiyatlarını etkileyen en temel faktörler aracın markası ve modelidir. Araç fiyatları üzerinde doğrudan etkisi olan marka değerinin yanı sıra kendi içerisinde sınıflara (segmentlere) ayrılan modellerin değer farklılıkları da önem taşımaktadır. Bu sebepten veri seti araç modellerine göre parçalanmış ve kendi içlerinde değerlendirmeye alınmıştır.

Bu değerlendirme için veri seti yetmiş marka ve altı yüz on altı modele sahip olduğu için altı yüz on altı parçaya ayrılmıştır.

Bu çalışmada öncelikli olarak ikinci el araç piyasasında yer alan ve en çok satılan yirmi model aracın, doğrusal regresyon ve yapay sinir ağları yöntemleri ile fiyatları tahmin edilmiş ve bu yöntemlerin performansları karşılaştırılarak en düşük hata miktarı ile tahminleri veren yöntem tespit edilmiştir.

Tablo 5’te görüldüğü üzere ikinci el araç piyasasında yer alan araçlardan en yüksek ilan miktarına sahip olan araçlar; Opel Astra, Renault Megane, Renault Clio, Tofaş Şahin, Volkswagen Polo, Ford Fiesta, Fiat Linea, Honda Civic, Volkswagen Golf, Volkswagen Jetta, BMW 3 Serisi, Tofaş Doğan, Renault Symbol, Fiat Fiorino, BMW 5 Serisi, Tofaş Kartal, Hyundai Accent, Opel Vectra, Ford Tourneo ve Peugeot 206 olarak geçmektedir.

Sırayla bu araçların fiyatları Weka üzerinde analiz edilerek hem doğrusal regresyon ve yapay sinir ağları yöntemleri ile elde edilen tahminlerin performanslarının karşılaştırılması; hem de örneklem hacminin yapılan tahminlerin başarısı üzerindeki etkisinin görülmesi hedeflenmektedir.

Tablo 6. Korelasyon Performanslarının Karşılaştırılması

Sıra	Marka	Model	Orijinal Veri Seti			Temizlenmiş Veri Seti		
			Örneklem Adedi	DR Korelasyon	YSA Korelasyon	Örneklem Adedi	DR Korelasyon	YSA Korelasyon
1	Opel	Astra	1366	0.9044	0.9372	1360	0.9043	0.9401
2	Renault	Megane	1072	0.9027	0.9419	1058	0.9077	0.9471
3	Renault	Clio	962	0.8881	0.9292	947	0.8938	0.9316
4	Tofaş	Şahin	939	0.3658	0.3539	891	0.6267	0.6305
5	Volkswagen	Polo	846	0.9391	0.9562	836	0.9393	0.956
6	Ford	Fiesta	839	0.8876	0.9091	835	0.8992	0.9178
7	Fiat	Linea	822	0.7535	0.8022	813	0.8224	0.8363
8	Honda	Civic	769	0.8871	0.8986	754	0.9505	0.9711
9	Volkswagen	Golf	700	0.9264	0.9696	689	0.9267	0.9692
10	Volkswagen	Jetta	604	0.8255	0.8604	595	0.8502	0.8912
11	BMW	3 Serisi	585	0.9089	0.9613	572	0.9114	0.9508
12	Tofaş	Doğan	554	0.0961	0.0955	517	0.7902	0.8062
13	Renault	Symbol	476	0.8459	0.9036	474	0.8512	0.9111
14	Fiat	Fiorino	427	0.1798	0.3218	409	0.8087	0.8363
15	BMW	5 Serisi	350	0.8597	0.9028	331	0.911	0.9755
16	Tofaş	Kartal	342	0	0.0615	302	0.7761	0.8009
17	Hyundai	Accent	337	0.6759	0.8268	326	0.6964	0.8474
18	Opel	Vectra	332	0.8888	0.9108	325	0.9199	0.9351
19	Ford	Tourneo	329	0.9106	0.9329	325	0.9115	0.9338
20	Peugeot	206	323	0.5611	0.6949	322	0.6023	0.6999

Öncelikle veri üzerindeki aykırı değerlerin gözle kontrolü yapılmış ve bu değerler silinmiştir. Bu işlem sonucunda Tablo 6’da görüldüğü üzere genel olarak performans iyileştirmeleri sağlanmıştır. Bundan sonraki analizler temizlenmiş veri seti üzerinde

gerçekleştirilmiştir. Çünkü aykırı değerler tahminlerin sapmalı olarak elde edilmesine neden olduğundan; Tablo 6’da on altıncı satırda yer alan Tofaş markasına ait Kartal modelli araçlarda doğruluk sıfıra inecek ve doğru analiz gerçekleştirilemeyecektir. Ayrıca yapılan diğer analizlerde aykırı değerler fiyat tahminlendirmesini olumsuz etkileyecek ve kimi araçlarda sürekli aynı fiyatı verecek döngüler oluşturacaktır.


Tablo 7. Ortalama Mutlak Hata ve Mutlak Hata Yüzdelerinin Karşılaştırılması

Marka	Model	Örnek Adedi	Ortalama Mutlak Hata DR (MAE)	Ortalama Mutlak Hata Yüzdeleri (MAPE)	Ortalama Mutlak Hata YSA (MAE)	Ortalama Mutlak Hata YSA (MAPE)
Opel	Astra	1366	4456	0.121	3729	0.100
Renault	Megane	1072	3709	0.125	3116	0.112
Renault	Clio	962	3626	0.171	2906	0.141
Tofaş	Şahin	939	1539	0.194	1529	0.186
Volkswagen	Polo	846	3268	0.108	3133	0.113
Ford	Fiesta	839	3142	0.101	3606	0.118
Fiat	Linea	822	2590	0.110	3377	0.140
Honda	Civic	769	3977	0.118	3395	0.105
Volkswagen	Golf	700	5769	0.150	4257	0.098
Volkswagen	Jetta	604	5139	0.100	7745	0.155
BMW	3 Serisi	585	12246	0.282	11037	0.260
Tofaş	Doğan	554	1373	0.156	1328	0.149
Renault	Symbol	476	2560	0.096	2016	0.078
Fiat	Fiorino	427	2717	0.149	4278	0.184
BMW	5 Serisi	350	20595	0.432	18820	0.364
Tofaş	Kartal	342	1398	0.165	1334	0.153
Hyundai	Accent	337	2737	0.147	2927	0.154
Opel	Vectra	332	2394	0.116	2356	0.118
Ford	Tourneo	329	3421	0.109	4352	0.155
Peugeot	206	323	2235	0.112	2241	0.104

Tablo 7’de doğrusal regresyon (DR) ve yapay sinir ağları (YSA) yöntemleri ile elde edilen tahminler için ortalama mutlak hata (mean absolute error) ve ortalama mutlak yüzde hata (mean absolute percentage error) değerleri hesaplanarak gösterilmiştir. Görüldüğü üzere yapay sinir ağları için hesaplanmış olan ortalama mutlak hata değerleri ve ortalama mutlak yüzde hata değerleri genel olarak daha iyi sonuç vermiştir. Ele alınan değerlerden 14 tanesi yapay sinir ağında daha iyi sonuç vermiş; 6’sında ise doğrusal regresyon daha iyi sonuç vermiştir. Bu değerleri yorumlayacak olursak Opel marka Astra


model aracın tahmin edilen fiyatlar ile ilan edilen fiyatlar arasında doğrusal regresyon yöntemi için ortalama 4456 TL ve %12 sapmakta iken bu değerler yapay sinir ağı yöntemi için 3729 TL ve %10'dur. Tablo 7'de en iyi sonuç veren araç ise ortalama mutlak hata açısından Tofaş Doğan iken; ortalama mutlak yüzde hata olarak Renault Symbol'dür. Ortalama mutlak hata $\frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j|$ formülünden; ortalama mutlak yüzde hata ise $\frac{100}{N} \times \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|$ formülünden elde edilmiştir.

Örnek sayısı olarak en çok örneğe sahip olan araç Opel Astra incelenirse; bu aracın toplam 1366 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 6 adet aykırı değer tespit edilerek silinmiş ve örnek sayısı 1360'a düşürülmüştür.




Şekil 39. Opel Astra Tahmin Genel Görünümü

Fiyat tahminleri Şekil 39'da görüldüğü gibi olacaktır. Yine görüldüğü üzere bu şekilde inceleme yapılabilmesi pek mümkün olmadığından ilk 20 örneği incelersek kullanıcı tarafından anlaşılması daha kolay olacaktır.



Şekil 40. Opel Astra Tahmin Daraltılmış Görünüm

Şekil 40'ta görüldüğü üzere örnekler çoğunlukla ilan edilen fiyatla paralel olarak ilerlemiş olmakla beraber; dördüncü örnekte bir sapma görülmektedir. İlan edilen fiyatlar ile tahmin edilen fiyat farklılıklarına bakacak olursak;



Şekil 41. Opel Astra Fiyat Farkı Görünümü

Şekil 41'de daha iyi gözlemlenebilmesi amacıyla sıfır noktası aracın ilan edildiği fiyat olarak baz alınmıştır. Bu işlem sonucunda ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahminin sapma miktarının) değişim aralığının yaklaşık 5000 TL olduğu görülmektedir. Dört numaralı örnekte fiyat farkının çok yüksek olduğu görülmektedir.

Tablo 8. Opel Astra Yıllara Göre Fiyat Tahmini


Opel Astra Model Yılı	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1992	12700	12700	3691	3691	8694	8694

1993	9000	14750	1601	8897	8732	10817
1994	12000	18500	1869	18895	9029	13159
1995	13500	15750	7972	19578	10970	15572
1996	14000	19700	7808	18750	11062	17629
1997	13000	21250	9586	20402	8922	17132
1998	13000	25000	14532	26711	14941	19489
1999	12350	30000	16317	23254	14997	20515
2000	17750	29750	10362	27123	13670	24913
2001	14750	35500	17182	31393	18125	26209
2002	21500	33750	21914	29367	20375	26287
2003	16900	28500	23777	29569	19356	28154
2004	19500	38750	23610	34928	24713	31486
2005	23500	36500	26539	37361	26697	33195
2006	20850	39500	29293	39271	27929	33941
2007	24500	42500	28317	40455	22735	35857
2008	22500	43777	32850	43216	30157	37620
2009	26750	45000	34995	46125	32966	40804
2010	23750	52250	38016	47225	35851	44607
2011	32000	61250	40296	51467	31973	49767
2012	34500	88000	42882	54912	40631	57147
2013	37750	67500	47011	57622	39540	59915
2014	41500	88000	48727	59593	47838	63820
2015	40900	78500	52632	60877	49853	73020
2016	56500	92000	56150	64418	53192	85089

Tablo 8’de ise Opel Astra marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1992 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 4456 TL ve ortalama mutlak yüzde hata %12,1, yapay sinir ağı için ortalama mutlak hata 3729 TL ve ortalama mutlak yüzde hata %10’dur. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 2010 model bir araç alacak olan kişinin 35851 TL ile 44607 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2013 için 39540 TL ile 59915 TL arasında; 2016 için 53192 TL ile 85089 TL arasındadır.


İkinci en çok satışta bulunan araç olan Renault Megane için bu grafikleri incelediğimizde bu aracın toplam 1072 örneğe sahip olduğu görülmüştür. Verinin grafiği

oluşturularak gözlemlenen değişim aralığının dışında kalan 14 aykırı değer tespit edilerek silinmiş ve örnek sayısı 1058'e düşürülmüştür.



Şekil 42. Renault Megane Tahmin Daraltılmış Görünüm

Bir sonraki araç olan Renault Megane marka ve model aracı inceleyecek olursak Şekil 42’de görüldüğü üzere ilan edilen fiyat ile tahmin edilen fiyatlar arasında çok büyük sapmaların olmadığı görülmektedir.



Şekil 43. Renault Megane Fiyat Farkı Görünümü

Şekil 43’te görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık yaklaşık 10.000 TL ye kadar çıktığı görülmektedir.


Tablo 9. Renault Megane Yıllara Göre Fiyat Tahmini

Renault Megane	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1998	8500	20000	9470	17436	13817	20260
1999	10750	24700	11326	20528	14713	21948

2000	14000	24750	13120	23626	18421	24036
2001	14000	28550	15915	28574	19820	26741
2002	14750	26000	16987	26523	22570	26074
2003	16750	29900	16872	29647	22570	29119
2004	19000	32750	17382	32390	25122	30304
2005	10000	34500	20729	32757	23486	30178
2006	21000	38000	22297	37924	27103	40736
2007	20750	41500	23978	37421	28096	35254
2008	22500	39000	28785	42501	24868	36020
2009	25100	45000	29939	41362	30349	41146
2010	26750	49000	35565	45161	34598	45910
2011	25000	79500	31387	50408	30132	59606
2012	31900	67500	39183	54730	39584	63641
2013	37900	65000	46063	53826	44667	59017
2014	47000	74900	49679	56735	45982	69370
2015	50000	82000	50339	58939	48700	73560
2016	75250	77500	59373	59632	71864	76394


Tablo 9’da ise Renault Megane marka ve model araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1998 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 3709 TL ve ortalama mutlak yüzde hata %12,5, yapay sinir ağı için ortalama mutlak hata 3116 TL ve ortalama mutlak yüzde hata %11,2’dir. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani 2002 model bir araç alacak olan kişinin 22570TL ile 26074 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2006 için 27103 TL ile 40736 TL arasında; 2010 için 34598 TL ile 45910 TL arasındadır.

Bir sonraki araç olan Renault Clio marka ve model aracı inceleyecek olursak bu aracın toplam 962 örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 15 aykırı değer tespit edilerek silinmiş ve örnek boyutu 947’ye düşürülmüştür. Bu iyileştirmeler sonucunda yapılan incelemede;



Şekil 44. Renault Clio Tahmin Daraltılmış Görünüm

Şekil 44'de görüldüğü gibi yine birbirine oldukça yakın sonuçlar ortaya çıkmıştır. İlan edilen araç fiyatları ile tahmin edilen fiyatların fark görünümüne bakacak olursak;



Şekil 45. Renault Clio Fiyat Farkı Görünümü

Şekil 45'te görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 15.000 TL ye kadar çıktığı görülmektedir.


Tablo 10. Renault Clio Yıllara Göre Fiyat Tahmini

Renault Clio	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1993	10000	10000	2205	2205	10697	10697
1996	12000	15800	8749	10189	10775	13396
1997	9900	16500	7169	16382	12548	18166
1998	10750	18750	9239	16862	13171	19435
1999	15000	22000	10022	22105	13424	21542
2000	12000	24250	12162	23042	15425	20954

2001	13000	24750	8899	24322	16147	20959
2002	15800	24500	15784	25154	16352	23159
2003	14000	29750	14097	23412	15068	22775
2004	12000	30250	19201	27839	18179	23653
2005	16750	26500	19805	28201	19649	24577
2006	1000	29500	19990	31022	16692	27973
2007	15500	36000	12006	29074	18081	27992
2008	19500	32000	25272	33908	21868	31626
2009	20000	36500	27710	36366	25508	33152
2010	16000	39150	30015	39054	24057	35812
2011	21250	43500	31605	41876	26166	38770
2012	26250	53000	32698	41101	28948	42124
2013	10000	53750	35716	46958	34171	51992
2014	33000	54500	37110	47564	36515	53235
2015	3000	63000	38626	50236	37822	59674
2016	49750	65500	46468	51307	52804	64111


Tablo 10’da ise Renault Clio markalı araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1993 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 3626 TL ve ortalama mutlak yüzde hata %17,1, yapay sinir ağı için ortalama mutlak hata 2906 TL ve ortalama mutlak hata %14,1’dir. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani 1998 model bir araç alacak olan kişinin 13171 TL ile 19435 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2008 için 21868 TL ile 31626 TL arasında; 2011 için 26166 TL ile 38770 TL arasındadır.

Bir sonraki araç olan Tofaş Şahin marka ve model aracı inceleyecek olursak bu aracın toplam 939 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 48 aykırı değer tespit edilerek silinmiş ve örnek adeti 891’e düşürülmüştür.



Şekil 46. Tofaş Şahin Daraltılmış Görünüm

Şekil 46'da görüldüğü üzere tahmin fiyatı ile ilan fiyatı arasında çoğunlukla düzensiz bir fark olduğu gözlenmektedir. Fiyat farkı görünümüne bakacak olursak;



Şekil 47. Tofaş Şahin Fiyat Farkı Görünümü

Şekil 47'de görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 4.000 TL ye ulaştığı görülmektedir.


Tablo 11. Tofaş Şahin Yıllara Göre Fiyat Tahmini

Tofaş Şahin Model Yılı	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1978	2750	2750	722	722	3133	3133
1979	2600	4800	2949	2972	3918	3939
1980	11750	11750	2989	2989	3503	3503
1983	2750	6500	3143	4747	3565	4379
1984	1750	4500	3195	5110	3933	4467
1985	4000	4500	3657	5461	2801	4027
1986	2700	8500	4187	5510	3498	5014

1987	1500	8000	4575	6488	2380	5779
1988	3700	6850	5128	6730	4721	6052
1989	3000	12900	3409	7233	4003	6697
1990	2600	9950	5935	7851	4258	7508
1991	4500	30000	6411	8261	5833	8308
1992	3900	11250	6883	8642	6415	8575
1993	4500	20000	5533	9133	5188	9177
1994	4750	20000	5065	9532	4825	9624
1995	4999	16500	8109	9912	8159	9950
1996	7000	14750	8833	10213	8895	10246
1997	7200	15000	9279	10642	9567	10549
1998	7000	14750	9731	11190	9960	10772
1999	7000	15250	10581	11528	9621	11005
2000	7250	15500	10728	11960	10566	11167
2001	8000	19750	11135	12406	10921	11270
2002	10000	13500	11602	12674	11103	11335


Tablo 11’de ise Tofaş Şahin marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1992 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 1539 TL ve ortalama mutlak yüzde hata %19,4, yapay sinir ağı için ortalama mutlak hata 1529 TL ve ortalama mutlak yüzde hata %18,6’dır. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani 1988 model bir araç alacak olan kişinin 4721 TL ile 6052 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işleme 1995 için 8159 TL ile 9950 TL arasında; 2000 için 10566 TL ile 11167 TL arasındadır.

Bir sonraki araç olan Volkswagen Polo marka ve model aracı inceleyecek olursak bu aracın toplam adet 846 örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 10 aykırı değer tespit edilerek silinmiş ve örnek adeti 836’ya düşürülmüştür.



Şekil 48. Volkswagen Polo Daraltılmış Görünüm

Şekil 48’de görüldüğü üzere genel olarak fiyat ile tahmin değerleri birbiri ile paralel ilerlemektedir. Fark görünümüne bakacak olursak;



Şekil 49. Volkswagen Polo Fiyat Farkı Görünümü

Şekil 49’da görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 10.000 TL ye kadar ulaştığı görülmektedir.


Tablo 12. Volkswagen Polo Yıllara Göre Fiyat Tahmini

Volkswagen Polo Model Yılı	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1989	19000	19000	1565	1565	14936	14936
1995	12500	14950	8238	11990	16877	17252
1996	8950	16500	9682	18190	12209	18704
1997	9250	21000	11617	21785	12380	23723
1998	9750	21500	11470	23767	15739	25707

1999	13500	22500	14642	25127	19064	23060
2000	14500	29500	15967	28458	19734	26950
2001	14200	27750	17191	28281	20808	26879
2002	19800	24500	20553	23595	23790	25210
2003	19500	26500	22446	24976	23876	25418
2004	21450	35300	20132	34132	24737	36317
2005	23000	35750	24189	35258	24308	33484
2006	22500	37500	25337	37777	27742	35663
2007	22500	33950	29682	37197	30345	35291
2008	25500	38500	29067	39232	31439	37063
2009	26000	43000	32942	42894	32856	40858
2010	26000	46500	33372	45552	33984	44514
2011	26750	53000	34267	46561	35319	49617
2012	14000	67000	37388	50049	35721	54874
2013	33500	57900	39870	51630	38918	56718
2014	37650	62000	42224	53154	42665	60073
2015	38500	65000	45707	55070	46230	63294
2016	42000	66900	47174	55544	49282	63714


Tablo 12’de ise Volkswagen Polo marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1989 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 3268 TL ve ortalama mutlak yüzde hata %10,8, yapay sinir ağı için ortalama mutlak hata 3133 TL ve ortalama mutlak yüzde hata %11,3’tür. Tablo 6’daki korelasyon değerlerini de inceleyecek olursak; doğrusal regresyonun korelasyon değeri 0,9393 çıkarken, yapay sinir ağının korelasyon değeri 0,956 çıkmıştır. Bu değerleri de göz önüne alarak yapay sinir ağının daha iyi sonuç verdiği söylenebilir. Çünkü elde edilen tahminlerin değişkenliğinden ve araç fiyatlarının değişim aralığının geniş olmasından kaynaklı olarak ortalama mutlak yüzde hatada sapma meydana gelebilir. Bu bilgiler ışığında 2000 model bir araç alacak olan kişinin 19734 TL ile 26950 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2005 için 24308 TL ile 33484 TL arasında; 2015 için 46230 TL ile 63294 TL arasındadır.

Bir sonraki aracımız Ford Fiesta’ya marka ve model aracı inceleyecek olursak; bu aracın toplam 839 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 3 adet aykırı değer tespit edilerek silinmiş ve örnek boyutu 836’ya düşürülmüştür.



Şekil 50. Ford Fiesta Daraltılmış Görünüm

Şekil 50’de görüldüğü üzere ilan edilen fiyatlar ile tahmini değerler arasında paralellik görülmektedir Tahmin değerleri genellikle ilan edilen fiyattan daha düşüktür. Tahmin farklılıklarına bakacak olursak;



Şekil 51. Ford Fiesta Fiyat Farkı Görünümü

Şekil 51’de görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 12.000 TL ye kadar eriştiği görülmektedir.


Tablo 13. Ford Fiesta Yıllara Göre Fiyat Tahmini

Ford Fiesta Model Yılı	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1992	9750	9750	6813	6813	5517	5517
1997	12750	26000	9489	10611	6902	10533
1998	10950	16750	9388	14355	7955	12190
1999	13500	15600	8438	14563	8730	11064
2000	12250	17500	10587	15668	9003	12654

2001	15350	21500	10855	18998	10381	13182
2002	18750	18750	14960	14960	12445	12445
2003	19250	26000	16766	23001	15341	20657
2004	16250	27500	18166	26651	13858	21566
2005	13000	29000	18655	27657	13706	23343
2006	14470	35000	15455	30999	10395	28620
2007	15250	30000	13937	31451	8175	24730
2008	17000	32000	16934	32678	12243	29153
2009	25750	39750	28212	36587	22699	32340
2010	23750	41500	27838	38143	26176	35957
2011	23900	44900	31884	40104	24380	37916
2012	28250	49000	31967	42919	29756	42358
2013	28000	52400	34914	45491	32419	46916
2014	36700	53000	40914	46960	37029	50552
2015	20000	57500	42478	48560	36714	53045
2016	45000	60500	46749	48496	47120	56001


Tablo 13'te ise Ford Fiesta marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1992 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7'yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 3142 TL ve ortalama mutlak yüzde hata %10,8, yapay sinir ağı için ortalama mutlak hata 3606 TL ve ortalama mutlak yüzde hata %11,8'dir. Araç alım satımında daha az sapma ve hata yüzdesine sahip olduğu için doğrusal regresyon yöntemini kullanmak daha isabetli sonuç verecektir. Yani 2004 model bir araç alacak olan kişinin 18166 TL ile 26651 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2006 için 15455 TL ile 30999 TL arasında; 2009 için 28212 TL ile 36587 TL arasındadır.

Bir sonraki araç olan Fiat Linea marka ve model aracı inceleyecek olursak; bu aracın toplam 822 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 9 aykırı değer tespit edilerek silinmiş ve örnek adeti 813'e düşürülmüştür.



Şekil 52. Fiat Linea Tahmin Daraltılmış Görünüm

Şekil 52’de görüldüğü üzere tahmin değerleri bazı bölgelerde ilan edilen değerlerden ayrılmıştır. Tahmin farklılıklarına bakacak olursak;



Şekil 53. Fiat Linea Tahmin Daraltılmış Görünüm

Şekil 53’te görüldüğü gibi ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığı yaklaşık 8.000 TL ye varmış olup; genellikle yapay sinir ağı tahminlerinin doğrusal regresyon tahminlerine göre daha yüksek değerler tahmin ettiği görülmektedir.


Tablo 14. Fiat Linea Yıllara Göre Fiyat Tahmini

Fiat Linea	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
2007	20250	28700	18458	32760	25304	39354
2008	20750	35000	18491	42402	23160	47351
2009	21000	34500	21469	41623	25362	45816

2010	23500	41500	15091	41308	24071	46761
2011	15500	46000	21110	41489	25567	45524
2012	1200	46500	21425	42910	26131	48446
2013	24500	47300	24198	42237	27704	46395
2014	30750	58000	22659	59577	26101	63919
2015	35900	53500	21687	43082	25504	48512
2016	50000	50000	44251	44251	51017	51017


Tablo 14’te ise Fiat Linea marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 2007 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 2590 TL ve ortalama mutlak hata %11, yapay sinir ağı için ortalama mutlak hata 3377 ve ortalama mutlak hata yüzde %14’tür. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için doğrusal regresyon yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 2007 model bir araç alacak olan kişinin 18458 TL ile 32760 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üstündeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2012 için 21425 TL ile 42910 TL arasında; 2013 için 24198 TL ile 42237 TL arasındadır.

Bir sonraki araç olan Honda Civic marka ve model aracı inceleyecek olursak; bu aracın toplam 769 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 15 aykırı değer tespit edilerek silinmiş ve örnek adeti 754’e düşürülmüştür.



Şekil 54. Honda Civic Tahmin Daraltılmış Görünüm

Şekil 54'te görüldüğü üzere yapay sinir ağlarının tahmin performansı aracın ilan edilen fiyatına göre çoğu yerde doğrusal regresyondan daha yakın değerler vermiştir. Tahmin farklarına bakacak olursak;



Şekil 55. Honda Civic Fiyat Farkı Görünümü

Şekil 55'te görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığı yaklaşık 10.000 TL ye kadar ulaşmıştır.


Tablo 15. Honda Civic Yıllara Göre Fiyat Tahmini

Honda Civic Model Yılı	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1990	8500	19800	-1145	9216	10168	15084
1991	6500	12500	547	11912	13189	15573
1992	9250	14750	8070	9510	13537	16724
1993	9200	20500	5318	13099	13115	17111
1994	8500	17000	8839	16257	13219	17904
1995	11000	22000	10810	15375	14660	26141
1996	14300	19000	13181	19644	15906	19943
1997	15500	25000	12157	24369	17661	26883
1998	15000	28000	17338	26229	18683	29422
1999	15500	29250	18820	26738	20715	25932
2000	19100	28000	21878	31766	23497	29906
2001	20500	34750	23005	31301	26593	30267
2002	23000	45450	25282	33119	27419	40995
2003	23800	37750	27104	34646	30690	34636
2004	24500	41500	26609	36551	30905	36702
2005	25000	42700	32002	40626	35565	38268
2006	18750	43000	34194	43061	37786	41414

2007	29300	49000	36176	46809	38138	43947
2008	32000	72000	36506	47822	41253	63468
2009	36000	54000	42971	51167	41518	47610
2010	33000	55500	46001	54326	46759	53855
2011	40000	63500	48995	56398	42393	54559
2012	42500	68000	51627	59830	48357	62020
2013	48000	67500	53880	62630	52859	71880
2014	57950	74000	58157	63965	60259	77948
2015	60499	79000	60913	66797	69029	73679
2016	72500	83900	64309	68735	74534	75643


Tablo 15’te ise Honda Civic marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1990 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 3977 TL ve ortalama mutlak yüzde hata %11,8, yapay sinir ağı için ortalama mutlak hata 3395 ve ortalama mutlak yüzde hata %10,5’tir. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 2005 model bir araç için, 35565 TL ile 38268 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2008 için 41253 TL ile 63468 TL arasında; 2014 için 60259 TL ile 77948 TL arasındadır.

Bir sonraki araç olan Volkswagen Golf marka ve model aracı inceleyecek olursak; bu aracın toplam 700 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 11 aykırı değer tespit edilerek silinmiş ve örnek adeti 689’a düşürülmüştür.



Şekil 56. Volkswagen Golf Tahmin Daraltılmış Görünüm

Şekil 56'da görüldüğü üzere yapay sinir ağlarının vermiş olduğu tahmin değerleri ilan edilen aracın fiyatına çoğu yerde paralel olarak ilerlerken; doğrusal regresyon tahmininde gözle görülür sapmalara rastlanmıştır. Tahmin farklılıklarına bakacak olursak;



Şekil 57. Volkswagen Golf Fiyat Farkı Görünümü

Şekil 57'de ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığı yaklaşık 20.000 TL ye kadar varmaktadır. Bu değer yapay sinir ağı uygulamasında ise 10.000 TL ye varmaktadır.

Tablo 16. Volkswagen Golf Yıllara Göre Fiyat Tahmini


Volkswagen Golf	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
Model Yılı						

1979	7500	7500	-1486	-1486	4200	4200
1980	6000	6000	-11636	-11636	975	975
1981	6200	6200	-31295	-31295	1252	1252
1986	14500	14500	1063	1063	9671	9671
1987	12500	12500	3082	3082	11077	11077
1988	12500	15000	2341	11748	7207	7322
1991	14000	20000	14232	18171	10551	13325
1992	11700	16500	-1941	13605	11009	12790
1993	13000	13000	9269	9269	11596	11596
1994	13500	17500	1295	25544	11881	16512
1995	13000	13000	14811	14811	11554	11554
1996	15300	15300	11406	11406	18297	18297
1997	16500	29500	15285	19581	16307	20672
1998	17000	24000	10353	26709	15808	21155
1999	19250	29000	10398	36439	13100	25462
2000	19750	27500	15529	31361	19340	23614
2001	22000	31800	17502	30448	18380	25437
2002	23500	25700	27100	28938	23834	25002
2003	22750	31750	22737	37254	25272	28172
2004	26000	36750	26882	41993	26009	31219
2005	24750	41500	26340	44005	26821	34340
2006	26500	41000	29558	45802	29179	37782
2007	26000	43250	33327	50965	33381	42992
2008	32500	51000	34475	58419	36639	45576
2009	38500	54000	44139	55730	40810	47609
2010	34000	56000	43573	60086	43421	55633
2011	34750	63750	41701	69236	46037	70620
2012	42500	77500	44952	70657	48696	75468
2013	51500	88888	55177	73938	58559	92502
2014	55250	91500	57688	75689	62687	88722
2015	54000	94500	59717	77318	66918	95193
2016	72000	96500	68338	79217	73468	99024

Tablo 16’da ise Volkswagen Golf marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1979 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 5769 TL ve ortalama mutlak yüzde hata %15, yapay sinir ağı için ortalama mutlak hata 4257 TL ve ortalama mutlak yüzde hata %9,8’dir. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 1998 model bir araç alacak olan kişinin 15808 TL ile 21155 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır.


Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2007 için 33381 TL ile 42992 TL arasında; 2016 için 73468 TL ile 99024 TL arasındadır.

Bir sonraki araç olan Volkswagen Jetta marka ve model aracı inceleyecek olursak bu aracın toplam 604 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 9 aykırı değer tespit edilerek silinmiş ve örnek adeti 595'e düşürülmüştür.



Şekil 58. Volkswagen Jetta Tahmin Daraltılmış Görünüm

Şekil 58'de görüldüğü üzere tahmin değerleri ilan edilen fiyatlar ile gözle görülür farklılıklar taşımaktadır. Bu farklılıklara bakacak olursak;



Şekil 59. Volkswagen Jetta Fiyat Farkı Görünümü


Şekil 59’da görüldüğü üzere genel olarak yapay sinir ağları tahmin verileri doğrusal regresyona göre daha yüksek sonuçlar vermiş ve ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 15.000 TL ye kadar eriştiği görülmektedir.

Tablo 17. Volkswagen Jetta Yıllara Göre Fiyat Tahmini

Volkswagen Jetta	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1985	9500	9500	-18473	-18473	14238	14238
2006	23500	43250	7642	41314	34988	47332
2007	31500	48000	25817	45513	40571	49035
2008	26500	60400	32299	48952	37017	52379
2009	34000	52500	37797	50565	43720	53198
2010	37500	58500	36231	60009	46237	67018
2011	41000	71000	47124	70494	52300	79125
2012	40000	155000	52309	67662	57442	77451
2013	50000	86500	53015	71374	57522	82020
2014	51750	85750	60498	75759	67128	85936
2015	57250	94500	65110	100816	73131	88215
2016	66750	77250	69054	79359	79744	84165


Tablo 17’de ise Volkswagen Jetta marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1985 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 5139 TL ve ortalama mutlak yüzde hata %10, yapay sinir ağı için ortalama mutlak hata 7745 TL ve ortalama mutlak yüzde hata %15,5’dir. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için doğrusal regresyon yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 2006 model bir araç alacak olan kişinin 7642 TL ile 41314 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2009 için 37797 TL ile 50565 TL arasında; 2012 için 52309 TL ile 67662 TL arasındadır.

Bir sonraki araç olan BMW 3 Serisi marka ve model aracı inceleyecek olursak bu aracın toplam 585 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 13 aykırı değer tespit edilerek silinmiş ve örnek adeti 872’ye düşürülmüştür.



Şekil 60. BMW 3 Serisi Tahmin Daraltılmış Görünüm

Şekil 60'ta görüldüğü üzere tahmin değerleri genel olarak ilan edilen araç fiyatlarına paralel olarak ilerlemekte ve bazı bölgelerde sapmalara rastlanmaktadır. Tahmin değerleri ile ilan edilen fiyatlar arasındaki farklara bakacak olursak;



Şekil 61. BMW 3 Serisi Fiyat Farkı Görünümü

Şekil 61'de görüldüğü gibi tahmin değerleri çoğunlukla ilan edilen değerden yüksek çıkmakla birlikte; ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığı yaklaşık 30.000 TL'nin üzerine çıkmıştır.

Tablo 18. BMW 3 Serisi Yıllara Göre Fiyat Tahmini


BMW 3 Serisi	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1980	4000	12000	-7417	9539	23084	23665
1982	11500	11500	25478	25478	22191	22191

1983	16500	16500	1614	1614	22778	22778
1984	17000	19500	-19190	-22730	23657	41008
1986	16400	16400	-2819	-2819	23813	23813
1987	12500	12500	-29424	-29424	67008	67008
1988	9800	10000	-6757	-2211	23846	23858
1989	10000	11450	-4729	5179	20699	23366
1990	8200	21750	-10566	23474	20624	29188
1991	16250	24000	-3661	7769	22270	31978
1992	16500	24000	3169	34079	19817	29775
1993	15000	32000	-3689	22527	23287	30958
1994	15500	43000	1051	40458	22535	56612
1995	17000	36250	1959	35112	22603	46228
1996	15500	35000	7746	43790	22724	37440
1997	18250	34500	13607	42550	24933	40782
1998	20000	45000	22543	57426	29994	47179
1999	24000	47750	29724	50375	31422	53788
2000	28000	80000	25518	77073	28357	70419
2001	30000	140000	24110	78174	30693	61978
2002	23500	67000	30847	75428	30425	63813
2003	23000	72000	40693	63191	42427	57883
2004	23000	55000	37844	67364	43677	60486
2005	29500	57500	33670	76613	39568	65842
2006	42500	73000	39510	80975	45766	69723
2007	52500	97500	59158	88883	58974	82834
2008	20500	120000	39088	95997	50119	111474
2009	37000	120000	67166	102273	66830	129076
2010	59755	127500	72953	116304	72789	133008
2011	69500	125000	82930	111859	83583	135214
2012	59000	160000	92899	120546	98447	146552
2013	10000	162000	97082	127208	111379	158474
2014	102500	190000	103300	130822	119371	166264
2015	124750	161000	101568	126430	135929	150098

Tablo 18’de ise BMW 3 Serisi marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1980 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 12246 TL ve ortalama mutlak yüzde hata %28,2, yapay sinir ağı için ortalama mutlak hata 11037 TL ve ortalama mutlak yüzde hata %26’dır. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 1989 model bir araç alacak olan kişinin 20699 TL ile 23366 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır.


Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 1996 için 22724 TL ile 37440 TL arasında; 2013 için 111379 TL ile 158474 TL arasındadır.

Bir sonraki araç olan Tofaş Doğan marka ve model aracı inceleyecek olursak; bu aracın toplam 554 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 37 aykırı değer tespit edilerek silinmiş ve örnek adeti 517'ye düşürülmüştür.



Şekil 62. Tofaş Doğan Tahmin Daraltılmış Görünüm

Şekil 62'de görüldüğü üzere tahmin verilerinin bir kısmı ilan edilen araç fiyatından farklıdır. Fark görünümüne bakacak olursak;



Şekil 63Tofaş Doğan Fiyat Farkı Görünümü

Şekil 63'te görüldüğü üzere doğrusal regresyon tahmin verileri ve yapay sınır ağları tahmin verileri birbirine oldukça yakındır.


Tablo 19. Tofaş Doğan Yıllara Göre Fiyat Tahmini

Tofaş Doğan Model Yılı	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1982	5000	5000	1554	1554	5017	5017
1983	3750	3750	-305	-305	2427	2427
1984	6500	6500	3400	3400	5675	5675
1985	3250	7500	3594	4110	4539	5031
1986	3500	10650	4264	4931	4707	6144
1987	4250	6300	5136	5546	5396	6265
1988	3000	7700	5607	6272	4058	6520
1989	3500	7500	6287	6817	5982	6771
1990	4500	11500	6983	7559	5280	7274
1991	4500	10500	7699	8229	7209	8256
1992	6500	10750	8346	8921	6775	9001
1993	6500	11500	8274	9574	7570	9902
1994	7000	20000	9708	10200	9439	10846
1995	6500	14000	10394	10911	10189	11553
1996	8750	14900	10157	11559	9941	12070
1997	10000	22500	11920	12222	11877	12628
1998	9500	16500	12498	12875	12470	12939
1999	8750	16500	13138	13473	12868	13181
2000	11200	17750	13831	14130	13167	13300
2001	13500	15000	14629	14808	13359	13496

Tablo 19’da ise Tofaş Doğan marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1982 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle ve 2001’den itibaren üretimi sonlandırılmıştır. İlan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 1373 TL ve ortalama mutlak yüzde hata %15,6, yapay sinir ağı için ortalama mutlak hata 1328 TL ve ortalama mutlak yüzde hata %14,9’dur. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 1985 model bir araç alacak olan kişinin 4539 TL ile 5031 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 1990 için 5280 TL ile 7274 TL arasında; 1994 için 9439 TL ile 10846 TL arasındadır.


Bir sonraki araç olan Renault Symbol marka ve model aracı inceleyecek olursak; bu aracın toplam 476 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak

gözlemlenen değişim aralığının dışında kalan 2 aykırı değer tespit edilerek silinmiş ve örnek adeti 474'e düşürülmüştür.



Şekil 64. Renault Symbol Tahmin Daraltılmış Görünüm

Şekil 64'te görüldüğü üzere ilan edilen araç verileri tahmin edilen verileri arasında genellikle paralellik söz konusudur. Fiyat farklarına bakacak olursak;



Şekil 65. Renault Symbol Fiyat Farkı Görünümü

Şekil 65'te görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 8.000 TL civarında olduğu görülmektedir.


Tablo 20. Renault Symbol Yıllara Göre Fiyat Tahmini

Renault Symbol	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
Model Yılı						

1998	14200	14200	12919	12919	16726	16726
2000	9000	23000	11110	19880	17336	20677
2001	15750	19950	12978	19105	17383	20962
2002	15750	22000	16351	18306	17641	20323
2003	15500	24750	17338	19267	17364	21381
2004	16250	24000	16009	22297	17928	22876
2005	14500	26300	17641	23173	18531	23688
2006	18250	26000	14895	24660	18576	25467
2007	19280	28500	21165	27553	21260	27333
2008	18500	30000	21138	28010	20716	27249
2009	19000	32950	16099	31109	19265	33168
2010	20000	35000	23418	31346	21335	35125
2011	18750	40000	24876	31855	24469	31395
2012	14500	33000	23480	34285	22076	34088
2013	27750	44750	28089	35842	27824	38081
2014	34000	43000	31699	36617	34848	40811
2015	34750	53500	34719	38214	37577	45146
2016	39500	45250	37089	38861	43010	47213


Tablo 20’de ise Renault Symbol marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1998 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 2560 TL ve ortalama mutlak yüzde hata %9,6, yapay sinir ağı için ortalama mutlak hata 2016 TL ve ortalama mutlak yüzde hata %7,8’dur. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 2000 model bir araç alacak olan kişinin 17336 TL ile 20667 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2006 için 18576 TL ile 25467 TL arasında; 2011 için 24469 TL ile 31395 TL arasındadır.

Bir sonraki araç olan Fiat Fiorino marka ve model aracı inceleyecek olursak; bu aracın toplam 427 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 18 aykırı değer tespit edilerek silinmiş ve örnek adeti 409’a düşürülmüştür.



Şekil 66. Fiat Fiorino Tahmin Daraltılmış Görünüm

Şekil 66’da görüldüğü üzere tahmin edilen fiyat ile ilan edilen fiyatlar arasında paralellik olmasına rağmen genellikle değişken farklılıklar ortaya çıkmıştır. Tahmin farklılıklarına bakacak olursak;



Şekil 67. Fiat Fiorino Fiyat Farkı Görünümü

Şekil 67’de görüldüğü üzere doğrusal regresyon tarafından yapılan tahminler yapay sinir ağına göre daha yüksek tahmin sonuçları vermiştir.


Tablo 21. Fiat Fiorino Yıllara Göre Fiyat Tahmini

Fiat Fiorino Model Yılı	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
2008	14000	28500	16771	26339	10312	23512
2009	14500	32500	15424	36181	12513	33402
2010	12750	35000	15150	37650	10606	35314
2011	17500	35000	21665	35454	15864	31562

2012	17500	38000	20518	38135	16123	33507
2013	25500	45000	25701	37507	22493	38419
2014	1600	42750	27001	40363	24113	39032
2015	28400	48500	35670	41713	25157	40327
2016	37200	50500	40850	42015	38288	42684


Tablo 21’de ise Fiat Fiorino marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 2008 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 2717 TL ve ortalama mutlak yüzde hata %14,9, yapay sinir ağı için ortalama mutlak hata 4278 TL ve ortalama mutlak yüzde hata %18,4’dur. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için doğrusal regresyon yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 2009 model bir araç alacak olan kişinin 15424 TL ile 36181 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2012 için 20518 TL ile 38135 TL arasında; 2013 için 25701 TL ile 37507 TL arasındadır.

Bir sonraki araç olan BMW 5 Serisi marka ve model aracı inceleyecek olursak; bu aracın toplam 350 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 19 aykırı değer tespit edilerek silinmiş ve örnek adeti 331’e düşürülmüştür.



Şekil 68. BMW 5 Serisi Tahmin Daraltılmış Görünüm

Şekil 68’de görüldüğü üzere tahmin verileri genel olarak paralel olarak ilerlemiştir. İlan edilen fiyat ile tahmin edilen değerler arasındaki farka bakacak olursak;



Şekil 69. BMW 5 Serisi Fiyat Farkı Görünümü

Şekil 69’da görüldüğü üzere yapay sinir ağları genellikle daha düşük tahminler verirken doğrusal regresyon sadece üç örnekte yapay sinir ağlarından daha düşük fiyat tahmini yapmıştır.


Tablo 22. BMW 5 Serisi Yıllara Göre Fiyat Tahmini

BMW Serisi	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1982	8500	8500	-97838	-97838	-14565	-14565
1983	6500	20000	-41641	5579	-5109	83
1989	14250	15250	6442	22903	-3026	-193
1990	12500	22500	-21554	37191	-7620	1668
1991	12000	18500	-29221	35552	-12791	3154
1992	14000	15500	-6125	21679	-3219	2236
1993	10500	23500	-12406	21799	843	3970
1994	15000	23011	9656	27621	2340	6766
1995	17500	26000	6066	43416	5683	17368
1996	22250	32000	12287	31932	10117	16149
1997	24000	37000	10058	36476	11451	18324
1998	24000	39500	18938	52980	2968	21241
1999	27500	42000	7135	70667	-15177	30181
2000	29000	38250	20979	66191	15329	31899
2001	38900	50000	37722	56574	13994	35291
2002	40000	43000	43529	72842	22423	34613
2003	39999	60000	53650	75813	4850	32998
2004	56500	85000	60641	96692	10093	52489
2005	52750	75000	57819	104662	-1647	36662

2006	62500	83000	91699	113862	43592	62039
2007	32500	85000	96797	124102	41439	70039
2008	14500	113000	103137	140016	66922	85368
2009	80000	120000	117278	137845	81256	119545
2010	89900	135000	125745	143830	76558	111667
2011	126000	192500	131376	156553	112646	148242
2012	129500	285000	131865	163291	141994	179034
2013	135000	225000	150912	173168	109022	195816
2014	115750	172500	159379	169024	124354	149187
2015	160000	300000	167669	183064	155207	223160


Tablo 22’de ise BMW 5 Serisi marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1982 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 20595 TL ve ortalama mutlak yüzde hata %43,2, yapay sinir ağı için ortalama mutlak hata 18820 TL ve ortalama mutlak yüzde hata %36,4’tür. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 2001 model bir araç alacak olan kişinin 13994 TL ile 35291 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2008 için 66922 TL ile 85368 TL arasında; 2015 için 155207 TL ile 223160 TL arasındadır.

Bir sonraki araç olan Tofaş Kartal marka ve model aracı inceleyecek olursak; bu aracın toplam 342 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 40 aykırı değer tespit edilerek silinmiş ve örnek adeti 302’ye düşürülmüştür. Özellikle bu araç üzerinde yapılan veri temizliği veri ile tahmin arasındaki korelasyonu doğrusal regresyon için 0’den 0.7761’e kadar çıkarmış; yapay sinir ağı için ise 0.0615’ten 0.8009’a kadar çıkarmıştır. Bu da veri temizliğinin ne kadar önemli olduğunu göstermektedir.



Şekil 70. Tofaş Kartal Tahmin Daraltılmış Görünüm

Şekil 70’te görüldüğü üzere ilan edilen fiyat ile tahmin edilen veri arasında farklılıklar bulunmasına rağmen tahmin verileri genel olarak birbirine paralel olarak ilerlemektedir. İlan edilen araç fiyatı ile tahmin edilen fiyat arasındaki farklara bakacak olursak;



Şekil 71. Tofaş Kartal Fiyat Farkı Görünümü

Şekil 71’de ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığı yaklaşık 2.000 TL dolaylarında olmakla beraber iki tahmin verisinde bu değer 4.000 TL’ye çıkmış ve birinde de 6.000 TL dolaylarında olmuştur.


Tablo 23. Tofaş Kartal Yıllara Göre Fiyat Dağılımı

Tofaş Kartal	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
Model Yılı	Min	Max	Min	Max	Min	Max

1983	2150	2150	3049	3049	1659	1659
1987	3000	3000	6298	6298	3335	3335
1988	3900	7500	5017	6965	3401	5280
1989	4240	7750	5493	7155	4838	5700
1990	4200	10250	6624	7645	5659	6851
1991	3900	7980	6545	8079	6136	7244
1992	5750	10400	6927	8552	6753	8090
1993	5900	14500	7413	9109	7151	8843
1994	5950	10900	8026	9253	6314	9269
1995	5950	13000	8813	9787	8543	9656
1996	7250	13500	9015	10291	9173	11302
1997	9100	13500	9294	10649	9797	13326
1998	9750	13750	9726	10782	10365	10689
1999	8750	12500	10437	11330	10337	11297
2000	9500	15750	10746	11858	11434	12982
2001	6500	15500	11654	12364	11281	14141
2002	14500	18500	12064	17070	14145	17070


Tablo 23'te ise Tofaş Kartal marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1983 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7'yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 1398 TL ve ortalama mutlak yüzde hata %16,5, yapay sinir ağı için ortalama mutlak hata 1334 TL ve ortalama mutlak yüzde hata %15,3'tür. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 1988 model bir araç alacak olan kişinin 3401 TL ile 5280 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 1995 için 8543 TL ile 9656 TL arasında; 1996 için 9173 TL ile 11302 TL arasındadır.

Bir sonraki araç olan Hyundai Accent marka ve model aracı inceleyecek olursak; bu aracın toplam 337 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 11 aykırı değer tespit edilerek silinmiş ve örnek adeti 326'ya düşürülmüştür.



Şekil 72. Hyundai Accent Tahmin Daraltılmış Görünüm

Şekil 72’de görüldüğü üzere ilan edilen fiyat ile tahmin edilen değerler arasında farklılıklar bulunmakla beraber bu değerlerin birbirine en çok yaklaştığı örnekler 8, 9, 10 ve 16. örneklerde olmuştur. Fiyat farklarına bakacak olursak;



Şekil 73. Hyundai Accent Fiyat Farkı Görünümü

Şekil 73’te görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 10.000’TL ye varan fiyat farklılıkları ortaya çıkmıştır.


Tablo 24. Hyundai Accent Yıllara Göre Fiyat Dağılımı

Hyundai Accent	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1995	11250	16500	9674	11231	11631	14776
1996	12500	17250	9182	14228	10957	14274

1997	9500	15000	10487	14024	9994	20824
1998	8000	20000	11398	19441	9512	22156
1999	11000	18250	10869	15924	12465	19723
2000	12000	19000	14364	22434	10525	16626
2001	12000	25300	14509	27181	14034	26672
2002	15450	25500	14018	27097	15167	21505
2003	14250	21500	16305	24561	15818	25120
2004	14500	26500	17083	26553	16255	20586
2005	10000	29500	15657	27834	16103	28960
2006	16000	27900	19262	28971	17183	20356
2007	19500	100000	22833	30966	18427	74869
2008	18000	31000	22375	27191	17789	30270
2010	28500	28500	26974	26974	21373	21373
2011	27500	35750	26003	36915	21276	40295
2012	31000	32500	29153	31070	22112	30468
2013	42500	50000	35684	41093	37426	49632


Tablo 24’te ise Hyundai Accent marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1995 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 2737 TL ve ortalama mutlak yüzde hata %14,7, yapay sinir ağı için ortalama mutlak hata 2927 TL ve ortalama mutlak yüzde hata %15,4’dur. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için yapay sinir ağı yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 1995 model bir araç alacak olan kişinin 11631 TL ile 14776 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 1999 için 12465 TL ile 19723 TL arasında; 2007 için 18427 TL ile 74869 TL arasındadır.

Bir sonraki araç olan Opel Vectra marka ve model aracı inceleyecek olursak; bu aracın toplam 332 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 7 aykırı değer tespit edilerek silinmiş ve örnek adeti 325’e düşürülmüştür.



Şekil 74. Opel Vectra Tahmin Daraltılmış Görünüm

Şekil 74'te görüldüğü üzere genellikle ilan edilen araç fiyatı ile tahmin edilen veri arasında paralellik bulunmaktadır. Fiyat farklarına bakacak olursak;



Şekil 75. Opel Vectra Fiyat Farkı Görünümü

Şekil 75'te görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 5.000TL dolaylarında olmakla beraber bu değerler 16 ve 17. örneklerde 10.000 TL'ye kadar çıkmıştır.


Tablo 25. Opel Vectra Yıllara Göre Fiyat Dağılımı

Opel Vectra Model Yılı	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1991	7250	12500	8468	10777	10712	10839
1992	9500	18000	8739	11712	10822	13211
1993	10750	17500	8529	13339	12544	17765
1994	11750	20500	12648	15131	15054	15938

1995	12500	18000	13761	16417	16505	17248
1996	14000	21750	15522	18342	16342	20536
1997	13250	25000	17304	20383	17620	20220
1998	14400	23650	18332	22591	19083	23160
1999	15500	25750	20538	23096	19440	23799
2000	15000	32500	21782	24880	20414	25585
2001	15300	31300	23391	26478	22053	27911
2002	29000	29000	27700	27700	25942	25942
2003	22000	36500	25491	30195	26773	32955
2004	21000	36750	28909	32365	28420	36118
2005	26500	41000	29292	33380	31956	36009
2006	28000	40750	30752	34869	35169	37595
2007	31750	48500	33929	36114	36394	38762
2008	37500	41000	35738	35772	37938	37947


Tablo 25’te ise Opel Vectra marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1991 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 2394 TL ve ortalama mutlak yüzde hata %11,6, yapay sinir ağı için ortalama mutlak hata 2356 TL ve ortalama mutlak yüzde hata %11,8’dir. Tablo 6’daki korelasyon değerlerini de inceleyecek olursak; doğrusal regresyonun korelasyon değeri 0,9199 çıkarken, yapay sinir ağının korelasyon değeri 0,9351 çıkmıştır. Bu değerleri de göz önüne alarak yapay sinir ağının daha iyi sonuç verdiği söylenebilir. Çünkü elde edilen tahminlerin değişkenliğinden ve araç fiyatlarının değişim aralığının geniş olmasından kaynaklı olarak ortalama mutlak yüzde hatada sapma meydana gelebilir. Bu bilgiler ışığında 1994 model bir araç alacak olan kişinin 15054 TL ile 15938 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 1996 için 16342 TL ile 20536 TL arasında; 2004 için 28420 TL ile 36118 TL arasındadır.

Bir sonraki araç olan Ford Tourneo marka ve model aracı inceleyecek olursak; bu aracın toplam 329 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 4 aykırı değer tespit edilerek silinmiş ve örnek adeti 325’e düşürülmüştür.



Şekil 76. Ford Tourneo Tahmin Daraltılmış Görünüm

Şekil 76’da görüldüğü üzere ilan edilen fiyat ile tahmin değerleri arasında genel olarak farklılıklar oluşmuştur. Fiyat farklarına bakacak olursak;



Şekil 77. Ford Tourneo Fiyat Farkı Görünümü

Şekil 77’de görüldüğü üzere yapay sinir ağları tüm örneklerde doğrusal regresyona göre daha yüksek fiyat tahmini vermiştir. İlan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığının yaklaşık 10.000 TL’ye ulaştığı görülmektedir. İki numaralı örnekte ise bu fark yapay sinir ağı için 20.000 TL ve doğrusal regresyon için 15.000 TL tutarında olmuştur.


Tablo 26. Ford Tourneo Yıllara Göre Fiyat Tahmini

Ford Tourneo	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
2003	13000	14500	13056	17271	23535	23936

2004	16500	27500	12248	21601	22969	26470
2005	17500	28000	14920	21696	24573	27780
2006	17500	28750	17541	26884	26147	29129
2007	19500	33500	21221	29491	27327	30535
2008	21900	31750	23512	30951	28618	31885
2009	19000	32000	24108	33333	29317	33902
2010	20750	38000	26237	35566	30623	36088
2011	19000	41000	30025	38281	32686	40755
2012	28500	48000	32423	40666	34962	43570
2013	26000	43500	35531	42241	40540	47237
2014	36500	52000	40714	46873	44706	52350
2015	29750	85000	43115	85000	47883	85704
2016	50000	68250	47005	50759	52724	58529


Tablo 26’da ise Ford Tourneo marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 2003 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 3421 TL ve ortalama mutlak yüzde hata %10,9, yapay sinir ağı için ortalama mutlak hata 4352 TL ve ortalama mutlak yüzde hata %15,5’tir. Araç alım ve satımında daha az sapma ve hata yüzdesine sahip olduğu için doğrusal regresyon yöntemini kullanmak daha isabetli sonuç verecektir. Yani; 2005 model bir araç alacak olan kişinin 14920 TL ile 21696 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2013 için 35531 TL ile 42241 TL arasında; 2014 için 40714 TL ile 46873 TL arasındadır.

Bir sonraki araç olan Peugeot 206 marka ve model aracı inceleyecek olursak; bu aracın toplam 323 adet örneğe sahip olduğu görülmüştür. Verinin grafiği oluşturularak gözlemlenen değişim aralığının dışında kalan 1 aykırı değer tespit edilerek silinmiş ve örnek adeti 322’ye düşürülmüştür.



Şekil 78. Peugeot 206 Tahmin Daraltılmış Görünüm

Şekil 78’de görüldüğü üzere ilan edilen değerler ile tahmin verileri arasında farklılıklar görülmektedir. Bu farkların en az olduğu nokta 17. nokta olmuştur. İlan edilen araçlar ile fiyat farklarına bakacak olursak;



Şekil 79. Peugeot 206 Fiyat Farkı Görünümü

Şekil 79’da görüldüğü üzere ilan edilen fiyat ile tahmin edilen değer arasındaki farkın (ya da tahmin sapma miktarının) değişim aralığı yaklaşık 6.000 TL dolaylarında olmuştur.

Tablo 27. Peugeot 206 Yıllara Göre Fiyat Tahmini

Peugeot 206	Fiyat Aralığı		DR Tahmini Fiyat Aralığı		YSA Fiyat Aralığı	
	Min	Max	Min	Max	Min	Max
1999	15250	16900	14627	16767	13113	15988
2000	13500	22500	15341	21837	13753	21653
2001	14000	35000	16055	21595	14494	29860

2002	15500	24750	18100	22934	15659	21245
2003	13700	27500	16314	23446	17362	31059
2004	13250	26500	16947	24032	13306	28333
2005	11900	28750	17779	24801	11973	30121
2006	11750	27000	18272	24871	12998	24389
2007	17500	23000	21027	23094	17957	20541
2008	18500	24000	21677	23332	19853	21709
2009	19500	29000	23016	24395	21053	23376
2010	16750	30250	22351	26260	20320	28144
2011	24900	30000	23134	25465	21515	23584

Tablo 27’de ise Peugeot 206 marka araçların ikinci el fiyatlarının minimum ve maksimum olmak üzere yıllara göre dağılımı gösterilmiştir. 1999 modelden itibaren ikinci el piyasasında bu araçtan bulunabildiği görülmekle beraber ilan edilen fiyatlar ve tahminleri tablodaki gibidir. Tablo 7’yi inceleyecek olursak; doğrusal regresyon için ortalama mutlak hata 2235 TL ve ortalama mutlak yüzde hata %11,2, yapay sinir ağı için ortalama mutlak hata 2241 TL ve ortalama mutlak yüzde hata %10,4’tür. Tablo 6’daki korelasyon değerlerini de inceleyecek olursak; doğrusal regresyonun korelasyon değeri 0,6023 çıkarken, yapay sinir ağının korelasyon değeri 0,6999 çıkmıştır. Bu değerleri de göz önüne alarak yapay sinir ağının daha iyi sonuç verdiği söylenebilir. Çünkü elde edilen tahminlerin değişkenliğinden ve araç fiyatlarının değişim aralığının geniş olmasından kaynaklı olarak ortalama mutlak yüzde hatada sapma meydana gelebilir. Bu bilgiler ışığında 2000 model bir araç alacak olan kişinin 13753 TL ile 21653 TL arasında satın alım işlemi gerçekleştirmesi daha isabetli olacaktır. Bunun altındaki fiyat için kâr, bunun üzerindeki fiyat için zarar edeceği tahmin edilmektedir. Bu işlem 2008 için 19853 TL ile 21709 TL arasında; 2010 için 20320 TL ile 28144 TL arasındadır.

Elde edilen veriler ışığında ve tablo 6’da da görüldüğü üzere veri temizliği verinin daha isabetli ve yüksek doğrulukla sonuçlar vermesinde önemlidir. Tablo 7’de de görüldüğü üzere genel olarak yapay sinir ağı daha iyi sonuç vermiştir.

Tablo 7’de görüldüğü üzere Volkswagen Polo’da doğrusal regresyon için ortalama mutlak hata 3268 TL ve ortalama mutlak yüzde hata %10,8, yapay sinir ağı için ortalama mutlak hata 3133 TL ve ortalama mutlak yüzde hata %11,3 çıkmaktadır. Bu durum aynı zamanda Fiat Fiorino, Opel Vectra ve Peugeot 206 marka ve model araçlarda da mevcuttur. Diğer modellerde ortalama mutlak hata ile ortalama mutlak yüzde hata birbirine paralel ilerlerken burada ters işlemiştir. Elde edilen tahminlerin

değişkenliğinden ve araç fiyatlarının değişim aralığının geniş olmasından kaynaklı olarak ortalama mutlak yüzde hatada sapma meydana gelebilir. Bu durumun sebebi; bir yöntemdeki tahmin 10.000 TL saparken bu 10.000 TL fiyatın yüzde 1 ine denk gelebilir. Dolayısı ile ortalama mutlak hata yüksek görünürken ortalama mutlak yüzde hata düşük kalır. Diğer yöntemle yapılan tahmin 1.000 TL saparken bu 1.000 TL fiyatın yüzde 10 una denk gelebilir. O zaman da ortalama mutlak hata düşük çıkarken ortalama mutlak yüzde hata yüksek çıkabilir.

Yapılan bu çalışmada veri madenciliği metotlarından olan doğrusal regresyon ile yapay sinir ağları yöntemlerinin ikinci el araçların fiyat tahminindeki performansları karşılaştırılmıştır. Bu karşılaştırma yapılırken korelasyon değerleri, ortalama mutlak hata ve ortalama mutlak yüzde hata değerlerinden de faydalanılmıştır.

Özellikle satıcıların kendi araçlarını ön plana çıkarmak için kilometre bilgilerini düşük gösterme, yüksek fiyatlar koyma gibi yöntemlere başvurmaları aykırı değerler oluşturmuştur. Bu da veri temizliğinin önemini ortaya çıkarmaktadır. Düşük fiyat sıralamasında en yukarıda görüntülenmesi için araç fiyatını 1 TL girenler, yanlışlıkla kilometre bilgisini fiyat bölmesine girenler gibi bilinçli veya bilinçsizce yapılmış hatalı veri girişleriyle karşılaşmıştır. Bu hatalı veri girişleri; seride aykırı değerlerin bulunmasına bu da yüksek sapmalı tahminlerin elde edilmesine neden olmuştur. Elde edilen tahminleri iyileştirmek için bu aykırı değerler tespit edilerek seriden temizlenmiştir.

Piyasalarda; çalışmada kullanılan veri setinde yer alan sayıdan daha fazla değişken bulunmaktadır. Örnek olarak araç için yılda ne kadar vergi verileceği, bakım masraflarının ne kadar tuttuğu, aracın kazasının olup olmadığı, aracın alınırken veya satılırken dolar veya euro kuru gibi negatif değişkenlerin olabileceği; aracın satılabilirlik hızı, marka değeri, güvenlik ekipmanları, araç üzerinde bulunan ekstra özellikler (opsiyonlar) vb. artı değerler sağlayan değişkenler de bulunmaktadır.

İlerleyen dönemlerde yapılan çalışmalarda bunların da dâhil edildiği daha kapsamlı bir çalışma yapılacağı gibi ülke çapında bir standart oluşturulabilir.

SONUÇ

Günümüzde veri madenciliği birçok alanda kullanılmaktadır. Özellikle bilgi yoğunluklu ve hızlı gelişmekte olan alanlarda zamanın önemi çok fazladır. Analistlerin terabaytlarca veriyi inceleyip, süzgeçten geçirip, hesaplamaları yapıp, sonuçları bulup ve bu verileri anlaşılır bir şekilde kısa sürede servis etmeleri neredeyse imkânsız bir durumdur. Bu durumda veri madenciliği araçlarının kullanımı zorunlu hale gelmektedir. Çünkü bu araçlar en kısa sürede bu işleri yapmaya odaklanmış ve insan hatalarını en aza indirmeyi amaçlayan yapıya sahiptir. Bu araçlar aynı zamanda istenildiği an veri ekleme ve yeniden hesap yapmayı da mümkün kılmaktadır.

Bu çalışmada, veri madenciliği tekniklerinden doğrusal regresyon ve yapay sinir ağları teknikleri kullanılarak, ikinci el araç piyasasından elde edilen veriler üzerinde yöntemin uygulanabilirliği gösterilmiştir. İkinci el araç piyasası üzerinde araç almayı veya aracını satmayı düşünen kişiler için, doğrusal regresyon ve yapay sinir ağları aracılığıyla fiyat tahmin sistemi oluşturulmuş, yöntemlerin sonuçları karşılaştırılmıştır. Bu karşılaştırma yapılırken korelasyon değerleri, ortalama mutlak hata ve ortalama mutlak yüzde hata değerlerinden de faydalanılmıştır. Elde edilen veriler ışığında, veri madenciliği sürecinde, verinin daha isabetli ve yüksek doğrulukla sonuçlar vermesi açısından, en önemli aşamanın veri temizliği olduğu saptanmıştır. Çalışmada fiyat tahmininde yapay sinir ağları, doğrusal regresyon yöntemine göre daha iyi sonuç vermiştir.

Bu çalışmada; problem tanımı, veri ön hazırlığı, veri keşfi, modelleme, değerlendirme, yerleştirme aşamaları takip edilmiştir.

Problem tanımı olarak ikinci el araç satın alırken “hangi fiyat aralığında hangi model aracı almamız mantıklı olur ve hangi yöntem bize daha çok avantaj sağlar?” sorusu temel olarak belirlenmiştir.

Problem belirlendikten sonra ikinci aşama olan veri ön hazırlığı aşamasına geçilmiştir. Öncelikle; alınabilecek veri kaynakları araştırıldıktan sonra hürriyet oto internet sitesinden 14.12.2016 tarihinde alınan; 13.12.2016 – 25.08.2010 tarihlerini kapsayan veriler ile bu aralıkta satılan araçlar dahil olmamakla beraber sadece aktif bulunan ilanlar olan 31.098 adet ilan alınmıştır. Veri üzerinde veri temizleme işlemi yapılarak eksik veya yanlış olan veriler temizlenmiştir. Bu işlemten sonra 30.570 adet ilan kalmıştır.

Veri keşfi süreci içerisinde ilk olarak doğrusal regresyon ve yapay sinir ağları sayısal verileri üzerinde çalışabildiği için, değerlendirme işleminin yapılabilmesi adına veriler sayısallaştırılmıştır. Sonrasında bu veriler veri madenciliği yöntemlerinden olan doğrusal regresyon ve yapay sinir ağı yöntemleri ile değerlendirilmiş ve model üzerinde işlenmiştir. İşlenen bu veriler değerlendirme aşamasına gelindikten sonra; marka ve model verilerinden ötürü sonuçlarda meydana gelen sapmalardan dolayı hatalı sonuçlar ürettiği için tekrar veri ön hazırlığı aşamasına dönülerek veri araç marka ve modellerine göre 70 marka altında 616 model olması nedeniyle veri 616 parçaya bölünmüştür. Bölümlendirme işlemi gerçekleştirildikten sonra tekrar değerlendirme sürecine geçilmiş ve doğrusal regresyon ve yapay sinir ağı ile değerlendirilmiştir. Bu değerlendirme sonucunda modellerin kendi içerisinde yer alan aykırı değerlerin giderilmesi için gözle kontrol işlemi gerçekleştirilerek aykırı değerler mümkün olduğunca giderilmiştir. Aykırı değerlerin giderilmesi işleminden sonra tekrar veri keşfi sürecine gelinmiş ve doğrusal regresyon ve yapay sinir ağı yöntemleri üzerinde uygulanmıştır. Tablo 6’da da görüleceği üzere aykırı değerlerin çıkarımından önce ve sonraki korelasyon değerlerinde kayda değer gelişme görülmüştür.

Verinin sayısallaştırma işlemine aynı zamanda verinin modellenmesi de denebilir. Çünkü verinin kullanılacak yöntemeye uygun hale getirilmesi gerekmektedir.

Veri modellemeden sonra model yerleştirme aşamasına geçilmiş ve veri kullanıcı dostu olacak şekilde programa yerleştirilmeye hazır hale getirilmiştir.

Veri hazır hale geldiği için sonrasında en çok örneğe sahip olan ilk 20 model araç üzerinde doğrusal regresyon ve yapay sinir ağları yöntemleri uygulanmıştır. Çıkan sonuçlar ile ortalama mutlak hata ve ortalama mutlak yüzde hatalar hesaplanmış ve bu en çok örneğe sahip olan ilk 20 araç üzerinde tablosal ve grafiksel olarak değerlendirilmiştir.

Sonuç olarak; ayrı ayrı en çok örneğe sahip olan ilk 20 model aracın yıllara dayalı olarak, minimum ve maksimum fiyatları incelenerek; bu 20 marka ve model üzerinde en iyi performans gösteren yöntem üzerinden değerlendirilmiştir. Bu iki yöntemin üzerinde yapılan incelemeye göre genel olarak yapay sinir ağı yönteminin daha iyi performans gösterdiği görülmüştür.

Çalışma kapsamında internet üzerinden faaliyet gösteren hürriyet oto sitesinden 70 marka ve 616 model aracın verileri sistemden alınmış, veri madenciliği ön hazırlık süreçleri uygulanmıştır. Bu süreçler sonucu elde edilen temiz veri ile ortalama mutlak

hata ve ortalama mutlak yüzde hata deęerleri bulunmuştur. Bu deęerler baz alınarak hata miktarı ve oranı en düşük olan yöntem ile inceleme yapılmıştır. Yapılan bu incelemede; ortalama mutlak hata bakımından yapay sinir aęları %70 daha iyi sonuç verirken, ortalama mutlak yüzde hata bakımından bu oran %60'a düşmüştür. Burdaki tezatlık Volkswagen Polo, Fiat Fiorino, Opel Vectra ve Peugeot 206 marka ve model araçlarda da mevcuttur. Dięer modellerde ortalama mutlak hata ile ortalama mutlak yüzde hata birbirine paralel ilerlerken burada ters işlemiştir. Elde edilen tahminlerin deęişkenliğinden ve araç fiyatlarının deęişim aralığının geniş olmasından kaynaklı olarak ortalama mutlak yüzde hatada sapma meydana gelebilir. Bu durumun sebebi; bir yöntemdeki tahmin 10.000 TL saparken bu 10.000 TL fiyatın yüzde 1'ine denk gelebilir. Dolayısı ile ortalama mutlak hata yüksek görünürken ortalama mutlak yüzde hata düşük kalır. Dięer yöntemle yapılan tahmin 1.000 TL saparken bu 1.000 TL fiyatın yüzde 10'una denk gelebilir. O zaman da ortalama mutlak hata düşük çıkarken ortalama mutlak yüzde hata yüksek çıkabilir. Tezatlığın giderilebilmesi için durumdan etkilenen araçlar üzerinden korelasyon tablosundan da destek alınarak en iyi sonucu veren sistem üzerinden deęerlendirme yapılmıştır.

Veride yer alan fiyatların doğruluk oranlarının ve ortalama mutlak hata ve ortalama mutlak yüzde hata deęerlerinin normal şartlar altında örnek sayısı yükseldikçe azalması gerekir. Bu da daha isabetli sonuçları beraberinde getirir. Fakat 1360 örneęe sahip olan Opel Vectra'da doğrusal regresyon için ortalama mutlak hata 4456 TL ve ortalama mutlak yüzde hata %12.1 ve yapay sinir aęları için ortalama mutlak hata 3729 TL ve ortalama mutlak yüzde hata %10 iken 476 örnepe sahip olan Renault Symbol'ün doğrusal regresyon için ortamam mutlak hata 2560 TL ve ortalama mutlak yüzde hata %9.6 ve yapay sinir aęı için ortalama mutlak hata 2016 TL ve ortalama mutlak yüzde hata %7.8 olduęu görölmektedir. Bu da verinin daha derin olarak incelenmesi gerektiğini göstermektedir.

Bulgular ışığında verideki bu tezatlıkları giderebilmek için, araçların model yılına kadar inerek daha yüksek bir homojenlik yakalamak gerekebilir. Aynı model yılı içerisindeki araçlar üzerinde yapılacak olan inceleme daha isabetli sonuçlar verecektir. Doğrusal regresyon ve yapay sinir aęı yöntemlerinin temeli aęırlıklandırarak deęerlendirmektir.

Veri üzerinde daha fazla ayrıntı elde etmek sureti ile araç üzerinde yer alan ekstra masraflar, eksiklikler, hasar kayıtları, ek donanımlar ve paketler ile birlikte araç değerini etkileyen tüm opsiyonlar da hesaba katılmalıdır. Bu işlemin yapılabilmesi için yeni bir sistem oluşturulup; oluşturulacak olan bu sistem üzerinde ön şart olarak bu verilerin de girilmesi, zorunlu olarak istenmesi gerekmektedir. Özellikle ülkemizde bu değişkenlerin araç fiyatlarını yüksek miktarda etkilediği düşünülürse ilerleyen çalışmalarda bu değişkenlerin eklenerek değerlendirilmesi zaruri bir hal almaktadır.

Daha kapsamlı değişkenlerin kullanılacağı veri madenciliği yöntemleri ile daha isabetli sonuçların alınacağı sistemler kurulabilir ve hem satıcı açısından hem de alıcı açısından daha güvenilir ve en az zarar ve en az bekleme süresi ile araç alışverişinin gerçekleşmesi sağlanabilir.

Özellikle oluşturulacak portal üzerinde; araç satın alan kişilerin aldıkları aracın durumunu ve aldıkları fiyat verilerini girmesi üzerinden bir nevi gönüllülük esasına dayanan bu sistem diğer araç alacak kişiler için bir rehber özelliği taşıyacaktır. İlk aşamada sadece gönüllü kullanıcılar üzerinden yürüyecek olan bu sistem yeterli büyüklüğe eriştikten sonra araç satacak kişilerin veya kurumların da dikkatini çekmesi ile birlikte bu kişi ve kurumların kendi fiyatlarını sisteme göre ayarlamaları ile daha düzenli bir hal alacaktır. Amerika Birleşik Devletleri'nde bu sistemin en büyük temsilcisi "Kelley Blue Book" adı verilen web sitesidir. Bu site üzerinden araç satacak veya alacak kişiler kendi posta kodlarını girerek eyalet bazlı vergiler ve kesintiler de dahil olmak üzere kendi araç değerlerini hesaplabilmektedirler. Bu sistem özellikle fiyat üzerinde yapılacak manipülasyonları önleme üzerine kuruludur. Türkiye için de veri madenciliği üzerinden böyle bir model uygulaması yapılabilir. Farklı olarak, vergiler yerine ülkemizde araç ve yedek parçalarının ithalatının daha yoğun olması nedeniyle, değer belirlemede döviz kurları baz alınarak fiyatlandırma yapılabilir.

Veri madenciliği uygulamaları girilen verinin miktarına göre doğruluk oranı artan sistemlerdir. Dolayısı ile sistem etkin bir şekilde kullanılırsa hem satıcılar hem de alıcılar yanlış veri vermemeye özen göstereceklerdir. Veri üzerindeki anormallikler ise yine veri madenciliği içerisinde kullanılan aykırı değerleri bulan ve yok eden algoritmalar ile aşılabilir. Her ne kadar veriler algoritmalar ile denetlense de son kontrol her zaman kullanıcılara aittir. Çünkü araç alırken ya da satarken yapılan ekspertiz kontrolleri araç

hakkındaki sisteme girilen verilerin tam ve doğru olup olmadığı konusunda kesin bilgiyi vermektedir.

Gelecekte yapılacak çalışmalarda; sınıflandırma ve kümeleme algoritmalarının kullanımı ile birlikte veriler daha iyi gruplandırılabilir, karar ağacı metotları kullanılarak alınacak olan aracın veya araçların fiyat performans açısından daha iyisinin seçilmesine yardımcı olabilir. Bu algoritmaların da katkıları ile karşılaştırmalar ve daha isabetli fiyat tahminleri yapılabilir. Ayrıca bulanık yapay sinir ağı metotlarının kullanımı ile doğruluk oranları arttırılabilir.

KAYNAKLAR

- Acuna, E., Rodriguez, C. (2004). "The treatment of missing values and its effect on classifier accuracy", *Classification, clustering, and data mining applications*, 639 – 647.
- Agarwal R., Rao, A. R., (2014). Data Reduction Techniques, Indian Agricultural Statistics Research Institute, http://www.iasri.res.in/ebook/EB_SMAR/e-book_pdf%20files/Manual%20II/9-data_reduction.pdf (04.01.2016).
- Aggarwal G., Singh L., (2015). "Characterization Between Child and Adult Voice Using Machine Learning Algorithm", *International Conference on Computing, Communication and Automation (ICCCA)*, 246 – 250.
- Allison R., (2012). Sas/Graph: Beyond The Basics, http://robslink.com/SAS/book1/Chapter_03_Bars.pdf (24.02.2016).
- Alvarez S. A., (2003) Chi - Squared Computation for Association Rules: preliminary results, Computer Science Department Boston College Technical Report, <http://www.cs.bc.edu/~alvarez/ChiSquare/chi2tr.pdf> (28.02.2016).
- Amor N. B., Benferhat S., Elouedi Z., (2004). "Naive Bayes vs Decision Trees in Intrusion Detection Systems", *Proceedings of the 2004 ACM symposium on Applied computing ACM Symposium on Applied Computing*, 420 – 424.
- Andritsos P., (2002). Data Clustering Techniques Qualifying Oral Examination Paper, Rapport Technique, University of Toronto Department of Computer Science. ftp://www.cs.toronto.edu/public_html/public_html/cs/ftp/pub/reports/csri/443/depth.pdf (03.05.2017).
- Batista, G. E., Monard, M. C. (2003). "An Analysis of Four Missing Data Treatment Methods for Supervised Learning", *Applied Artificial Intelligence*, Volume:17 (5-6), 519 – 533.
- Beniwal S., Arora J., (2012). "Classification and Feature Selection Techniques in Data Mining", *International Journal of Engineering Research & Technology*, Volume: 1, Issue: 6, 1 – 6.

- Berkhin P., (2002). A Survey of Clustering Data Mining Techniques, <https://pdfs.semanticscholar.org/26f1/78dbb00630ce19cccb9840ea12dbe31801be.pdf> (03.05.2017).
- Bingham R. P., Kreiss D., Santoso S., (1995). “Advances in data reduction techniques for power quality instrumentation”, *Proceedings of 3rd European Power Quality Conference*. 1 – 14.
- Breiman L., (1995). “Better Subset Regression Using the Nonnegative Garrote”, *J Stor, Technometrics*, 1995 Volume: 37, No: 4, 373 – 384.
- Breslow L. A., Aha D. W., (1997). “Simplifying Decision Trees: A Survey”, *The Knowledge Engineering Review*, Volume: 12 (1), 1 – 40.
- Brusic V., Rudy G., Honeyman M., Hammer J., Harrison L., ve diğerleri, (1998). “Prediction of MHC Class II- Binding Peptides Using an Evolutionary Algorithm and Artificial Neural Network”, *Bioinformatics*, Volume: 14, No: .2, 121 – 130.
- Burbidge R., (2001). “Buxton B, An Introduction to Support Vector Machines for Data Mining”, *Computer Science Dept., UCL, Gower Street, WC1E 6BT, UK* http://www.cc.gatech.edu/fac/Charles.Isbell/classes/2008/cs7641_spring/handouts/yor12-introsvm.pdf (12.11.2016).
- Burges C. J. C., (2010). “Dimension Reduction: A Guided Tour”, *Foundations and Trends in Machine Learning*, Volume: 2, No:4, 275 – 365.
- Butler C., (1985). *Statistics in Linguistics*, Basil Blackwell.
- Cerny P. A., (2001). “Data Mining and Neural Networks from a Commercial Perspective”, *ORSNZ Conference Twenty Naught One* Auckland, New Zealand Student of the Department of Mathematical Sciences, University of Technology, Sydney, Australia, 1 – 10.
- Charniak E., (1991). “Bayesian Networks Without Tears”, *AI Magazine*, Volume: 12 NumerNo: 4 (AAAI), 50 – 63.
- Chickering D. M., (1995). “A Transformational Characterization of Equivalent Bayesian Network Structures”, *Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence (UAI1995)*, 87 – 98.

- Coenen F., (2004) “Data Mining: Past, Present and Future”, *The Knowledge Engineering Review Vol. 00:0 1-24 Cambridge University Press*, 1 – 24.
- Cooper G. F., (1990). “The Computational Complexity of Probabilistic Inference Using Bayesian Belief Networks”, *Artificial Intelligence*, Volume: 42 (2-3), :393 – 405.
- Danubianu M., Pentiu S. G., Danibianu D. M., (2012). “Data Dimensionality Reduction for Data Mining A Combined Filter – Wrapper Framework”, *International Journal Computer Communications and Control*, Volume: 7, No: 5, 824 – 831.
- Das A., Kempe D., (2008). “Algorithm for Subset Selection in Linear Regression”, *In Proceeding STOC '08 Proceedings of the fortieth annual ACM symposium on Theory of computing*, 45 – 54.
- Dash M., Liu H., (2009). “Dimensionality Reduction”, Department of Computer Science and Engineering Arizona State University *Encyclopedia of Computer Science and Engineering*, B. W. Wah, Ed., John Wiley & Sons, Hoboken, NJ, USA, Volume: 2, 958–966.
- Dawson C. W., Wilby R., (1998). “An Artificial Neural Network Approach to Rainfall-Runoff Modelling”, *Hydrological Sciences Journal*, Volume: 43, Issue: 1, 47 – 66.
- Deville B., Neville P., (2006). *Decision Trees for Analytics Using SAS Enterprise Miner*, SAS Institute.
- De’ath G., Fabricius K. E., (2000). “Classification and Regression Trees: A Powerful Yet Simple Technique For Ecological Data Analysis”, *Ecology*, 81 (11), 3178 – 3192.
- Dekker A. H., (1994). “Kohonen Neural Networks for Optimal Colour Quantization”, *Network: Computation in Neural Systems*, Volume: 5 Issue: 3, 351 – 367.
- Doan A., McCann R., (2003). “Building Data Integration Systems: A Mass Collaboration Approach”, *Sixth International Workshop ob the Web and Databases (WebDB-03)*, 1 – 6.
- Du, J., Xie, L., Schroeder, S. (2009). “Practice Prize Paper—PIN Optimal Distribution of Auction Vehicles System: Applying Price Forecasting, Elasticity Estimation, and Genetic Algorithms to Used-Vehicle Distribution”, *Marketing Science*, 28(4), 637-644.

- Fayyad U., Piatetsky-Shapiro G., Smyth P., (1996). “From Data Mining to Knowledge Discovery in Databases”, *AI Magazine*, Volume: 17 No: 3, 37 – 54.
- Flockhart, I. W., Radcliffe, N. J., (1996). “A Genetic Algorithm-Based Approach to Data Mining”, *Knowledge Discovery and Data Mining*, 299 – 302.
- Fomby T., (2008). Multiple Linear Regression and Subset Selection, Elsevier Computers & Industrial Engineering, 2008http://faculty.smu.edu/efomby/eco5385_eco6380/lecture/Multiple%20Linear%20Regression%20and%20Subset%20Selection.pdf (01.04.2017).
- Friendly M., Denis D., (2005). “The Early Origins and Development of The Scatter Plot”, *Journal of the History of the Behavioral Sciences*, Volume: 41(2), 103 – 130.
- Garcia V., Debreuve E., Barlaud M., (2008). “Fast K Nearest Neighbor Search Using GPU”, *Computer Vision on Pattern Recognition Workshops, CVPRW'08. IEEE Computer Society Conference*, 1 – 6.
- Gibson D., Kleinberg J., Raghavan P., (1998). “Clustering Categorical Data: An Approach Based on Dynamical Systems”, *In Proceedings of the 24th International Conference on Very Large Databases*, 311 – 322.
- Gordon, L., (2013) “Using Classification and Regression Trees (CART) in SAS Enterprise Miner for Applications in Public Health”, *SAS Global Forum*, 2013, Paper: 089, 1 – 8.
- Gray J., Bosworth A., Layman A., Pirahesh H., (1997). “Data Cube: A Relational Aggregation Operator Generalizing Group-By, Cross-Tab, and Sub Totals”, *Data Mining and Knowledge Discovery*, Volume: 1 (1) Institute of Electrical and Electronics Engineers, Inc., 29 – 53.
- Grzymala-Busse J. W., (2005). “Rough Set Theory with Applications to Data Mining”, *Real World Applications of Computational Intelligence*, Volume: 179, 76 – 147.
- Halevy A., Rajaraman A., Ordille J., (2006). “Data Integration: The Teenage Years”, *VLDB '06 Proceedings of 32nd International conference Conference on Very large Large databasesDatabases*, 9 – 16.
- Han, J., Kamber, M. (2006). *Data Mining: Concepts and Techniques*, University of Illinois at Urbana-Champaign.

- Hand D., (2001). *Principles of Data Mining (Adaptive Computation and Machine Learning Series)*, MIT Press.
- Hardin M., Hom D., (2016). Perez R., Williams L., ve diğerleri, Which chart or graph is right for you?, http://www.tableau.com/sites/default/files/media/which_chart_v6_final_0.pdf (26.02.2016).
- Harinarayan V., Rajaraman A., Ullman J. D., (1996). “Implementing Data Cubes Efficiently”, *Proceeding SIGMOD '96 Proceedings of the 1996 ACM SIGMOD International Conference on Management of Data*, Volume: 25 No:2, 205 – 216.
- Heckerman D., (1995). A Tutorial of Learning Bayesian Networks, Local: Microsoft Research Advanced Technology Division. Notas: Technical Report MSR-TR-95-06, <http://tomlr.free.fr/Math%E9matiques/Fichiers%20Claude/Auteurs/AAprov070125/Heckerman%20-%20A%20Tutorial%20On%20Learning%20Bayesian%20Networks.pdf> (05.08.2016).
- Hellerstein, J. M. (2008). *Quantitative data cleaning for large databases*, United Nations Economic Commission for Europe (UNECE).
- Ho, A., Romano, R., Wu, X. A. (2012). “Don’t Get Kicked-Machine Learning Predictions for Car Buying”, Stanford University, CS229 Machine Learning.
- Hoffmann M., Numerical, (2005). “Numerical Control of Kohonen Neural Network for Scattered Data Approximation”, *Numerical Algorithms*, Volume: 39, Issue: 1 – 3, 175 – 186.
- Huang G. B., Zhu Q. Y., Siew C. K., (2004). “Extreme Learning Machine: A New Learning Scheme of Feedforward Neural Networks”, *Neurocomputing Neural Networks 2004, Proceedings. 2004 IEEE International Joint Conference*, Volume 2, 985 – 990.
- Huang Z., (1997). “A Fast Clustering Algorithm to Cluster Very Large Categorical Data Sets in Data Mining”, *Conference: Research Issues on Data Mining and Knowledge Discovery – DMKD*, 34 – 39.

- IBM Corp, (2014). IBM Combination Chart Extensible Visualizations Product: IBM Cognos Business Intelligence Area of Interest: Reporting, [Online], 02.03.2015, <http://docplayer.net/11525217-Combination-chart-extensible-visualizations-product-ibm-cognos-business-intelligence-area-of-interest-reporting.html>https://www.ibm.com/web/wcm/connect/analytics/d71846d5-2090-4348-b0a0-76066911d835/combination_chart_visualization.pdf?MOD=AJPERES&CONVERT_TO=url&CACHEID=d71846d5-2090-4348-b0a0-76066911d835, (02.03.2015).
- Idreos S., Papaemmanouil O., Chaudhuri S., (2015). “Overview of Data Exploration Techniques”, *Proceedings of the ACM SIGMOD International Conference on Management of Data*, 277 – 281.
- Kadam S. U., Thakore D. M., (2012). “High Dimensional Data Mining in Time Series by Reducing Dimensionality and Numerosity”, *International Journal of Computer Technology & Applications*, 903 – 908.
- Kaiser, J. (2014). “Dealing with missing values in data”. *Journal of systems integration*, Volume: 5(1), 42 – 51.
- Kalegvele K. ve diğerleri Sveholm J., Takahashi H., Sasai K., Kitagata G., Kinoshita T., (2011). “On-Demand Numerosity Reduction for Object Learning”, *Proceedings IoTSP Proceedings IoTSP '11 Proceedings of the workshop on Internet of Things and Service Platforms*, Article No: 6, 1 – 8.
- Keller J. M., Gray M. R., Givens J. A., (1985). “A Fuzzy K- Nearest Neighbor Algorithm”, *IEEE Transactions On Systems, Man And Cybernetics*, Volume: SMC-15 No: 4, 580 – 585.
- Korb K. B., Nicholson A E, (2010). *Bayesian Artificial Intelligence*, CRC Press.
- Kuiper, S. (2008). “Introduction to Multiple Regression: How Much Is Your Car Worth?”, *Journal of Statistics Education*, 16(3).
- Kumar A., (2016). Artificial Neural Networks for Data Mining, <http://studyres.com/doc/690730/artificial-neural-networks-for-data-mining> (11.08.2015). I.A.S.R.I Library Avenue, Pusa, New Delhi-110012.

- Lenzerini M., (2002). “Data integration: A Theoretical Perspective”, *Proceedings of the Twenty-First ACM SIGMOD-SIGACT-SIGART Symposium on Principles of Database Systems*, 233 – 246.
- Lessmann S., Voß S., (2009). “A Reference Model for Customer-Centric Data Mining With Support Vector Machines”, *European Journal of Operational Research*, 2009. Volume: 199, Issue: 2, 520 – 530.
- Li B., Yu S., Lu Q., (2003). “An Improved k-Nearest Neighbor Algorithm for Text Categorization”, *Proceedings of the 20th International Conference on Computer Processing of Oriental Languages*, 1 – 7.
- Li R., History of Data Mining, <https://rayli.net/blog/data/history-of-data-mining/> (21.05.2017).
- Lin L., Cao L. L., Wang J., Zhang C., (2004). “The Applications of Genetic Algorithms in Stock Market Data Optimization”, *Conference on Data Mining, Text Mining and Their Business Application. Wessex Institute of Technology Press* WIT Transactions on Information and Communication Technologies, 1 – 9.
- Lin, Y. (2015). Auto Car Sales Prediction: A Statistical Study Using Functional Data Analysis and Time Series, Doctoral dissertation, University of Michigan.
- Listiani M. (2009). Support Vector Regression Analysis for Price Prediction in a Car Leasing Application, Master Thesis. Hamburg University of Technology.
- Liu H., Hussain F., Tan C. L., Dash M., 2002. “Discretization: An enabling technique”. *Data mining and knowledge discovery*, Volume: 6(4), 393-423.
- Luk K. C., Ball J. E., Sharma A., (2000). “A Study of Optimal Model Lag and Spatial Inputs to Artificial Neural Network for Rainfall Forecasting”, *Journal of Hydrology*, Volume: 227, 56 – 65.
- Meals D. W., Dressing S. A., (2005). Monitoring Data Exploring Your Data, The First Step, National Nonpoint Source Monitoring Program, https://www.epa.gov/sites/production/files/2015-10/documents/technote1_exploring_data.pdf (06.03.2015).

- Medeiros-Ribeiro G., ve diğerleri Bratkovski A. M., Kamins T. I., Ohlberg D. A. A., Williams R. S., (1998). “Shape Transition of Germanium Nanocrystals on a Silicon (001) Surface from Pyramids to Domes”, *Science* 279 (5349), 353 – 355.
- Medsker L. R., Jain L. C., (2001) *Recurrent Neural Networks Design and Applications*, CRC Press., 2001.
- Miller A. J., (1984). “Selection of Subsets of Regression Variables”, *Blackwell Publishing for the Royal Statistical Society, 1984 Journal of the Royal Statistical Society, Series A (General)*, 389 – 425.
- Moreno M. N., Segretera, S., Lopez, V. F., Polo, M. J. (2007). “Improving the Quality of Association Rules by Preprocessing Numerical Data”, *Congreso Espanol de Informatica*, 223 – 230.
- Murthy S. K., Kasif S., Salzberg S., (1994). “A System for Induction of Oblique Decision Trees”, *Journal of Artificial Intelligence Research*, Volume: 2, 1 – 32.
- Murty M. R., (2016). Discretization and Concept Hierarchy Generation, http://dataminingzone.weebly.com/uploads/6/5/9/4/6594749/ch_7discretization_and_concept_hierarchy_generation.pdf (23.01.2016).
- Neapolitan R. E., (2003). *Learning Bayesian Networks*, Prentice Hall.
- Nookola G. K. M., Pottumunthu B. K., Orsu N., Muduruni S. B., (2013). “Performance Analysis and Evaluation of Different Data Mining Algorithms used for Cancer Classification”, *(IJARAI) International Journal of Advanced Research in Artificial Intelligence*, Volume: 2 No: 5, 49 – 55.
- Oğuzlar A., (2003). “Veri Ön İşleme”, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Sayı: 21, Temmuz-Aralık, 67 – 76.
- Ohrn A., Rowland T., (2000) “Rough Sets: A Knowledge Discovery Technique for Multifactorial Medical Outcomes”, *American Journal of Physical Medicine*, 1 – 15.
- Oprea, C. (2011). “Making the decision on buying second-hand car market using data mining techniques”, *The USV Annals of Economics and Public Administration*, 10(3), 17-26.

- Pawlak Z., (2002)., “Rough Set Theory and Its Applications”, *Journal of Telecommunications and Information Technology*, 7 – 10.
- Pedersen, M. E. H., (2003). Genetic Algorithms for Rule Discovery in Data Mining, <http://www.hvass-labs.org/people/magnus/schoolwork/mining/project1/ga-rule.pdf> (04.01.2016).
- Peerun S., Chummun N. H., Pudaruth S., (2015). “Predicting the Price of Second-hand Cars using Artificial Neural Networks”, Proceedings of the Second International Conference on Data Mining, Internet Computing, and Big Data, Reudit, Mauritius, 17-21
- Penny W., Friston K., Ashburner J., Kiebel S., Nichols T. J., Statistical, (2007). *Statistical Parametric Mapping: The Analysis of Functional Brain Images*, Elseiver.
- Pudaruth, S. (2014). “Predicting the price of used cars using machine learning techniques”, *Int. J. Inf. Comput. Technol*, 4(7), 753-764.
- Purohit, D. (1992). “Exploring the relationship between the markets for new and used durable goods: The case of automobiles”, *Marketing Science*, 11(2), 154-167.
- Qin B., Xia Y., Prabhakar S., Tu Y., (2009). “A Rule-Based Classification Algorithm for Uncertain Data”, *Data Engineering ICDE'09. IEEE 25th International Conference IEEE International Conference on Data Engineering*, 1633 – 1640.
- Quinlan J. R., Rivest R. L., (1989). “Inferring Decision Trees Using the Minimum Description Length Principle”, *Information and computation*, Volume: 80(3), 227 – 248.
- Rahm, E., Do, H. H. (2000). “Data cleaning: Problems and current approaches”. *IEEE Data Eng. Bull.*, Volume: 23(4), 3 – 13.
- Rajagopal S., (2011) “Customer Data Clustering Using Data Mining Technique”, *International Journal of Database Management Systems (IJDMS)*, 2011Volume: 3, No: 4, 1 – 11.
- Rani U., (2011). “Analysis of Heart Diseases Dataset Using Neural Network Approach”, *International Journal of Data Mining & Knowledge Management Process (IJDMP)*, 2011Volume: 1, No: 5, 1 – 8.

- Ratner B., (2003). Stepwise is a Problematic Method for Variable Selection in Regression: Alternative Methods are Available, DM STAT-1 Consulting, <http://www.geniq.net/res/Stepwise-is-a-Problematic-Method-for-Variable-Selection-in-Regression.pdf> (02.02.2017).
- Rissino S., Lambert – Torres G., (2009) “Rough Set Theory – Fundamental Concepts, Principals, Data Extraction, and Applications”, *Data mining and knowledge discovery in real life applications. InTech.*, 35 – 59.
- Rokach L., Maimon O., (2005). *Data mining and Knowledge Discovery Handbook*, Springer Verlag New York Inc.
- Rokach L., Maimon O., (2005). *Decision Trees, Data Mining with Decision Trees Theory and Applications*, World Scientific.
- Ruggeri, F., Kenett, R. S., Faltin, F. W. (2007). *Encyclopedia of statistics in quality and reliability*, Wiley.
- Rupnik R., Jaklic J., (2009). *The Deployment of Data Mining into Operational Business Processes, Data mining and knowledge discovery in real life applications, InTech*, 373 – 388.
- Savaş, S., Topaloğlu N., Yılmaz M., (2012). “Veri Madenciliği ve Türkiye’deki Uygulama Örnekleri”, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, Yıl: 11, Sayı 21 Bahar, 1 – 23.
- Sayad S., (2015). K Nearest Neighbors – Classification [online], 14.09.2015, http://www.sayed sayad.com/k_nearest_neighbors.htm (14.09.2015).
- Seo J., Gordish-Dressman H., (2007). Exploratory Data Analysis with Categorical Variables: An Improved Rank-by-Feature Framework and a Case Study, <http://www.cs.umd.edu/hcil/ben60/Seopaper.pdf> (01.03.2015).
- Shaw S., Most B., (1990). “Error Bars With Line Graphs and Bar Charts”, *SAS Global Forum Proceedings SUGI 90*, 1419 – 1424, <http://www.sascommunity.org/sugi/SUGI90/Sugi-90-250%20Shaw%20Most.pdf> (02.03.2015).
- Singh Y., Chauhan A. S., (2009) “Neural Networks in Data Mining”, *Journal of Theoretical & Applied Information Technology*, Volume: 5, Issue: 1, 37 – 42.

- Singhi S. K., Liu H., (2006). “Feature Subset Selection Bias for Classification Learning”, *ICML '06 Proceedings of the 23rd international conference on Machine learning*, 849 – 856.
- Souza J., Matwin S., Japkowicz N., (2002). “Evaluating Data Mining Models: a Pattern Language”, *Proceedings of the 9th Conference on Pattern Language of Programs, Illinois, USA*, 1 – 23.
- Sunithaa, L., Rajua, M. B., Srinivas, B. S. (2013). “A Comparative Study between Noisy Data and Outlier Data in Data Mining”, *International Journal of Current Engineering and Technology*, Volume: 3 No: 2, 575 – 577.
- Sutton O., (2012). *Introduction to K Nearest Neighbour Classification and Condensed Nearest Neighbour Data Reduction*, University lectures, University of Leicester.
- Sykes A. O., (1993). “An Introduction to Regression Analysis”, *Coase-Sandor Institute for Law & Economics Working Paper No: 20*, 1993., 1 – 33.
- Tiwari M., Jha M. B., Yadav O., (2012). “Performance Analysis of Data Mining Algorithms in Weka”, *IORS Journal of Computer Engineering (IOSRJCE)*, 2012Volume: 6, Issue: 3, (Sept-Oct 2012), 32 – 41.
- Trivedi S., Pardos, Z. A., Sárközy, G. N., Heffernan, N. T.ve diğ er, (2011) “Spectral Clustering in Educational Data Mining”, *In Proceedings of the 4th International Conference on Educational Data Mining*, 129 – 138.
- Trnka A., (2010). “Classification and Regression Trees as a Part of Data Mining in Six Sigma Methodology”, *Proceedings of the World Congress on Engineering and Computer Science*, Volume: 1, 449 – 453.
- Urbanek S., (2016). Cubes Documentation Release 1.1, <https://media.readthedocs.org/pdf/cubes/latest/cubes.pdf> (18.01.2016).
- Utgoff P. E., (1989). “Incremental Induction of Decision Trees”, *Machine learning*, Volume: 4(2), 161 – 186.
- Venkatadri M., Reddy L. C., (2011). “A Review on Data Mining from Past to Future”, *International Journal of Computer Applications*, Volume 15 No. 7, 19 – 22.

- Vishwakarma P., Kumar Y., Nath R. K., (2012). “Data Mining Using GeneticAlgorithm (DMUGA)”, *International Journal of Engineering Research Engineering Research and Development*, Volume Issue 2, 88-94.
- Voß, S., & Lessmann, S. (2013). “Resale price prediction in the used car market”. In *Tristan Symposium VIII*.
- Web_1. (2016). <http://www.biyodoc.com//Sinir-sistemi-sinir-hucyelerinin-yapisi-ve-noron-cesitleri.html> (21.04.2016).
- Weinberger K. Q., Saul Lawrence K., (2009). “Distance Metric Learning for Large Margin Nearest Neighbor Classification”, *Journal of Machine Learning Research*, Volume: 10 (Şubat), 207 – 244.
- Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques*, Elsevier.
- Yingwei L., Sundararajan N., Saratchandran P., (1997). “A Sequential Learning Scheme for Function Approximation Using Minimal Radial Basis Function Neural Networks”, *Neural Computation*, Volume: 9, Issue: 2, 461 – 478.
- Zaiane O. R., (1999). *Principles of Knowledge Discovery in Databases*, University of Alberta.
- Zou K. H., Tuncali K., Silverman S. G., (2003). “Correlation and Simple Linear Regression”, *Radiology*, Volume: 227 (3), 617 – 628.

EKLER

EK – 1

Yapay Sinir Ağı Ve Doğrusal Regresyon Yöntemleri İle Tahmin Yapılan Araç Verileri

Sıra No	Marka	Model	Seri	Fiyat	Mod el Yılı	Kasa Tipi	Vites Tipi	Renk	Garan ti	Kilomet re	Yakıt Tipi	Kapı Sayısı
1	Acura	CL	3.2 Type-S	1700000	2003	Sedan	Manuel	Bordo	Hayır	199200	Benzin	4
2	Alfa Romeo	145	1.Haz	13250	1996	Hatchback	Manuel	Gri	Hayır	195000	Benzin	3
3	Alfa Romeo	145	1.7 16V	11500	1995	Hatchback	Manuel	Metalik gri	Hayır	238000	Benzin + LPG	3
4	Alfa Romeo	145	1.6 TS Sportivo	17750	2001	Hatchback	Manuel	Lacivert	Hayır	168000	Benzin + LPG	3
5	Alfa Romeo	145	1.7 16V	11500	1996	Hatchback	Manuel	Siyah	Hayır	235400	Benzin	3
6	Alfa Romeo	145	1.4 TS STD.	11500	1998	Hatchback	Manuel	Siyah	Hayır	139400	Benzin	3
7	Alfa Romeo	145	1.4 TS STD.	10000	1998	Hatchback	Manuel	Siyah	Hayır	147000	Benzin + LPG	3
8	Alfa Romeo	145	1.4 TS STD.	12250	1999	Hatchback	Manuel	Kırmızı	Hayır	120000	Benzin	3
9	Alfa Romeo	145	1.6 TS L	14000	2000	Hatchback	Manuel	Gri	Hayır	192000	Benzin	3
10	Alfa Romeo	146	1.6 L	13850	1996	Hatchback	Manuel	Beyaz	Hayır	194000	Benzin	5
11	Alfa Romeo	146	1.4 TS STD.	11000	1998	Hatchback	Manuel	Siyah	Hayır	265000	Benzin	5
12	Alfa Romeo	146	1.6 L	14000	1996	Hatchback	Manuel	Bordo	Hayır	198000	Benzin + LPG	5
13	Alfa Romeo	146	1.4 TS STD.	12500	1998	Hatchback	Manuel	Beyaz	Hayır	178000	Benzin	5
14	Alfa Romeo	146	1.6 L	13000	1997	Hatchback	Manuel	Bordo	Hayır	262800	Benzin + LPG	5
15	Alfa Romeo	147	1.6 T. Spark Progression	25500	2004	Hatchback	Manuel	Kırmızı	Hayır	141000	Benzin	5
16	Alfa Romeo	147	1.6 T. Spark Progression	28500	2006	Hatchback	Manuel	Bej	Hayır	136000	Benzin	5
17	Alfa Romeo	147	1.6 T. Spark Distinctive	22750	2005	Hatchback	Manuel	Kırmızı	Hayır	167000	Benzin + LPG	3
18	Alfa Romeo	147	1.6 T. Spark Progression	25000	2004	Hatchback	Manuel	Siyah	Hayır	178000	Benzin + LPG	5
19	Alfa Romeo	147	1.6 T. Spark Collezione	27000	2006	Hatchback	Manuel	Gri	Hayır	90000	Benzin	5
20	Alfa Romeo	147	1.6 T. Spark Progression	29800	2008	Hatchback	Manuel	Gri	Hayır	83000	Benzin	5
21	Alfa Romeo	147	2.0 T. Spark Distinctive	20500	2001	Hatchback	Manuel	Gri	Hayır	224000	Benzin + LPG	5
22	Alfa Romeo	147	1.6 T. Spark Distinctive	25750	2006	Hatchback	Manuel	Gri	Hayır	145000	Benzin	5
23	Alfa Romeo	147	1.6 T. Spark Distinctive	27500	2004	Hatchback	Manuel	Siyah	Hayır	200000	Benzin + LPG	5
24	Alfa Romeo	147	1.6 T. Spark Distinctive	29750	2008	Hatchback	Manuel	Siyah	Hayır	183000	Benzin + LPG	5
25	Alfa Romeo	147	1.6 T. Spark Distinctive	27500	2006	Hatchback	Manuel	Titanyum grisi	Hayır	142000	Benzin	5
26	Alfa Romeo	147	1.6 T. Spark Distinctive	36000	2008	Hatchback	Manuel	Siyah	Hayır	73000	Benzin	5
27	Alfa Romeo	147	1.6 T. Spark Progression	24000	2004	Hatchback	Manuel	Siyah	Hayır	141000	Benzin	5
28	Alfa Romeo	147	1.6 T. Spark Distinctive	23750	2006	Hatchback	Manuel	Kırmızı	Hayır	158000	Benzin + LPG	5
29	Alfa Romeo	147	1.6 T. Spark Distinctive	17600	2004	Hatchback	Manuel	Gri	Hayır	253309	Benzin + LPG	5
30	Alfa Romeo	147	1.6 T. Spark Distinctive	22500	2004	Hatchback	Manuel	Siyah	Hayır	143000	Benzin	5
31	Alfa Romeo	147	1.6 T. Spark Progression	26000	2004	Hatchback	Manuel	Kırmızı	Hayır	99000	Benzin + LPG	5
32	Alfa Romeo	147	1.6 T. Spark Distinctive	23500	2004	Hatchback	Manuel	Siyah	Hayır	86000	Benzin	5
33	Alfa Romeo	147	1.6 T. Spark Distinctive	23500	2004	Hatchback	Manuel	Kırmızı	Hayır	197000	Benzin	5
34	Alfa Romeo	147	1.6 T. Spark Distinctive	26000	2004	Hatchback	Manuel	Siyah	Hayır	88000	Benzin + LPG	5
35	Alfa Romeo	147	1.6 T. Spark Distinctive	24700	2004	Hatchback	Manuel	Gri	Hayır	106700	Benzin	5
36	Alfa Romeo	147	1.9 JTD 16V Q2	45750	2008	Hatchback	Manuel	Kırmızı	Hayır	180000	Dizel	5

37	Alfa Romeo	147	1.6 T. Spark Distinctive	25000	2004	Hatchback	Manuel	Kırmızı	Hayır	229000	Benzin + LPG	5
38	Alfa Romeo	147	1.6 T. Spark Distinctive	30500	2006	Hatchback	Manuel	Gri	Evet	168000	Benzin + LPG	5
39	Alfa Romeo	147	1.6 T. Spark Distinctive	23000	2003	Hatchback	Manuel	Yeşil	Hayır	162000	Benzin	5
40	Alfa Romeo	147	1.6 T. Spark Distinctive	26000	2003	Hatchback	Manuel	Kırmızı	Hayır	100000	Benzin	5
41	Alfa Romeo	147	1.6 T. Spark Distinctive	19000	2003	Hatchback	Manuel	Kahverengi	Hayır	162000	Benzin	5
42	Alfa Romeo	147	1.6 T. Spark Distinctive	26950	2006	Hatchback	Manuel	Bej	Hayır	120000	Benzin	5
43	Alfa Romeo	147	1.6 T. Spark Collezione	33000	2009	Hatchback	Manuel	Beyaz	Hayır	110000	Benzin + LPG	5
44	Alfa Romeo	147	1.6 T. Spark Distinctive	19850	2003	Hatchback	Manuel	Kırmızı	Hayır	124000	Benzin	5
45	Alfa Romeo	147	1.6 T. Spark Distinctive	27900	2005	Hatchback	Manuel	Bordo	Hayır	135000	Benzin	5
46	Alfa Romeo	147	1.6 T. Spark Progression	19900	2004	Hatchback	Manuel	Siyah	Hayır	149000	Benzin + LPG	3
47	Alfa Romeo	147	1.6 T. Spark Progression	24900	2007	Hatchback	Manuel	Kırmızı	Hayır	89000	Benzin	3
48	Alfa Romeo	156	1.6 16V T.Spark	20000	1998	Sedan	Manuel	Kırmızı	Hayır	205000	Benzin + LPG	4
49	Alfa Romeo	156	1.6 T. Spark Distinctive	26000	2004	Sedan	Manuel	Siyah	Hayır	219000	Benzin + LPG	5
50	Alfa Romeo	156	2.0 16V T. Spark Executive	25000	2001	Sedan	Manuel	Gri	Hayır	148000	Benzin	4
51	Alfa Romeo	156	1.6 T. Spark Distinctive	30000	2005	Sedan	Manuel	Gri	Hayır	229000	Benzin + LPG	4
52	Alfa Romeo	156	1.6 T. Spark Distinctive	23450	2004	Sedan	Manuel	Gri	Hayır	204000	Benzin	4
53	Alfa Romeo	156	1.6 16V T.Spark	20250	2000	Sedan	Manuel	Kırmızı	Hayır	240000	Benzin + LPG	4
54	Alfa Romeo	156	1.6 16V T. Spark Distinctive	19500	2001	Sedan	Manuel	Siyah	Hayır	212000	Benzin	4
55	Alfa Romeo	156	1.6 16V T. Spark Progression	22250	2002	Sedan	Manuel	Gri	Hayır	157000	Benzin	4
56	Alfa Romeo	156	1.6 16V T. Spark Distinctive	21750	2001	Sedan	Manuel	Kırmızı	Hayır	198000	Benzin + LPG	4
57	Alfa Romeo	156	1.6 T. Spark Distinctive	29750	2004	Sedan	Manuel	Siyah	Hayır	207000	Benzin + LPG	4
58	Alfa Romeo	156	1.6 T. Spark Distinctive	28000	2004	Sedan	Manuel	Gri	Hayır	91000	Benzin	4
59	Alfa Romeo	156	2.0 16V JTS Distinctive	25000	2005	Sedan	Otomatik	Bej	Hayır	242000	Benzin	4
60	Alfa Romeo	156	1.6 16V T.Spark	22000	1999	Sedan	Manuel	Gri	Hayır	271000	Benzin + LPG	4
61	Alfa Romeo	156	1.6 T. Spark Distinctive	30300	2006	Sedan	Manuel	Siyah	Hayır	119000	Benzin	4
62	Alfa Romeo	156	2.0 16V JTS Distinctive	20500	2001	Sedan	Tiptronik	Gri	Hayır	73600	Benzin	4
63	Alfa Romeo	156	1.6 16V T. Spark Distinctive	17500	1998	Sedan	Manuel	Kırmızı	Hayır	241000	Benzin + LPG	4
64	Alfa Romeo	156	1.6 T. Spark Distinctive	27750	2005	Sedan	Manuel	Bordo	Hayır	170000	Benzin + LPG	4
65	Alfa Romeo	156	2.0 16V T. Spark Selespeed	20500	2001	Sedan	Tiptronik	Gri	Hayır	158000	Benzin + LPG	4
66	Alfa Romeo	156	1.6 T. Spark Distinctive	27500	2005	Sedan	Manuel	Gri	Hayır	164000	Benzin + LPG	4
67	Alfa Romeo	156	2.0 16V T. Spark Executive	22000	2002	Sedan	Tiptronik	Gri	Hayır	225000	Benzin + LPG	4
68	Alfa Romeo	156	1.6 T. Spark Distinctive	25000	2004	Sedan	Manuel	Bej	Evet	190000	Benzin	4
69	Alfa Romeo	156	1.6 T. Spark Distinctive	26500	2004	Sedan	Manuel	Siyah	Hayır	81000	Benzin	4
70	Alfa Romeo	156	2.0 16V T. Spark Executive	18000	2002	Sedan	Manuel	Gri	Hayır	17000	Benzin + LPG	5
71	Alfa Romeo	156	SW 2.0 JTS Distinctive Selespeed	27000	2005	Sedan	Tiptronik	Siyah	Hayır	208000	Benzin + LPG	4
72	Alfa Romeo	156	1.6 T. Spark Distinctive	31300	2004	Sedan	Manuel	Kırmızı	Hayır	168000	Benzin	4
73	Alfa Romeo	156	1.6 16V T.Spark	15500	1998	Sedan	Manuel	Kırmızı	Hayır	222000	Benzin	4
74	Alfa Romeo	156	2.0 16V T. Spark Executive	18750	2002	Sedan	Manuel	Krem	Hayır	136000	Benzin + LPG	4
75	Alfa Romeo	156	1.6 T. Spark Distinctive	28500	2004	Sedan	Manuel	Bordo	Hayır	208000	Benzin	4
76	Alfa Romeo	156	2.0 16V T. Spark	23000	2000	Sedan	Otomatik	Kırmızı	Hayır	237600	Benzin + LPG	5
77	Alfa Romeo	156	2.0 16V T. Spark	19000	1999	Sedan	Manuel	Gri	Hayır	163000	Benzin + LPG	4
78	Alfa Romeo	156	2.0 16V JTS Distinctive	20500	1996	Sedan	Manuel	Gri	Hayır	244400	Benzin + LPG	4
79	Alfa Romeo	156	2.0 16V T. Spark	18500	1999	Sedan	Manuel	Siyah	Hayır	207000	Benzin	4

80	Alfa Romeo	156	1.6 T. Spark Distinctive	29000	2005	Sedan	Manuel	SarA=	Hayır	173000	Benzin + LPG	4
81	Alfa Romeo	156	2.0 16V T. Spark	21750	1998	Sedan	Manuel	Kırmızı	Hayır	184000	Benzin + LPG	4
82	Alfa Romeo	156	2.0 16V T. Spark Executive	19250	2002	Sedan	Manuel	Bej	Hayır	147000	Benzin	4
83	Alfa Romeo	156	1.6 T. Spark Progression	24000	2004	Sedan	Manuel	Gri	Hayır	220000	Benzin	4
84	Alfa Romeo	156	2.0 16V T. Spark	12000	1998	Sedan	Manuel	Siyah	Hayır	240000	Benzin	4
85	Alfa Romeo	156	SW 2.0 JTS 16V JTS Distinctive Selespeed	21000	2002	Sedan	Tiptronik	Gümüş	Hayır	190000	Benzin + LPG	4
86	Alfa Romeo	156	2.0 16V T. Spark	16500	1998	Hatchback	Manuel	Metalik gri	Hayır	220000	Benzin + LPG	5
87	Alfa Romeo	156	1.6 T. Spark Distinctive	28500	2006	Sedan	Manuel	Siyah	Hayır	99000	Benzin	4
88	Alfa Romeo	156	1.6 16V T. Spark	15000	1999	Sedan	Manuel	Siyah	Hayır	180000	Benzin	4
89	Alfa Romeo	156	2.0 16V T. Spark Selespeed	25000	2001	Sedan	Tiptronik	Siyah	Evet	121000	Benzin + LPG	4
90	Alfa Romeo	159	1.9 JTD Distinctive Q-tronic	39500	2008	Sedan	Otomatik	Siyah	Hayır	220000	Dizel	4
91	Alfa Romeo	159	1.9 JTD Distinctive Plus Q-tronic	46500	2008	Sedan	Otomatik	Siyah	Hayır	183000	Dizel	4
92	Alfa Romeo	159	1.9 JTD Distinctive Plus Q-tronic	45000	2008	Sedan	Otomatik	Siyah	Hayır	198434	Dizel	4
93	Alfa Romeo	164	2.0 Twin Spark	4000	1989	Sedan	Manuel	Metalik mavi	Hayır	396000	Benzin + LPG	4
94	Alfa Romeo	33	1.5 I.E.	8000	1991	Hatchback	Manuel	Beyaz	Hayır	130000	Benzin	5
95	Alfa Romeo	33	1.5 4x4 Giardinetta	6500	1990	Hatchback	Manuel	Siyah	Evet	100000	Benzin	5
96	Alfa Romeo	75	2.0 Twin Spark	25000	1987	Sedan	Manuel	Yeşil	Hayır	238000	Benzin + LPG	4
97	Alfa Romeo	GT	2.0 JTS Distinctive Selespeed	40000	2006	Coupe	S-Tronik	Siyah	Hayır	116000	Benzin	2
98	Alfa Romeo	GT	2.0 JTS Distinctive Selespeed	51250	2006	Coupe	S-Tronik	Siyah	Hayır	23750	Benzin	2
99	Alfa Romeo	GT	2.0 JTS Distinctive	200000	2007	Coupe	Manuel	Kırmızı	Hayır	111600	Benzin	2
100	Alfa Romeo	GTV	2.0 V6 TB	22000	1996	Coupe	Manuel	Gri	Hayır	142000	Benzin	2
101	Alfa Romeo	Giulietta	1.6 JTD Distinctive	53000	2013	Hatchback	Manuel	Beyaz	Hayır	60450	Dizel	5
102	Alfa Romeo	Giulietta	1.4 TB Distinctive MultiAir TCT	69900	2015	Hatchback	Otomatik	Beyaz	Evet	27500	Benzin	5
103	Alfa Romeo	Giulietta	1.4 TB Progression Plus	54750	2013	Hatchback	Manuel	Beyaz	Hayır	35000	Benzin	5
104	Alfa Romeo	Giulietta	1.6 JTD Distinctive	75000	2014	Hatchback	Manuel	Kırmızı	Evet	22500	Dizel	5
105	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	62000	2013	Hatchback	Otomatik	Beyaz	Hayır	49000	Benzin	5
106	Alfa Romeo	Giulietta	1.4 TB Progression Plus	53000	2011	Hatchback	Manuel	Kırmızı	Evet	45000	Benzin	5
107	Alfa Romeo	Giulietta	1.6 JTD Distinctive	66000	2015	Hatchback	Manuel	Siyah	Evet	37000	Dizel	5
108	Alfa Romeo	Giulietta	1.6 JTD Distinctive	57500	2012	Hatchback	Manuel	Beyaz	Hayır	81500	Dizel	5
109	Alfa Romeo	Giulietta	1.6 JTD Distinctive	59900	2012	Hatchback	Manuel	Kırmızı	Hayır	99000	Dizel	5
110	Alfa Romeo	Giulietta	1.6 JTD Distinctive	51000	2011	Hatchback	Manuel	Beyaz	Hayır	105000	Dizel	5
111	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	57000	2012	Hatchback	Manuel	Beyaz	Hayır	74000	Benzin	5
112	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	56000	2011	Hatchback	Manuel	Beyaz	Hayır	76500	Benzin	5
113	Alfa Romeo	Giulietta	1.4 TB Distinctive	52000	2012	Hatchback	Manuel	Siyah	Hayır	55000	Benzin	5
114	Alfa Romeo	Giulietta	1.6 JTD Progression Plus	51000	2011	Hatchback	Manuel	Beyaz	Hayır	116000	Dizel	5
115	Alfa Romeo	Giulietta	1.4 TB Distinctive MultiAir TCT	68500	2014	Hatchback	Otomatik	Beyaz	Evet	47000	Benzin	5
116	Alfa Romeo	Giulietta	1.6 JTD Distinctive	100000	2015	Hatchback	Manuel	Kırmızı	Evet	16800	Dizel	5
117	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	64500	2012	Hatchback	Manuel	Kırmızı	Evet	47500	Benzin	5
118	Alfa Romeo	Giulietta	1.6 JTD Distinctive	54500	2011	Hatchback	Manuel	Beyaz	Hayır	110000	Dizel	5
119	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	67000	2012	Hatchback	Otomatik	Kırmızı	Hayır	106000	Benzin	5
120	Alfa Romeo	Giulietta	1.6 JTD Distinctive	68500	2013	Hatchback	Manuel	Beyaz	Evet	19000	Dizel	5
121	Alfa Romeo	Giulietta	1.6 JTD Distinctive	61500	2013	Hatchback	Manuel	Metalik gri	Evet	20850	Dizel	5
122	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	58000	2011	Hatchback	Manuel	Beyaz	Hayır	40750	Benzin	5

123	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	53500	2011	Hatchback	Manuel	Beyaz	Hayır	120000	Benzin	5
124	Alfa Romeo	Giulietta	1.6 JTD Distinctive	47750	2011	Hatchback	Manuel	Beyaz	Hayır	144000	Dizel	5
125	Alfa Romeo	Giulietta	1.6 JTD Distinctive	61500	2012	Hatchback	Manuel	Beyaz	Evet	26000	Dizel	5
126	Alfa Romeo	Giulietta	1.6 JTD Distinctive	55000	2011	Hatchback	Manuel	Siyah	Hayır	108000	Dizel	5
127	Alfa Romeo	Giulietta	1.4 TB Progression Plus	66000	2014	Hatchback	Manuel	Kırmızı	Hayır	14007	Dizel	Bilinmiyor
128	Alfa Romeo	Giulietta	1.6 JTD Distinctive	52500	2013	Hatchback	Manuel	Kırmızı	Hayır	40100	Dizel	Bilinmiyor
129	Alfa Romeo	Giulietta	1.6 JTD Distinctive	66000	2014	Hatchback	Manuel	Kırmızı	Hayır	9799	Dizel	Bilinmiyor
130	Alfa Romeo	Giulietta	1.6 JTD Distinctive	67000	2014	Sedan	Manuel	Kırmızı	Hayır	7816	Dizel	Bilinmiyor
131	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	63500	2012	Hatchback	Manuel	Beyaz	Hayır	18500	Benzin	5
132	Alfa Romeo	Giulietta	1.6 JTD Distinctive	66500	2013	Hatchback	Manuel	Beyaz	Evet	29900	Dizel	5
133	Alfa Romeo	Giulietta	1.4 TB Distinctive	56750	2011	Hatchback	Manuel	Beyaz	Hayır	60000	Benzin	5
134	Alfa Romeo	Giulietta	1.4 TB Distinctive	55500	2011	Hatchback	Manuel	Beyaz	Hayır	60000	Benzin	5
135	Alfa Romeo	Giulietta	1.6 JTD Distinctive	67000	2015	Hatchback	Manuel	Gri	Hayır	34000	Dizel	5
136	Alfa Romeo	Giulietta	1.6 JTD Progression Plus	58000	2013	Hatchback	Manuel	Beyaz	Hayır	80000	Dizel	5
137	Alfa Romeo	Giulietta	1.6 JTD Distinctive	67500	2015	Hatchback	Manuel	Mavi	Hayır	34000	Dizel	5
138	Alfa Romeo	Giulietta	1.6 JTD Progression Plus	50000	2011	Hatchback	Manuel	Kırmızı	Hayır	87200	Dizel	5
139	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	50000	2011	Hatchback	Manuel	Kırmızı	Hayır	48000	Benzin	5
140	Alfa Romeo	Giulietta	1.6 JTD Progression Plus	56500	2012	Hatchback	Manuel	Kırmızı	Hayır	65000	Dizel	5
141	Alfa Romeo	Giulietta	1.6 JTD Distinctive	60000	2012	Hatchback	Manuel	Beyaz	Evet	53000	Dizel	5
142	Alfa Romeo	Giulietta	1.6 JTD Distinctive	67000	2014	Sedan	Manuel	Kırmızı	Hayır	6800	Dizel	Bilinmiyor
143	Alfa Romeo	Giulietta	1.6 JTD Distinctive	67000	2014	Hatchback	Manuel	Siyah	Hayır	6092	Dizel	Bilinmiyor
144	Alfa Romeo	Giulietta	1.6 JTD Distinctive	67000	2014	Sedan	Manuel	Beyaz	Hayır	9012	Dizel	Bilinmiyor
145	Alfa Romeo	Giulietta	1.6 JTD Distinctive	67000	2014	Sedan	Manuel	Kırmızı	Hayır	13620	Dizel	Bilinmiyor
146	Alfa Romeo	Giulietta	1.6 JTD Distinctive	57000	2013	Hatchback	Manuel	Beyaz	Hayır	21578	Dizel	Bilinmiyor
147	Alfa Romeo	Giulietta	1.6 JTD Distinctive	57000	2013	Hatchback	Manuel	Beyaz	Hayır	34621	Dizel	Bilinmiyor
148	Alfa Romeo	Giulietta	1.4 TB Progression Plus	62000	2012	Hatchback	Manuel	Bordo	Evet	60000	Benzin	5
149	Alfa Romeo	Giulietta	1.4 TB Distinctive MultiAir TCT	66000	2014	Hatchback	Manuel	Kırmızı	Hayır	8250	Dizel	Bilinmiyor
150	Alfa Romeo	Giulietta	1.6 JTD Distinctive	68000	2014	Sedan	Manuel	Beyaz	Hayır	8284	Dizel	Bilinmiyor
151	Alfa Romeo	Giulietta	1.4 TB MultiAir Distinctive	56500	2012	Hatchback	Manuel	Füme	Hayır	35000	Benzin	5
152	Alfa Romeo	Mito	1.4 T MultiAir Quadrifoglio Verde	51500	2011	Hatchback	Manuel	Siyah	Hayır	75000	Benzin	3
153	Alfa Romeo	Mito	1.6 JTD Progression	38000	2009	Hatchback	Manuel	Siyah	Hayır	118500	Dizel	3
154	Alfa Romeo	Mito	1.3 JTD City	46500	2012	Hatchback	Manuel	Beyaz	Hayır	51000	Dizel	3
155	Alfa Romeo	Mito	1.3 JTD City	49000	2013	Hatchback	Manuel	Kırmızı	Evet	40900	Dizel	3
156	Alfa Romeo	Mito	1.6 JTD Distinctive	37000	2011	Hatchback	Manuel	Beyaz	Hayır	188000	Dizel	3
157	Anadol	1.Haz		1250	1979	Sedan	Manuel	Beyaz	Hayır	544800	Benzin + LPG	2
158	Anadol	1.Haz		7000	1976	Stationvagon	Manuel	Mavi	Hayır	10000	Benzin	4
159	Anadol	1.Haz		6000	1991	Pick up	Manuel	Beyaz	Hayır	89000	Benzin + LPG	2
160	Anadol	1.Haz		6750	1991	Pick up	Manuel	Beyaz	Hayır	100000	Benzin + LPG	2
161	Anadol	1.Haz	SV	3000	1978	Stationvagon	Manuel	Kırmızı	Hayır	54850	Benzin	5
162	Anadol	1.Haz		4500	1983	Pick up	Manuel	Bej	Hayır	2000	Benzin + LPG	2
163	Anadol	A1		19500	1968	Coupe	Manuel	Turuncu	Hayır	100000	Benzin	2
164	Anadol	A1		12750	1971	Coupe	Manuel	Beyaz	Hayır	98000	Benzin	2
165	Anadol	A1		15000	1969	Coupe	Manuel	Beyaz	Hayır	100000	Benzin + LPG	2

166	Anadol	A1		6900	1971	Coupe	Manuel	Beyaz	Hayır	120000	Benzin + LPG	2
167	Anadol	A1		8750	1968	Cabrio	Manuel	Kırmızı	Hayır	57000	Benzin	2
168	Anadol	A2		9000	1974	Sedan	Manuel	Beyaz	Hayır	109000	Benzin	4
169	Anadol	A2		10000	1975	Sedan	Manuel	Beyaz	Hayır	92000	Benzin	4
170	Anadol	A2		19500	1978	Sedan	Manuel	Beyaz	Hayır	53000	Benzin	4
171	Anadol	A2		5500	1979	Sedan	Manuel	Beyaz	Hayır	90000	Benzin + LPG	4
172	Anadol	A8		7950	1979	Pick up	Manuel	SarA±	Hayır	81000	Dizel	2
173	Anadol	A8		7950	1979	Pick up	Manuel	SarA±	Hayır	81000	Dizel	2
174	Aro	Cross Lander	CL 244	25000	2000	SUV	Manuel	Mavi	Hayır	232800	Benzin	3
175	Audi	100	1.Haz	94000	2013	Sedan	S-Tronik	Siyah	Evet	86000	Dizel	4
176	Audi	200	2.2 Quattro	15000	1985	Sedan	Manuel	Kırmızı	Hayır	149500	Benzin	4
177	Audi	80	1.6 D	5100	1983	Sedan	Manuel	Yeşil	Hayır	200000	Dizel	4
178	Audi	80	1.6 D	9900	1980	Sedan	Manuel	Yeşil	Hayır	100000	Dizel	4
179	Audi	80	1.Haz	13500	1983	Sedan	Manuel	Gri	Hayır	218000	Benzin	4
180	Audi	80	1.Haz	13450	1984	Sedan	Manuel	Yeşil	Hayır	227000	Benzin + LPG	4
181	Audi	80	1.6 D	4000	1980	Sedan	Manuel	Buz Yeşil	Hayır	190000	Dizel	4
182	Audi	80	1.8 S	15000	1991	Sedan	Manuel	Gri	Hayır	150000	Benzin + LPG	4
183	Audi	80	1.6 D	13500	1988	Sedan	Manuel	Krem	Hayır	317500	Dizel	4
184	Audi	80	1.6 D	13850	1983	Sedan	Manuel	Beyaz	Hayır	625000	Dizel	4
185	Audi	80	1.6 D	5250	1982	Sedan	Manuel	Beyaz	Evet	2580	Dizel	4
186	Audi	80	2	22000	1992	Sedan	Otomatik	Siyah	Hayır	315000	Benzin + LPG	4
187	Audi	80	1.Haz	9000	1991	Sedan	Manuel	Gri	Hayır	294000	Benzin	4
188	Audi	90	TD	7500	1986	Sedan	Manuel	Kırmızı	Hayır	144400	Dizel	5
189	Audi	A1	1.6 TDI Sportback Attraction S-tronic	70000	2012	Hatchback	S-Tronik	Bej	Hayır	18300	Dizel	5
190	Audi	A1	1.4 TFSI Sportback Attraction S-tronic	54500	2012	Hatchback	S-Tronik	Siyah	Hayır	87000	Benzin	3
191	Audi	A1	1.4 TFSI Attraction	44500	2011	Coupe	S-Tronik	Beyaz	Hayır	122000	Benzin	2
192	Audi	A1	1.4 TFSI Sportback Ambition S-tronic	45500	2011	Hatchback	S-Tronik	Mavi	Hayır	68000	Benzin	3
193	Audi	A1	1.4 TFSI Sportback Attraction S-tronic	74000	2012	Hatchback	S-Tronik	Beyaz	Hayır	42300	Benzin	5
194	Audi	A2	1.4 TDI	93000	2013	Hatchback	S-Tronik	Beyaz	Hayır	33000	Dizel	5
195	Audi	A3	1.6 Ambiente	42000	2006	Hatchback	Manuel	Siyah	Hayır	120000	Benzin	5
196	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	85000	2015	Hatchback	S-Tronik	Beyaz	Evet	27600	Dizel	5
197	Audi	A3	1.6 Sportback Attraction	55000	2009	Hatchback	Manuel	Siyah	Hayır	65000	Benzin	5
198	Audi	A3	1.4 TFSI Attraction	95000	2015	Sedan	Manuel	Siyah	Hayır	43000	Benzin	4
199	Audi	A3	1.6 FSI Sportback	51000	2006	Hatchback	Manuel	Siyah	Hayır	135000	Benzin	5
200	Audi	A3	1.8 TFSI	77000	2010	Cabrio	Otomatik	Beyaz	Hayır	63000	Benzin	2
201	Audi	A3	1.6 TDI Sportback Attraction S-tronic	69990	2012	Hatchback	S-Tronik	Beyaz	Hayır	60600	Dizel	5
202	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	80250	2012	Hatchback	S-Tronik	Beyaz	Evet	67000	Dizel	5
203	Audi	A3	1.4 TFSI Attraction	72900	2011	Hatchback	Manuel	Siyah	Hayır	51000	Benzin	5
204	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	97900	2016	Hatchback	S-Tronik	Siyah	Evet	15670	Dizel	5
205	Audi	A3	1.6 TDI Attraction S-tronic	69990	2012	Hatchback	Tiptronik	Beyaz	Hayır	60065	Dizel	Bilimiy or
206	Audi	A3	1.4 TFSI	44000	2008	Hatchback	Manuel	Siyah	Hayır	151000	Benzin	5
207	Audi	A3	1.4 TFSI Ambiente S-tronic	86800	2013	Sedan	S-Tronik	Gri	Evet	30000	Benzin	4
208	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	64000	2010	Hatchback	S-Tronik	Siyah	Hayır	50000	Benzin	5

209	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	76000	2012	Hatchback	S-Tronic	Beyaz	Hayır	54300	Dizel	5
210	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	81500	2014	Hatchback	S-Tronic	Siyah	Hayır	42000	Benzin	5
211	Audi	A3	1.6 TDI Ambiente S-tronic	115500	2015	Sedan	S-Tronic	Beyaz	Evet	14000	Dizel	4
212	Audi	A3	1.4 TFSI Ambition	89000	2013	Hatchback	Manuel	Beyaz	Hayır	31000	Benzin	5
213	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	67750	2012	Hatchback	S-Tronic	Beyaz	Hayır	82000	Benzin	5
214	Audi	A3	1.6 TDI Attraction	99000	2014	Hatchback	Manuel	Siyah	Hayır	57000	Dizel	5
215	Audi	A3	1.6 Ambiente	38500	2004	Coupe	Manuel	Gri	Hayır	186500	Benzin	3
216	Audi	A3	1.6 TDI Attraction	100000	2014	Sedan	Otomatik	Siyah	Hayır	60000	Benzin	5
217	Audi	A3	1.6 Sportback	51500	2011	Hatchback	Manuel	Beyaz	Hayır	81000	Benzin	Bilinmiyor
218	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	55500	2010	Hatchback	S-Tronic	Beyaz	Hayır	110000	Benzin	5
219	Audi	A3	1.4 TFSI Sportback Attraction	50000	2010	Hatchback	Tiptronic	Beyaz	Hayır	120000	Benzin	5
220	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	51500	2009	Hatchback	Otomatik	Siyah	Hayır	168000	Benzin	5
221	Audi	A3	1.6 Ambiente	20000	1998	Hatchback	Manuel	Turuncu	Hayır	240000	Benzin	3
222	Audi	A3	1.6 TDI Attraction S-tronic	71000	2012	Hatchback	Tiptronic	Beyaz	Hayır	69000	Dizel	Bilinmiyor
223	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	92250	2013	Hatchback	S-Tronic	Kırmızı	Hayır	81000	Dizel	5
224	Audi	A3	1.4 TFSI Attraction	81000	2013	Sedan	S-Tronic	Beyaz	Hayır	16000	Benzin	4
225	Audi	A3	1.4 TFSI Attraction	97500	2014	Sedan	S-Tronic	Beyaz	Hayır	25400	Benzin	4
226	Audi	A3	3.2 V6 Quattro Ambition DSG	36250	2006	Hatchback	Manuel	Siyah	Hayır	179400	Benzin + LPG	3
227	Audi	A3	1.6 TDI Ambition S-tronic	93000	2014	Hatchback	S-Tronic	Beyaz	Hayır	43500	Dizel	5
228	Audi	A3	1.6 Sportback Attraction	28500	2001	Hatchback	Manuel	Mavi	Hayır	239000	Benzin + LPG	5
229	Audi	A3	1.6 Sportback Attraction	44000	2007	Hatchback	Otomatik	Mavi	Hayır	180000	Benzin + LPG	5
230	Audi	A3	1.4 TFSI Ambition	45500	2008	Hatchback	Manuel	Siyah	Hayır	105000	Benzin	2
231	Audi	A3	1.6 TDI Ambition S-tronic	81250	2013	Hatchback	S-Tronic	Siyah	Hayır	67000	Dizel	4
232	Audi	A3	1.6 FSI Sportback	48500	2007	Hatchback	Manuel	Siyah	Hayır	129000	Benzin	5
233	Audi	A3	1.6 TDI Sportback Attraction	65900	2012	Hatchback	Otomatik	Siyah	Hayır	70000	Dizel	Bilinmiyor
234	Audi	A3	1.6 FSI Sportback	43000	2005	Hatchback	Manuel	Füme	Hayır	95000	Benzin	5
235	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	87500	2015	Hatchback	S-Tronic	Siyah	Hayır	18000	Dizel	5
236	Audi	A3	1.8 Attraction	22200	1999	Hatchback	Manuel	Mavi	Hayır	327000	Benzin + LPG	5
237	Audi	A3	1.4 TFSI Ambition	92000	2015	Hatchback	S-Tronic	Kırmızı	Evet	9250	Benzin	5
238	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	76500	2012	Hatchback	S-Tronic	Beyaz	Hayır	52000	Benzin	5
239	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	75750	2012	Hatchback	S-Tronic	Beyaz	Hayır	70000	Dizel	5
240	Audi	A3	1.6 Sportback	116000	2015	Hatchback	S-Tronic	Beyaz	Evet	10600	Dizel	5
241	Audi	A3	1.6 FSI	38700	2006	Hatchback	Manuel	Gri	Hayır	101	Benzin	3
242	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	52500	2009	Hatchback	S-Tronic	Gri	Evet	95000	Benzin	5
243	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	108000	2014	Hatchback	S-Tronic	Kırmızı	Hayır	50000	Dizel	5
244	Audi	A3	1.6 TDI Ambiente S-tronic	95000	2014	Sedan	S-Tronic	Siyah	Hayır	59600	Dizel	4
245	Audi	A3	1.6 Sportback	55500	2007	Hatchback	Otomatik	Siyah	Hayır	120000	Benzin	5
246	Audi	A3	2.0 TDI	36000	2004	Hatchback	Manuel	Siyah	Hayır	299999	Dizel	3
247	Audi	A3	1.6 TDI Sportback Attraction S-tronic	96000	2015	Hatchback	S-Tronic	Siyah	Evet	16400	Dizel	5
248	Audi	A3	1.6 FSI Sportback	37850	2006	Hatchback	Manuel	Kırmızı	Hayır	152400	Benzin	5
249	Audi	A3	1.6 Ambition	25500	2000	Hatchback	Otomatik	Bordo	Hayır	245000	Benzin + LPG	5
250	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	83000	2012	Hatchback	S-Tronic	Beyaz	Evet	68000	Dizel	5
251	Audi	A3	1.6 TDI Sportback Attraction	99500	2015	Hatchback	S-Tronic	Beyaz	Evet	20500	Dizel	5

252	Audi	A3	1.4 TFSI Attraction	92000	2013	Sedan	S-Tronik	Siyah	Hayır	7300	Benzin	4
253	Audi	A3	1.6 TDI Sportback Attraction	67000	2013	Hatchback	Otomatik	Siyah	Hayır	75207	Dizel	5
254	Audi	A3	1.4 TFSI Ambition S-tronic	57000	2011	Hatchback	S-Tronik	Beyaz	Hayır	79000	Benzin	3
255	Audi	A3	1.6 TDI Attraction	83000	2013	Hatchback	Otomatik	Beyaz	Evet	98000	Dizel	5
256	Audi	A3	1.4 TFSI Sportback	83500	2013	Hatchback	Tiptronik	Siyah	Hayır	28000	Benzin	Bilinmiyor
257	Audi	A3	1.6 Ambiente	28500	2000	Hatchback	Manuel	Mavi	Hayır	191000	Benzin	5
258	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	57000	2010	Hatchback	S-Tronik	Beyaz	Hayır	115000	Benzin	5
259	Audi	A3	1.6 TDI Ambition S-tronic	97750	2015	Hatchback	S-Tronik	Siyah	Evet	35500	Dizel	5
260	Audi	A3	1.6 Sportback Attraction S-Tronic	63700	2010	Hatchback	S-Tronik	Beyaz	Hayır	74400	Benzin + LPG	5
261	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	70000	2011	Hatchback	S-Tronik	Beyaz	Hayır	33000	Benzin	5
262	Audi	A3	1.4 TFSI Ambition	57500	2009	Hatchback	Manuel	Beyaz	Hayır	150000	Benzin	5
263	Audi	A3	1.6 Sportback	55500	2010	Hatchback	Manuel	Beyaz	Hayır	75000	Benzin	Bilinmiyor
264	Audi	A3	1.4 TFSI	45000	2008	Hatchback	S-Tronik	Gri	Hayır	130000	Benzin	5
265	Audi	A3	1.6 Sportback	40000	2006	Hatchback	Tiptronik	Siyah	Hayır	170000	Benzin + LPG	5
266	Audi	A3	1.6 Attraction S-Tronic	55000	2010	Hatchback	S-Tronik	Beyaz	Hayır	164000	Benzin + LPG	5
267	Audi	A3	1.4 TFSI Ambition	73000	2012	Hatchback	Manuel	Metalik mavi	Hayır	79000	Benzin	5
268	Audi	A3	1.2 TFSI Sportback Attraction	57250	2012	Hatchback	Manuel	Okyanus mavi	Evet	79000	Benzin	5
269	Audi	A3	1.6 Attraction	52000	2008	Hatchback	Otomatik	Siyah	Hayır	55000	Benzin	3
270	Audi	A3	1.6 Sportback Attraction	47500	2008	Hatchback	Tiptronik	Füme	Hayır	126000	Benzin	5
271	Audi	A3	1.6 TDI Ambition S-tronic	105000	2014	Sedan	Tiptronik	Beyaz	Evet	35000	Dizel	4
272	Audi	A3	1.6 TDI Sportback Attraction	68500	2012	Hatchback	Otomatik	Beyaz	Hayır	73000	Dizel	Bilinmiyor
273	Audi	A3	1.Haz	30000	2004	Hatchback	Manuel	Mavi	Hayır	127000	Benzin	3
274	Audi	A3	1.6 TDI Attraction	93500	2015	Sedan	Otomatik	Beyaz	Hayır	16400	Dizel	4
275	Audi	A3	1.4 TFSI Ambition S-tronic	53500	2009	Coupe	S-Tronik	Gri	Hayır	87000	Benzin	3
276	Audi	A3	1.6 Sportback Attraction	45000	2006	Hatchback	Manuel	Mavi	Hayır	40000	Benzin	5
277	Audi	A3	1.6 TDI Attraction	89000	2014	Sedan	S-Tronik	Beyaz	Hayır	26000	Dizel	4
278	Audi	A3	1.6 TDI Ambition S-tronic	106000	2014	Sedan	S-Tronik	Siyah	Evet	51000	Dizel	4
279	Audi	A3	1.6 Sportback Attraction	59500	2009	Hatchback	Otomatik	Beyaz	Hayır	56000	Benzin	5
280	Audi	A3	2.0 TDI Sportback Attraction Quattro	59000	2007	Hatchback	Manuel	Gri	Hayır	167000	Dizel	5
281	Audi	A3	1.Haz	8000	2005	Hatchback	Manuel	Mavi	Hayır	66000	Benzin	5
282	Audi	A3	1.8 Attraction	28750	2000	Hatchback	Otomatik	Siyah	Hayır	180000	Benzin	3
283	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	67000	2011	Hatchback	S-Tronik	Kırmızı	Hayır	93000	Benzin	5
284	Audi	A3	1.6 TDI Attraction	109000	2014	Sedan	S-Tronik	Beyaz	Evet	24500	Dizel	4
285	Audi	A3	2.0 TFSI Sportback	45000	2006	Hatchback	Tiptronik	Siyah	Hayır	135000	Benzin	3
286	Audi	A3	1.4 TFSI Ambition	67500	2010	Hatchback	S-Tronik	Beyaz	Hayır	62500	Benzin	5
287	Audi	A3	1.6 Sportback Attraction S-Tronic	55000	2009	Hatchback	S-Tronik	Gri	Hayır	29000	Benzin	5
288	Audi	A3	1.6 TDI Sportback Attraction S-tronic	86000	2013	Hatchback	S-Tronik	Beyaz	Evet	41000	Dizel	5
289	Audi	A3	1.6 FSI	34000	2006	Hatchback	Manuel	Siyah	Hayır	176700	Benzin	3
290	Audi	A3	1.6 TDI Attraction	61000	2011	Hatchback	Otomatik	Beyaz	Hayır	133000	Dizel	5
291	Audi	A3	1.6 Ambition	42500	2006	Coupe	Manuel	Kırmızı	Hayır	115000	Benzin	3
292	Audi	A3	1.6 Sportback	50000	2008	Hatchback	Tiptronik	Gri	Evet	61500	Benzin	5
293	Audi	A3	1.6 TDI Attraction	84900	2014	Sedan	Otomatik	Siyah	Hayır	35000	Dizel	Bilinmiyor
294	Audi	A3	1.6 TDI Sportback Attraction S-tronic	70000	2013	Hatchback	S-Tronik	Siyah	Hayır	147000	Dizel	5

295	Audi	A3	1.6 TDI Attraction	80000	2013	Hatchback	S-Tronik	Kırmızı	Hayır	30000	Dizel	5
296	Audi	A3	1.6 Sportback Attraction	44500	2007	Hatchback	Manuel	Gri	Hayır	125000	Benzin	5
297	Audi	A3	1.6 TDI Ambition S-tronic	76000	2012	Hatchback	S-Tronik	Siyah	Hayır	59500	Dizel	5
298	Audi	A3	1.6 Sportback Attraction	8950	2008	Hatchback	Manuel	Gri	Hayır	90000	Benzin	5
299	Audi	A3	1.6 TDI Sportback Attraction S-tronic	89500	2014	Hatchback	S-Tronik	Beyaz	Hayır	8500	Dizel	5
300	Audi	A3	1.6 Sportback Attraction	35000	2008	Hatchback	Manuel	Siyah	Evet	120000	Benzin	3
301	Audi	A3	1.6 Sportback Attraction	57500	2011	Hatchback	Manuel	Beyaz	Hayır	80000	Benzin	5
302	Audi	A3	1.8 Attraction	17500	1998	Hatchback	Manuel	Gri	Hayır	264000	Benzin + LPG	3
303	Audi	A3	1.6 Sportback Attraction	51000	2010	Hatchback	Manuel	Siyah	Hayır	133000	Benzin + LPG	5
304	Audi	A3	1.4 TFSI Attraction	110000	2014	Sedan	S-Tronik	Bej	Evet	19500	Dizel	4
305	Audi	A3	1.6 TDI Sportback Attraction S-tronic	92000	2013	Hatchback	S-Tronik	Kahverengi	Evet	34500	Dizel	5
306	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	52000	2011	Hatchback	S-Tronik	Gri	Hayır	140000	Benzin	5
307	Audi	A3	1.6 FSI	38500	2006	Hatchback	Manuel	Siyah	Hayır	60000	Benzin	3
308	Audi	A3	1.6 Sportback	61999	2012	Hatchback	Manuel	Siyah	Hayır	24000	Benzin	5
309	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	58500	2011	Hatchback	S-Tronik	Siyah	Hayır	57500	Benzin	5
310	Audi	A3	1.6 TDI Sportback Attraction S-tronic	83750	2013	Hatchback	S-Tronik	Siyah	Hayır	29000	Dizel	5
311	Audi	A3	1.6 Sportback	55000	2012	Hatchback	Manuel	Beyaz	Evet	40000	Benzin	5
312	Audi	A3	1.6 TDI Ambition S-tronic	80000	2012	Hatchback	S-Tronik	Siyah	Evet	47000	Dizel	3
313	Audi	A3	1.6 Ambiente	61250	2011	Hatchback	Manuel	Beyaz	Hayır	48000	Benzin	5
314	Audi	A3	1.6 TDI Ambition S-tronic	116000	2014	Sedan	S-Tronik	Beyaz	Evet	16500	Dizel	4
315	Audi	A3	1.8 TFSI Attraction	73000	2009	Cabrio	Otomatik	Beyaz	Hayır	99600	Benzin	2
316	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	60000	2011	Hatchback	S-Tronik	Beyaz	Hayır	98000	Benzin	5
317	Audi	A3	1.6 TDI Attraction	90750	2014	Sedan	S-Tronik	Siyah	Evet	25000	Dizel	4
318	Audi	A3	1.6 TDI Attraction	93250	2015	Sedan	S-Tronik	Siyah	Evet	11500	Dizel	4
319	Audi	A3	1.6 TDI Sportback Attraction S-tronic	107500	2015	Hatchback	S-Tronik	Siyah	Evet	12000	Dizel	5
320	Audi	A3	1.6 Ambition	51900	2010	Hatchback	Manuel	Siyah	Hayır	65000	Benzin + LPG	5
321	Audi	A3	1.6 TDI Attraction	102000	2014	Sedan	Otomatik	Siyah	Hayır	24500	Dizel	4
322	Audi	A3	1.4 TFSI Attraction	76900	2013	Hatchback	Otomatik	Siyah	Hayır	87000	Dizel	Bilinmiyor
323	Audi	A3	1.6 TDI Ambition S-tronic	117500	2014	Sedan	Otomatik	Beyaz	Hayır	10000	Dizel	4
324	Audi	A3	1.4 TFSI	46000	2009	Hatchback	S-Tronik	Siyah	Hayır	117500	Benzin	3
325	Audi	A3	1.6 TDI Sportback Attraction S-tronic	78500	2013	Hatchback	S-Tronik	Beyaz	Hayır	118000	Dizel	5
326	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	69500	2011	Hatchback	S-Tronik	Beyaz	Evet	136000	Dizel	5
327	Audi	A3	1.Haz	26000	2000	Hatchback	Otomatik	Gri	Hayır	175000	Benzin + LPG	5
328	Audi	A3	1.6 Attraction	32500	2005	Hatchback	Manuel	Siyah	Hayır	260000	Benzin	3
329	Audi	A3	1.4 TFSI Sportback	52500	2008	Hatchback	Tiptronik	Siyah	Hayır	50000	Benzin	5
330	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	65000	2011	Hatchback	S-Tronik	Beyaz	Hayır	104000	Dizel	5
331	Audi	A3	1.6 TDI Attraction	91999	2015	Hatchback	Otomatik	Beyaz	Hayır	10500	Dizel	5
332	Audi	A3	1.6 TDI Attraction	115000	2014	Sedan	Otomatik	Siyah	Evet	4750	Dizel	4
333	Audi	A3	1.6 TDI Attraction	105500	2015	Hatchback	Tiptronik	Beyaz	Hayır	11688	Dizel	5
334	Audi	A3	2.0 TFSI Attraction	64500	2008	Cabrio	Manuel	Beyaz	Hayır	108000	Benzin	2
335	Audi	A3	1.6 TDI Attraction	99500	2013	Sedan	S-Tronik	Beyaz	Hayır	19000	Dizel	4
336	Audi	A3	1.6 Attraction	35750	2004	Hatchback	Manuel	Gri	Hayır	176000	Benzin + LPG	3
337	Audi	A3	1.6 Sportback	43500	2010	Hatchback	S-Tronik	Siyah	Hayır	85000	Benzin + LPG	5

338	Audi	A3	1.6 Attraction	28500	2004	Hatchback	Manuel	Siyah	Hayır	165000	Benzin + LPG	3
339	Audi	A3	1.6 Sportback	42500	2006	Hatchback	Tiptronik	Siyah	Hayır	164000	Benzin	5
340	Audi	A3	1.6 TDI Attraction	97750	2015	Sedan	Otomatik	Beyaz	Hayır	4000	Dizel	Bilimmiyor
341	Audi	A3	1.6 Sportback Attraction	58500	2010	Hatchback	Manuel	Siyah	Hayır	39200	Benzin	5
342	Audi	A3	1.6 Ambiente	32500	2004	Coupe	Otomatik	Gri	Hayır	193000	Benzin + LPG	3
343	Audi	A3	1.4 TFSI Sportback	59000	2012	Hatchback	Otomatik	Pembe	Hayır	99000	Benzin	5
344	Audi	A3	1.4 TFSI Ambiente S-tronic	70750	2012	Hatchback	S-Tronic	Kırmızı	Hayır	25000	Benzin	3
345	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	86000	2013	Hatchback	S-Tronic	Bordo	Hayır	4880	Dizel	5
346	Audi	A3	1.4 TFSI Ambition	49000	2009	Hatchback	Manuel	Gri	Hayır	85000	Benzin	5
347	Audi	A3	1.6 TDI Sportback Attraction S-tronic	81000	2012	Hatchback	S-Tronic	Beyaz	Hayır	79000	Dizel	5
348	Audi	A3	1.4 TFSI Ambition	59500	2009	Coupe	Tiptronik	Beyaz	Hayır	135000	Benzin	3
349	Audi	A3	1.6 Sportback	48500	2006	Hatchback	Manuel	Parlement mavı	Hayır	81000	Benzin	5
350	Audi	A3	1.6 Ambiente	26500	2001	Hatchback	Manuel	SarA±	Hayır	130000	Benzin	3
351	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	80000	2014	Hatchback	Otomatik	Beyaz	Hayır	6900	Dizel	5
352	Audi	A3	1.6 Attraction	20950	2000	Hatchback	Manuel	Lacivert	Hayır	258000	Benzin	5
353	Audi	A3	1.6 Attraction	33500	2005	Coupe	Tiptronik	Gri	Hayır	92000	Benzin	2
354	Audi	A3	1.6 TDI Sportback Attraction S-tronic	73250	2012	Hatchback	S-Tronic	Beyaz	Evet	71000	Dizel	5
355	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	76500	2012	Hatchback	S-Tronic	Beyaz	Hayır	44000	Dizel	5
356	Audi	A3	1.Haz	44000	2008	Hatchback	Tiptronik	Siyah	Evet	159000	Benzin + LPG	3
357	Audi	A3	1.6 TDI Sportback Attraction	76500	2012	Hatchback	Tiptronik	Beyaz	Hayır	22500	Dizel	Bilimmiyor
358	Audi	A3	1.6 FSI	31500	2005	Hatchback	Manuel	Gri	Hayır	141600	Benzin	3
359	Audi	A3	1.6 Ambiente	31000	2004	Hatchback	Manuel	Mavi	Hayır	132000	Benzin + LPG	3
360	Audi	A3	1.6 Sportback Attraction	37000	2006	Hatchback	Otomatik	Gri	Hayır	180000	Benzin	5
361	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	51500	2009	Hatchback	S-Tronic	Metalik gri	Hayır	85000	Benzin	5
362	Audi	A3	1.6 Attraction	36500	2006	Hatchback	Manuel	Siyah	Hayır	10500	Benzin	3
363	Audi	A3	1.6 Ambition	29250	2004	Hatchback	Manuel	Gri	Hayır	179000	Benzin + LPG	3
364	Audi	A3	1.6 Ambiente	17000	1997	Hatchback	Manuel	Beyaz	Hayır	220000	Benzin	3
365	Audi	A3	1.4 TFSI Ambition S-tronic	49250	2009	Hatchback	Tiptronik	Gümüş	Hayır	65000	Benzin	3
366	Audi	A3	1.6 Ambiente	14500	1999	Hatchback	Otomatik	Gri	Hayır	230000	Benzin	3
367	Audi	A3	1.4 TFSI Sportback Attraction	44000	2009	Hatchback	Manuel	Füme	Hayır	118005	Benzin	5
368	Audi	A3	1.6 Sportback Attraction	56500	2011	Hatchback	Otomatik	Gümüş	Hayır	16000	Benzin	Bilimmiyor
369	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	82000	2012	Hatchback	S-Tronic	Siyah	Hayır	18500	Dizel	5
370	Audi	A3	2.0 FSI Attraction Tiptronic	37600	2006	Hatchback	S-Tronic	Siyah	Hayır	171000	Benzin + LPG	3
371	Audi	A3	2.0 TFSI	38500	2008	Hatchback	Tiptronik	Siyah	Hayır	123000	Benzin + LPG	3
372	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	74000	2012	Hatchback	S-Tronic	Beyaz	Hayır	24500	Dizel	5
373	Audi	A3	1.2 TFSI Sportback	47500	2012	Hatchback	Manuel	Beyaz	Hayır	67000	Benzin	5
374	Audi	A3	1.4 TFSI Ambition	58000	2010	Hatchback	Manuel	Beyaz	Hayır	28100	Benzin	3
375	Audi	A3	1.4 TFSI Sportback	53000	2010	Hatchback	Otomatik	Beyaz	Evet	75000	Benzin	5
376	Audi	A3	1.6 Sportback Attraction	48000	2008	Hatchback	Tiptronik	Siyah	Hayır	101000	Benzin	5
377	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	68500	2012	Hatchback	Otomatik	Beyaz	Hayır	48000	Dizel	5
378	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	65000	2012	Hatchback	S-Tronic	Beyaz	Hayır	40000	Benzin	5
379	Audi	A3	1.4 TFSI Attraction	39750	2008	Coupe	Manuel	Siyah	Hayır	74000	Benzin	3
380	Audi	A3	1.6 Ambiente	18750	1999	Hatchback	Manuel	Kırmızı	Hayır	160000	Benzin	3

381	Audi	A3	1.6 Ambition	13750	2003	Hatchback	Manuel	Beyaz	Hayır	125000	Benzin + LPG	3
382	Audi	A3	1.6 Sportback	47000	2010	Hatchback	Manuel	Siyah	Hayır	66600	Benzin	5
383	Audi	A3	1.6 Sportback	45000	2005	Hatchback	Manuel	Gri	Evet	108500	Benzin	5
384	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	63000	2011	Hatchback	S-Tronic	Beyaz	Hayır	90000	Dizel	5
385	Audi	A3	2.0 FSI Attraction Tiptronic	33000	2004	Hatchback	Tiptronic	Gri	Hayır	117000	Benzin	3
386	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	52000	2009	Hatchback	S-Tronic	Siyah	Hayır	47000	Benzin	5
387	Audi	A3	1.6 TDI Attraction	106500	2013	Sedan	S-Tronic	Beyaz	Evet	2900	Dizel	4
388	Audi	A3	1.6 Ambiente Aut.	25500	1998	Hatchback	Otomatik	Beyaz	Hayır	248000	Benzin	3
389	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	68000	2012	Hatchback	S-Tronic	Siyah	Hayır	95500	Dizel	5
390	Audi	A3	1.6 Attraction	50750	2011	Hatchback	Manuel	Siyah	Hayır	120000	Benzin + LPG	5
391	Audi	A3	1.4 TFSI Ambition	82000	2013	Hatchback	S-Tronic	Kırmızı	Hayır	66000	Benzin	5
392	Audi	A3	2.0 FSI Ambition	52000	2009	Hatchback	Manuel	Siyah	Hayır	140000	Dizel	3
393	Audi	A3	1.6 Sportback	43500	2005	Hatchback	Tiptronic	Gri	Hayır	216000	Benzin	5
394	Audi	A3	2.0 TDI	52000	2009	Hatchback	Manuel	Gümüş	Hayır	140000	Dizel	3
395	Audi	A3	1.6 TDI Ambition	105000	2015	Sedan	S-Tronic	Siyah	Hayır	17000	Dizel	4
396	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	81000	2013	Hatchback	S-Tronic	Bej	Hayır	55200	Dizel	5
397	Audi	A3	1.6 FSI	45350	2008	Hatchback	Manuel	Gümüş	Hayır	116000	Benzin	3
398	Audi	A3	1.6 Ambition	43000	2006	Hatchback	S-Tronic	Siyah	Hayır	143000	Benzin + LPG	3
399	Audi	A3	1.6 TDI Ambiente S-tronic	75000	2012	Hatchback	S-Tronic	Beyaz	Hayır	98000	Dizel	5
400	Audi	A3	1.6 TDI Ambiente S-tronic	110000	2015	Hatchback	S-Tronic	Beyaz	Evet	13500	Dizel	5
401	Audi	A3	1.6 TDI Sportback Attraction S-tronic	76000	2012	Hatchback	S-Tronic	Beyaz	Hayır	87000	Dizel	5
402	Audi	A3	1.6 Attraction	32250	2000	Hatchback	Manuel	Gri	Hayır	110000	Benzin + LPG	3
403	Audi	A3	1.6 TDI Sportback Attraction S-tronic	94500	2015	Hatchback	S-Tronic	Siyah	Hayır	5000	Dizel	5
404	Audi	A3	1.6 Sportback Attraction	59000	2010	Hatchback	Manuel	Beyaz	Hayır	87000	Benzin	5
405	Audi	A3	1.6 Ambiente	23000	2001	Hatchback	Manuel	Siyah	Hayır	197000	Benzin	3
406	Audi	A3	1.4 TFSI	160000	2015	Cabrio	Tiptronic	Parlamente mavı	Evet	22800	Benzin	3
407	Audi	A3	1.4 TFSI Sportback	51000	2008	Hatchback	Manuel	Siyah	Hayır	110000	Benzin	5
408	Audi	A3	1.6 Ambiente	22000	1997	Hatchback	Manuel	Koyu mavı	Hayır	277000	Benzin	3
409	Audi	A3	1.6 Ambiente	31000	2002	Hatchback	Otomatik	Bej	Evet	163500	Benzin + LPG	5
410	Audi	A3	2.0 TFSI Attraction	66000	2009	Cabrio	Manuel	Beyaz	Hayır	108000	Benzin	2
411	Audi	A3	1.6 Attraction	25000	2001	Hatchback	Manuel	Gri	Hayır	268000	Benzin + LPG	5
412	Audi	A3	1.4 TFSI Attraction	62500	2010	Hatchback	Tiptronic	Beyaz	Hayır	60000	Benzin	5
413	Audi	A3	1.4 TFSI Ambition S-tronic	54900	2010	Hatchback	S-Tronic	Siyah	Hayır	123000	Benzin	3
414	Audi	A3	1.4 TFSI Sportback Attraction	82800	2014	Hatchback	S-Tronic	Kırmızı	Hayır	15000	Benzin	5
415	Audi	A3	1.4 TFSI Attraction S-tronic	43000	2009	Coupe	Manuel	Siyah	Hayır	91000	Benzin	3
416	Audi	A3	1.4 TFSI Attraction S-tronic	65000	2012	Hatchback	Manuel	Gri	Hayır	79000	Benzin	3
417	Audi	A3	1.6 Ambition	78500	2012	Hatchback	S-Tronic	Beyaz	Hayır	68000	Dizel	5
418	Audi	A3	1.6 TDI Attraction	106000	2014	Sedan	S-Tronic	Siyah	Evet	26000	Dizel	4
419	Audi	A3	1.6 Attraction	29750	2003	Hatchback	Otomatik	Siyah	Hayır	238000	Benzin + LPG	5
420	Audi	A3	1.4 TFSI Attraction	54750	2009	Hatchback	Manuel	Beyaz	Hayır	90400	Benzin	5
421	Audi	A3	1.6 Ambiente	15000	1999	Hatchback	Manuel	Kırmızı	Hayır	243600	Benzin	3
422	Audi	A3	1.4 TFSI Attraction S-tronic	66000	2012	Hatchback	S-Tronic	Gri	Hayır	77000	Benzin	3
423	Audi	A3	1.6 Sportback Attraction	56500	2012	Hatchback	Manuel	Siyah	Hayır	67000	Benzin	5

424	Audi	A3	1.Haz	41000	2005	Hatchback	Tiptronik	Gümüş	Hayır	106000	Benzin	5
425	Audi	A3	1.6 Ambiente Aut.	33850	2004	Hatchback	Manuel	Gümüş	Hayır	238400	Benzin + LPG	3
426	Audi	A3	1.8 TFSI Sportback Attraction S-Tronic	73500	2009	Hatchback	S-Tronic	Gri	Hayır	37000	Benzin	5
427	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	75000	2012	Hatchback	S-Tronic	Siyah	Hayır	28000	Dizel	5
428	Audi	A3	1.6 Sportback Attraction	47500	2008	Hatchback	Otomatik	Kırmızı	Hayır	97000	Benzin	5
429	Audi	A3	1.6 Attraction	37500	2004	Hatchback	Tiptronik	Siyah	Hayır	200000	Benzin + LPG	3
430	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	79500	2012	Hatchback	S-Tronic	Beyaz	Hayır	40000	Dizel	5
431	Audi	A3	1.6 Ambiente	33000	2004	Hatchback	Tiptronik	Gümüş	Hayır	163000	Benzin + LPG	3
432	Audi	A3	1.4 TFSI Sportback Attraction S-Tronic	77500	2014	Hatchback	S-Tronic	Beyaz	Evet	20000	Benzin	5
433	Audi	A3	1.6 Sportback Attraction	47550	2005	Hatchback	Tiptronik	Siyah	Hayır	66200	Benzin + LPG	5
434	Audi	A3	1.6 Ambiente Aut.	20000	1999	Hatchback	Otomatik	Koyu mavi	Hayır	210000	Benzin + LPG	3
435	Audi	A3	1.6 Ambiente	42500	2010	Hatchback	S-Tronic	Beyaz	Hayır	103400	Benzin	3
436	Audi	A3	1.4 TFSI	58000	2011	Coupe	Tiptronik	Siyah	Hayır	45000	Benzin	2
437	Audi	A3	1.6 TDI Attraction	78000	2012	Hatchback	S-Tronic	Beyaz	Hayır	23000	Dizel	5
438	Audi	A3	2.0 TDI Sportback S-Tronic	38600	2006	Hatchback	S-Tronic	Siyah	Hayır	213600	Dizel	5
439	Audi	A3	1.6 TDI Sportback Attraction S-tronic	81750	2013	Hatchback	S-Tronic	Siyah	Evet	31200	Dizel	5
440	Audi	A3	1.6 Ambiente	39750	2006	Coupe	S-Tronic	Siyah	Hayır	180000	Benzin	3
441	Audi	A3	1.6 Sportback	55000	2010	Hatchback	Otomatik	Beyaz	Hayır	35000	Benzin	5
442	Audi	A3	1.6 Attraction S-Tronic	58000	2010	Hatchback	S-Tronic	Beyaz	Hayır	25000	Benzin	5
443	Audi	A3	1.6 TDI Sportback Attraction S-Tronic	79500	2012	Hatchback	S-Tronic	Beyaz	Hayır	73000	Dizel	5
444	Audi	A3	1.6 Sportback	39500	2007	Hatchback	Tiptronik	Beyaz	Hayır	146000	Benzin + LPG	5
445	Audi	A3	1.6 FSI	32250	2004	Hatchback	Otomatik	Siyah	Hayır	193000	Benzin + LPG	3
446	Audi	A3	1.4 TFSI Sportback	52000	2010	Hatchback	Otomatik	Beyaz	Hayır	41000	Benzin	5
447	Audi	A3	1.9 PD TDI Sportback	40000	2006	Hatchback	Manuel	Bordo	Hayır	159000	Dizel	5
448	Audi	A3	1.6 TDI Attraction	80000	2012	Hatchback	Manuel	Beyaz	Hayır	69000	Dizel	5
449	Audi	A3	1.6 TDI Attraction S-tronic	97900	2014	Sedan	S-Tronic	Beyaz	Hayır	9000	Dizel	4
450	Audi	A3	1.6 Attraction	23500	2003	Hatchback	Otomatik	Açık gri	Hayır	165000	Benzin + LPG	3
451	Audi	A3	1.6 Ambiente Aut.	200000	2000	Hatchback	Otomatik	Mavi	Hayır	210000	Benzin	3
452	Audi	A3	1.6 Attraction	35000	2004	Coupe	Otomatik	Siyah	Hayır	145000	Benzin	2
453	Audi	A3	1.4 TFSI Ambition	62000	2011	Hatchback	Tiptronik	Beyaz	Hayır	70500	Benzin	3
454	Audi	A3	1.6 Sportback Attraction	40500	2007	Hatchback	Manuel	Gümüş	Evet	98000	Benzin	5
455	Audi	A3	1.4 TFSI	53000	2008	Hatchback	Manuel	Gri	Evet	28000	Benzin	5
456	Audi	A3	1.6 Sportback Attraction	42000	2007	Hatchback	Otomatik	Siyah	Hayır	95000	Benzin	5
457	Audi	A3	1.Haz	100000	2012	Hatchback	Manuel	Siyah	Evet	166	Benzin	5
458	Audi	A3	1.8 Attraction	16500	1999	Hatchback	Manuel	Mavi	Hayır	199000	Benzin + LPG	3
459	Audi	A3	1.6 FSI Sportback	39500	2007	Hatchback	Manuel	Siyah	Hayır	74000	Benzin	5
460	Audi	A4	2.0 TDI Multitronic	85000	2011	Sedan	Otomatik	Beyaz	Hayır	81000	Dizel	Bilinmiyor
461	Audi	A4	1.8 TFSI	91000	2012	Sedan	Otomatik	Gri	Hayır	72005	Benzin	4
462	Audi	A4	1.8 T	26000	1997	Sedan	Manuel	Siyah	Hayır	300000	Benzin	4
463	Audi	A4	2.0 TDI	90000	2011	Sedan	Manuel	Gri	Hayır	158000	Dizel	4
464	Audi	A4	1.8 TFSI Multitronic	60000	2010	Sedan	Tiptronik	Siyah	Hayır	107000	Benzin	4
465	Audi	A4	1.8 TFSI Multitronic	69500	2009	Sedan	Tiptronik	Gri	Hayır	142000	Benzin	4
466	Audi	A4	1.8 T	70000	2009	Sedan	Tiptronik	Füme	Hayır	114000	Benzin	4

467	Audi	A4	2.0 TDI Quattro S-tronic	149750	2015	Sedan	Tiptronik	Beyaz	Hayır	29000	Dizel	Bilinmiyor
468	Audi	A4	2.5 V6 TDI Quattro Tiptronic	40000	2003	Stationvagon	Tiptronik	Kırmızı	Hayır	320000	Dizel	5
469	Audi	A4	1.4 TFSI S tronic	159500	2016	Sedan	S-Tronic	Beyaz	Evet	-	Benzin	4
470	Audi	A4	1.9 TDI	30500	1996	Sedan	Manuel	Lacivert	Hayır	167000	Dizel	4
471	Audi	A4	1.8 TFSI Multitronic	65000	2009	Sedan	Tiptronik	Siyah	Hayır	133000	Benzin	4
472	Audi	A4	1.8 T Quattro	34900	1999	Sedan	Manuel	Beyaz	Hayır	138000	Benzin	4
473	Audi	A4	1.8 TFSI Multitronic	82000	2011	Sedan	Tiptronik	Beyaz	Hayır	81000	Benzin	4
474	Audi	A4	2.0 TDI Multitronic	91000	2012	Sedan	Tiptronik	Siyah	Hayır	158000	Dizel	4
475	Audi	A4	2.0 TDI	130000	2011	Sedan	Manuel	Füme	Hayır	6000	Dizel	4
476	Audi	A4	1.8 TFSI	65000	2008	Sedan	Manuel	Gri	Hayır	135000	Benzin	4
477	Audi	A4	2.0 TDI Multitronic	107000	2013	Sedan	Otomatik	Siyah	Hayır	63000	Dizel	Bilinmiyor
478	Audi	A4	1.Haz	41500	2008	Sedan	Manuel	Siyah	Hayır	210000	Benzin + LPG	4
479	Audi	A4	1.8 TFSI	74500	2011	Sedan	Manuel	Siyah	Hayır	66000	Benzin	4
480	Audi	A4	1.8 TFSI Multitronic	65500	2010	Sedan	Tiptronik	Gri	Hayır	145000	Benzin	4
481	Audi	A4	1.8 TFSI	68500	2011	Sedan	Manuel	Beyaz	Hayır	63000	Benzin	4
482	Audi	A4	1.Haz	53000	2008	Sedan	Manuel	Gri	Hayır	155000	Benzin	4
483	Audi	A4	2.0 TDI Multitronic	134990	2014	Sedan	Otomatik	Beyaz	Hayır	45000	Dizel	Bilinmiyor
484	Audi	A4	2.0 TDI	125000	2011	Sedan	Otomatik	Gri	Hayır	6000	Dizel	4
485	Audi	A4	1.8 TFSI Multitronic	79500	2012	Sedan	Tiptronik	Beyaz	Hayır	117000	Benzin	4
486	Audi	A4	2.8 Quattro	25000	1995	Sedan	Otomatik	Siyah	Hayır	25000	Benzin + LPG	4
487	Audi	A4	2.0 TDI Quattro S-tronic	75500	2013	Sedan	S-Tronic	Beyaz	Hayır	115000	Dizel	4
488	Audi	A4	2.0 TDI Multitronic	85500	2011	Sedan	Tiptronik	Beyaz	Hayır	80000	Dizel	4
489	Audi	A4	1.Ağu	23500	1998	Sedan	Otomatik	Kahverengi	Hayır	220000	Benzin + LPG	4
490	Audi	A4	2.0 TDI Quattro S-tronic	122000	2013	Sedan	Tiptronik	Siyah	Hayır	45000	Dizel	4
491	Audi	A4	2.0 TDI	116500	2014	Sedan	Manuel	Beyaz	Hayır	60000	Dizel	4
492	Audi	A4	1.Haz	44500	2004	Sedan	Manuel	Gri	Hayır	187000	Benzin + LPG	4
493	Audi	A4	1.Haz	56000	2008	Sedan	Manuel	Siyah	Hayır	130000	Benzin	4
494	Audi	A4	2.0 TDI Multitronic	125000	2013	Sedan	Tiptronik	Beyaz	Hayır	44000	Dizel	4
495	Audi	A4	1.9 TDI	32000	1997	Sedan	Manuel	Siyah	Hayır	320000	Dizel	4
496	Audi	A4	2.0 TDI Multitronic	146500	2015	Sedan	Tiptronik	Beyaz	Evet	6500	Dizel	4
497	Audi	A4	1.Haz	43250	2005	Sedan	Manuel	Bej	Hayır	259000	Benzin + LPG	4
498	Audi	A4	2.5 V6 TDI 2.5 TDI	50000	2001	Stationvagon	Manuel	Siyah	Hayır	245000	Dizel	5
499	Audi	A4	1.8 Aut.	25450	1998	Sedan	Otomatik	Kahverengi	Hayır	235000	Benzin	4
500	Audi	A4	1.Haz	45700	2005	Sedan	Manuel	Gri	Hayır	196000	Benzin + LPG	4
.												
.												
.												
30601	Volkswagen	Polo	1.4 Basicline Otomatik	25000	2004	Hatchback	Otomatik	Siyah	Hayır	145000	Benzin	5
30602	Volkswagen	Polo	1.4 85 HP DSG Comfortline	35500	2010	Hatchback	Manuel	Kırmızı	Hayır	27000	Benzin	5
30603	Volkswagen	Polo	1.6 Otomatik	19000	1997	Hatchback	Otomatik	Gri	Hayır	191000	Benzin	5
30604	Volkswagen	Polo	1.2 TDI 75 HP Trendline	34800	2012	Hatchback	Manuel	Beyaz	Hayır	98000	Dizel	5
30605	Volkswagen	Polo	1.6 Otomatik	19250	1998	Hatchback	Otomatik	Yeşil	Hayır	193000	Benzin + LPG	5
30606	Volkswagen	Polo	1.4 Trendline	31750	2009	Hatchback	Manuel	Siyah	Hayır	57000	Benzin	5

30607	Volkswagen	Polo	1.2 70 HP Trendline	38500	2015	Hatchback	Manuel	Beyaz	Hayır	4500	Benzin	5
30608	Volkswagen	Polo	1.4 85 HP DSG Comfortline	43500	2012	Hatchback	S-Tronik	Metalik gri	Hayır	44200	Benzin	5
30609	Volkswagen	Polo	85 Fan Edition	43500	2012	Hatchback	Manuel	Beyaz	Hayır	68000	Benzin	5
30610	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline	47500	2013	Hatchback	Manuel	Siyah	Hayır	42000	Dizel	5
30611	Volkswagen	Polo	1.4 85 HP DSG Comfortline	47500	2013	Hatchback	S-Tronik	Beyaz	Evet	35700	Benzin	5
30612	Volkswagen	Polo	Classic 1.6 Comfortline	17500	1999	Sedan	Manuel	Siyah	Hayır	240000	Benzin	4
30613	Volkswagen	Polo	1.4 Comfortline	23900	2000	Hatchback	Manuel	Mavi	Hayır	152000	Benzin + LPG	5
30614	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline	44500	2011	Hatchback	Manuel	Beyaz	Hayır	77000	Dizel	5
30615	Volkswagen	Polo	1.6 TDI 90 HP DSG Comfortline	42500	2010	Hatchback	S-Tronik	Beyaz	Hayır	143000	Dizel	5
30616	Volkswagen	Polo	1.4 TDI BMT Comfortline	53750	2014	Hatchback	Manuel	Beyaz	Hayır	18400	Dizel	5
30617	Volkswagen	Polo	1.4 Trendline	29000	2005	Hatchback	Manuel	Kırmızı	Hayır	67000	Benzin	5
30618	Volkswagen	Polo	1.4 Trendline	32500	2006	Hatchback	Manuel	Mavi	Hayır	117000	Benzin + LPG	5
30619	Volkswagen	Polo	1.Haz	17500	1998	Sedan	Manuel	Beyaz	Hayır	170000	Benzin	4
30620	Volkswagen	Polo	1.4 Basicline	26500	2004	Hatchback	Manuel	Siyah	Hayır	157000	Benzin	5
30621	Volkswagen	Polo	1.2 TSI BMT Comfortline	46000	2015	Hatchback	Manuel	Beyaz	Evet	7500	Benzin	5
30622	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline DSG	45000	2012	Hatchback	Tiptronik	Beyaz	Evet	170000	Dizel	5
30623	Volkswagen	Polo	Classic 1.6	18750	1998	Sedan	Manuel	Beyaz	Evet	274000	Benzin	4
30624	Volkswagen	Polo	Classic 1.6	19000	2000	Sedan	Manuel	Beyaz	Hayır	136000	Benzin + LPG	4
30625	Volkswagen	Polo	1.4 85 HP Comfortline	40000	2012	Hatchback	Manuel	Siyah	Hayır	46806	Benzin + LPG	4
30626	Volkswagen	Polo	1.6 TDI 90 HP Comfortline	37500	2012	Hatchback	Manuel	Siyah	Hayır	60000	Dizel	5
30627	Volkswagen	Polo	1.4 Basicline Otomatik	35300	2004	Hatchback	Otomatik	Beyaz	Hayır	120000	Benzin	5
30628	Volkswagen	Polo	1.4 Comfortline	19850	2001	Hatchback	Manuel	Mavi	Hayır	19900	Benzin	5
30629	Volkswagen	Polo	1.Haz	16500	1997	Hatchback	Manuel	Yeşil	Hayır	173000	Benzin	5
30630	Volkswagen	Polo	1.2 70 HP Trendline	38500	2013	Hatchback	Manuel	Beyaz	Hayır	27000	Benzin	5
30631	Volkswagen	Polo	1.Nis	14500	1996	Hatchback	Manuel	Koyu Yeşil	Hayır	180000	Benzin	5
30632	Volkswagen	Polo	1.2 TSI BMT Comfortline	49900	2014	Hatchback	Otomatik	Beyaz	Hayır	18000	Benzin	5
30633	Volkswagen	Polo	1.2 70 HP Trendline	33900	2011	Hatchback	Manuel	Kırmızı	Hayır	70000	Benzin	5
30634	Volkswagen	Polo	1.2 TSI BMT Comfortline	40900	2014	Hatchback	Manuel	Gri	Evet	15800	Benzin	5
30635	Volkswagen	Polo	1.4 Comfortline	57000	2014	Hatchback	Tiptronik	Siyah	Hayır	19500	Dizel	4
30636	Volkswagen	Polo	1.2 TDI 75 HP Trendline	32000	2012	Hatchback	Manuel	Beyaz	Hayır	82400	Dizel	5
30637	Volkswagen	Polo	1.4 Trendline	19000	2001	Hatchback	Manuel	Kırmızı	Hayır	192504	Benzin	5
30638	Volkswagen	Polo	Classic 1.6	15500	1997	Sedan	Manuel	Yeşil	Hayır	171000	Benzin	4
30639	Volkswagen	Polo	1.2 70 HP Trendline	38500	2013	Hatchback	Manuel	Beyaz	Hayır	28000	Benzin	5
30640	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline	52000	2013	Hatchback	Manuel	Siyah	Hayır	28000	Dizel	5
30641	Volkswagen	Polo	1.4 85 HP Comfortline	36500	2011	Hatchback	Manuel	Beyaz	Hayır	96000	Benzin + LPG	5
30642	Volkswagen	Polo	1.4 Comfortline	24250	2001	Hatchback	Manuel	Metalik gri	Hayır	180000	Benzin	5
30643	Volkswagen	Polo	1.Haz	17000	1998	Hatchback	Manuel	Füme	Hayır	181000	Benzin	5
30644	Volkswagen	Polo	1.2 TSI BMT Comfortline	53000	2015	Hatchback	Otomatik	Kırmızı	Hayır	21000	Benzin	5
30645	Volkswagen	Polo	1.6 TDI 90 HP Comfortline	36500	2012	Hatchback	Manuel	Füme	Hayır	76000	Dizel	5
30646	Volkswagen	Polo	1.2 TSI BMT Comfortline	51500	2014	Hatchback	Otomatik	Beyaz	Evet	10000	Benzin	5
30647	Volkswagen	Polo	1.6 Otomatik	13950	1996	Hatchback	Otomatik	Yeşil	Hayır	177850	Benzin + LPG	5
30648	Volkswagen	Polo	Classic 1.6	17100	1997	Sedan	Manuel	Beyaz	Hayır	200000	Benzin	4
30649	Volkswagen	Polo	1.2 LT 70 HP BlueMotion	49000	2014	Hatchback	Otomatik	Beyaz	Hayır	6000	Benzin	5

30650	Volkswagen	Polo	1.4 Comfortline Otomatik	26000	2000	Hatchback	Otomatik	Mavi	Hayır	61200	Benzin	5
30651	Volkswagen	Polo	1.4 Trendline	30000	2006	Hatchback	Manuel	Beyaz	Hayır	60000	Benzin	5
30652	Volkswagen	Polo	Classic 1.6 Comfortline	18750	2000	Sedan	Manuel	Mor	Hayır	228000	Benzin	4
30653	Volkswagen	Polo	1.Haz	17300	1999	Hatchback	Manuel	Koyu mavi	Hayır	173000	Benzin + LPG	4
30654	Volkswagen	Polo	1.2 TDI 75 HP Trendline	38750	2011	Hatchback	Manuel	Siyah	Hayır	68000	Dizel	5
30655	Volkswagen	Polo	1.4 Trendline Otomatik	30000	2005	Hatchback	Otomatik	Kırmızı	Hayır	123000	Benzin	5
30656	Volkswagen	Polo	GTi 1.4 TSi DSG	53000	2011	Hatchback	S-Tronik	Beyaz	Hayır	76000	Benzin	3
30657	Volkswagen	Polo	1.4 TDI Trendline	48000	2014	Hatchback	Manuel	Beyaz	Hayır	24000	Dizel	5
30658	Volkswagen	Polo	1.6 Otomatik	17000	1998	Hatchback	Otomatik	Beyaz	Hayır	129000	Benzin	5
30659	Volkswagen	Polo	1.Haz	16250	1998	Hatchback	Manuel	Kırmızı	Hayır	160000	Benzin + LPG	5
30660	Volkswagen	Polo	1.4 TSi Pulse	43000	2012	Hatchback	Manuel	Beyaz	Hayır	26000	Benzin	5
30661	Volkswagen	Polo	1.4 85 HP Comfortline	45250	2012	Hatchback	Otomatik	Siyah	Hayır	28250	Benzin	5
30662	Volkswagen	Polo	1.4 TDI BMT Comfortline	60250	2015	Hatchback	Otomatik	Beyaz	Hayır	14800	Dizel	5
30663	Volkswagen	Polo	1.Haz	18500	1998	Hatchback	Manuel	Kırmızı	Hayır	253200	Benzin	5
30664	Volkswagen	Polo	1.4 85 HP Comfortline	36500	2010	Hatchback	Manuel	Siyah	Hayır	28000	Benzin	5
30665	Volkswagen	Polo	1.Haz	19750	2000	Hatchback	Otomatik	Kırmızı	Hayır	175000	Benzin + LPG	Bilinmiyor
30666	Volkswagen	Polo	1.4 Trendline	27250	2006	Hatchback	Manuel	Gümüş	Hayır	155000	Benzin + LPG	5
30667	Volkswagen	Polo	1.4 TDI Trendline	18950	2001	Hatchback	Manuel	Beyaz	Hayır	198000	Dizel	5
30668	Volkswagen	Polo	1.4 Trendline	23000	2000	Hatchback	Manuel	Kırmızı	Hayır	166000	Benzin	5
30669	Volkswagen	Polo	1.4 Comfortline	20000	2001	Hatchback	Manuel	Gri	Hayır	148000	Benzin	5
30670	Volkswagen	Polo	1.4 Comfortline	44000	2014	Hatchback	Manuel	Beyaz	Hayır	25000	Benzin	5
30671	Volkswagen	Polo	1.4 Basicline	24500	2004	Hatchback	Manuel	Gri	Hayır	51500	Benzin	5
30672	Volkswagen	Polo	1.6 TDI 90 HP Comfortline	40500	2011	Hatchback	Manuel	Siyah	Evet	75000	Dizel	5
30673	Volkswagen	Polo	1.6 Otomatik	20500	2000	Hatchback	Otomatik	Kırmızı	Hayır	190000	Benzin + LPG	5
30674	Volkswagen	Polo	1.4 Trendline	33500	2009	Hatchback	Manuel	Siyah	Hayır	31000	Benzin	5
30675	Volkswagen	Polo	1.2 TSi BMT Comfortline	42500	2014	Hatchback	Manuel	Beyaz	Evet	18000	Benzin	5
30676	Volkswagen	Polo	1.4 Trendline	25000	2006	Hatchback	Manuel	Metalik gri	Hayır	121	Benzin	5
30677	Volkswagen	Polo	1.4 Comfortline	40750	2013	Hatchback	Manuel	Bej	Evet	19000	Benzin	5
30678	Volkswagen	Polo	1.4 85 HP Comfortline	34500	2010	Hatchback	Manuel	Kırmızı	Hayır	84000	Benzin	5
30679	Volkswagen	Polo	1.Haz	15500	1998	Hatchback	Manuel	Yeşil	Hayır	248400	Benzin	5
30680	Volkswagen	Polo	1.4 Trendline Tiptronik	28000	2008	Hatchback	Manuel	Beyaz	Hayır	105000	Benzin	4
30681	Volkswagen	Polo	1.4 Trendline	25500	2004	Hatchback	Manuel	Kırmızı	Hayır	118000	Benzin + LPG	5
30682	Volkswagen	Polo	1.2 TDI 75 HP Trendline	35450	2012	Hatchback	Manuel	Gri	Hayır	110000	Dizel	5
30683	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline DSG	54750	2014	Hatchback	Otomatik	Gri	Hayır	30000	Dizel	5
30684	Volkswagen	Polo	1.4 TSi Chrome Edition DSG	50500	2013	Hatchback	Otomatik	Beyaz	Evet	6000	Benzin	5
30685	Volkswagen	Polo	1.2 TSi BMT Comfortline	44500	2015	Hatchback	Manuel	Beyaz	Hayır	880	Benzin	5
30686	Volkswagen	Polo	1.Haz	17500	1998	Hatchback	Manuel	Yeşil	Hayır	126000	Benzin + LPG	5
30687	Volkswagen	Polo	1.4 Trendline	21500	2001	Hatchback	Manuel	Gri	Hayır	127000	Benzin	5
30688	Volkswagen	Polo	Classic 1.6	13350	1996	Sedan	Otomatik	Siyah	Hayır	182000	Benzin + LPG	3
30689	Volkswagen	Polo	Classic 1.6	22000	1999	Sedan	Manuel	Kırmızı	Hayır	72000	Benzin	4
30690	Volkswagen	Polo	1.6 TDI 90 HP Comfortline	38000	2011	Hatchback	Manuel	Beyaz	Hayır	97000	Dizel	5
30691	Volkswagen	Polo	1.2 TDI 75 HP Trendline	43000	2014	Hatchback	Manuel	Beyaz	Evet	13500	Dizel	5
30692	Volkswagen	Polo	1.2 LT 70 HP BlueMotion	43500	2014	Hatchback	Manuel	Siyah	Hayır	4400	Benzin	5

30693	Volkswagen	Polo	1.2 TDI 75 HP Trendline BlueMotion	40000	2012	Hatchback	Manuel	Beyaz	Hayır	76000	Dizel	5
30694	Volkswagen	Polo	1.Haz	17750	2000	Hatchback	Manuel	Beyaz	Hayır	180000	Benzin + LPG	5
30695	Volkswagen	Polo	1.Haz	15500	1999	Hatchback	Manuel	Mavi	Hayır	124000	Benzin	5
30696	Volkswagen	Polo	1.4 Primeline	19500	2003	Sedan	Manuel	Mavi	Hayır	205000	Benzin	4
30697	Volkswagen	Polo	1.Haz	16500	2000	Hatchback	Manuel	Beyaz	Hayır	180000	Benzin + LPG	5
30698	Volkswagen	Polo	1.4 Trendline	29500	2008	Hatchback	Manuel	Kahverengi	Hayır	36500	Benzin + LPG	5
30699	Volkswagen	Polo	Classic 1.6 Trendline	17500	2000	Sedan	Manuel	Metalik gri	Hayır	133000	Benzin + LPG	5
30700	Volkswagen	Polo	1.4 TDI 70 HP Trendline	28500	2006	Hatchback	Manuel	Beyaz	Hayır	86000	Dizel	5
30701	Volkswagen	Polo	1.4 TDI 70 HP Trendline	30000	2009	Hatchback	Manuel	Beyaz	Hayır	87000	Dizel	5
30702	Volkswagen	Polo	Classic 1.6	14912	1997	Sedan	Manuel	Kırmızı	Hayır	180458	Benzin	Bilmiyor
30703	Volkswagen	Polo	1.2 70 HP Trendline	37700	2013	Hatchback	Manuel	Beyaz	Evet	13650	Benzin	5
30704	Volkswagen	Polo	1.6 TDI 90 HP DSG Comfortline	52000	2012	Hatchback	S-Tronik	Beyaz	Evet	28000	Dizel	5
30705	Volkswagen	Polo	Classic 1.6	14200	1997	Sedan	Manuel	Yeşil	Hayır	205000	Benzin	4
30706	Volkswagen	Polo	1.Haz	15800	1997	Hatchback	Manuel	Mavi	Hayır	158580	Benzin	5
30707	Volkswagen	Polo	1.2 TDI 75 HP Trendline	36000	2011	Hatchback	Manuel	Kırmızı	Hayır	43200	Dizel	5
30708	Volkswagen	Polo	85 Fan Edition	36850	2012	Hatchback	Manuel	Bordo	Hayır	35000	Benzin	5
30709	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline	40000	2012	Hatchback	Manuel	Beyaz	Hayır	103000	Dizel	5
30710	Volkswagen	Polo	1.6 TDI 90 HP Comfortline	48000	2013	Hatchback	Manuel	Beyaz	Hayır	9000	Dizel	5
30711	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline	47900	2013	Hatchback	Manuel	Siyah	Hayır	6686	Dizel	5
30712	Volkswagen	Polo	1.Haz	14250	1999	Hatchback	Manuel	Mor	Hayır	160000	Benzin	5
30713	Volkswagen	Polo	1.4 Trendline	28700	2007	Hatchback	Manuel	Beyaz	Hayır	94500	Benzin + LPG	5
30714	Volkswagen	Polo	1.2 70 HP Trendline	34250	2012	Hatchback	Manuel	Beyaz	Hayır	48000	Benzin	5
30715	Volkswagen	Polo	1.4 Trendline	23500	2004	Hatchback	Manuel	Metalik gri	Hayır	135000	Benzin	5
30716	Volkswagen	Polo	1.4 Comfortline	45750	2014	Hatchback	Manuel	Beyaz	Hayır	4500	Benzin	5
30717	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline	52000	2013	Hatchback	Otomatik	Beyaz	Hayır	38000	Dizel	5
30718	Volkswagen	Polo	1.4 85 HP Comfortline	34000	2010	Hatchback	Manuel	Kırmızı	Hayır	10000	Benzin	5
30719	Volkswagen	Polo	1.2 70 HP Trendline	33700	2012	Hatchback	Manuel	Füme	Hayır	25000	Benzin	5
30720	Volkswagen	Polo	1.2 70 HP Trendline	32950	2012	Hatchback	Manuel	Beyaz	Hayır	7000	Benzin	5
30721	Volkswagen	Polo	1.2 70 HP Trendline	26750	2011	Hatchback	Manuel	Beyaz	Hayır	202000	Benzin	5
30722	Volkswagen	Polo	1.6 TDI 90 HP 90 CR Comfortline	45750	2013	Hatchback	Manuel	Beyaz	Hayır	28000	Dizel	5
30723	Volkswagen	Polo	1.4 Trendline Otomatik	31750	2006	Hatchback	Otomatik	Siyah	Hayır	43000	Benzin	5
30724	Volkswagen	Polo	1.4 85 HP Comfortline	39500	2012	Hatchback	Manuel	Krem	Evet	40550	Benzin	5
30725	Volkswagen	Polo	Classic 1.6	16000	1999	Sedan	Manuel	Beyaz	Hayır	222000	Benzin	4
30726	Volkswagen	Polo	1.2 TDI 75 HP Trendline	31000	2012	Hatchback	Manuel	Beyaz	Hayır	12000	Dizel	5
30727	Volkswagen	Polo	1.2 TDI 75 HP Trendline	31000	2012	Hatchback	Manuel	Beyaz	Hayır	60400	Dizel	5
30728	Volkswagen	Polo	1.4 Basicline	22750	2004	Hatchback	Manuel	Beyaz	Hayır	137200	Benzin + LPG	5
30729	Volkswagen	Polo	1.4 85 HP Comfortline	28750	2010	Hatchback	Otomatik	Bordo	Hayır	100000	Benzin	5
30730	Volkswagen	Polo	1.4 Comfortline Otomatik	30000	2005	Hatchback	Otomatik	Beyaz	Hayır	80000	Benzin	5
30731	Volkswagen	Polo	1.2 70 HP Trendline	49500	2011	Hatchback	Otomatik	Parlamente mavı	Hayır	-	Benzin	5
30732	Volkswagen	Polo	1.4 Comfortline	27750	2009	Hatchback	Manuel	Siyah	Hayır	42633	Benzin	5
30733	Volkswagen	Polo	1.4 TDI 70 HP Trendline	26000	2009	Hatchback	Manuel	Beyaz	Hayır	170000	Dizel	5
30734	Volkswagen	Polo	Classic 1.6 Highline	16000	2000	Sedan	Manuel	Gümüş	Hayır	210000	Benzin + LPG	4
30735	Volkswagen	Polo	1.Haz	14000	1999	Hatchback	Manuel	Bordo	Hayır	160000	Benzin + LPG	5

30736	Volkswagen	Polo	1.2 70 HP Trendline	36000	2011	Hatchback	Manuel	Beyaz	Hayır	22000	Benzin	5
30737	Volkswagen	Polo	1.4 Trendline	23000	2002	Hatchback	Manuel	Mor	Hayır	145000	Benzin	5
30738	Volkswagen	Polo	1.4 Comfortline	21500	2000	Hatchback	Manuel	Gümüş	Hayır	135000	Benzin + LPG	5
30739	Volkswagen	Polo	1.4 Comfortline	20000	2003	Hatchback	Manuel	Gümüş	Hayır	130000	Benzin	3
30740	Volkswagen	Polo	1.2 70 HP Trendline	34000	2012	Hatchback	Manuel	Beyaz	Hayır	15000	Benzin	5
30741	Volkswagen	Polo	1.Haz	14500	2000	Hatchback	Manuel	Mavi	Hayır	124500	Benzin + LPG	5
30742	Volkswagen	Polo	1.Haz	14900	1999	Hatchback	Manuel	Beyaz	Hayır	117000	Benzin	5
30743	Volkswagen	Polo	Classic 1.6	16000	1998	Sedan	Manuel	Kırmızı	Evet	175000	Benzin + LPG	4
30744	Volkswagen	Polo	1.4 Comfortline	19800	2002	Hatchback	Manuel	Mavi	Hayır	141000	Benzin	5
30745	Volkswagen	Polo	Classic 1.6 Comfortline	14250	2001	Sedan	Manuel	Bej	Hayır	217000	Benzin	4
30746	Volkswagen	Polo	1.4 Tour	28000	2008	Hatchback	Manuel	Beyaz	Hayır	54000	Benzin	5
30747	Volkswagen	Polo	1.6 TDI 90 HP Comfortline	50000	2012	Hatchback	Tiptronik	Beyaz	Hayır	6000	Dizel	5
30748	Volkswagen	Polo	1.4 Comfortline	21750	2000	Hatchback	Otomatik	Mavi	Hayır	147000	Benzin	5
30749	Volkswagen	Polo	1.2 LT 70 HP BlueMotion	47000	2013	Hatchback	Manuel	Beyaz	Evet	4500	Dizel	5
30750	Volkswagen	Polo	1.Haz	15000	2000	Hatchback	Manuel	Mavi	Hayır	103200	Benzin	5
30751	Volkswagen	Polo	1.Haz	13500	1999	Hatchback	Manuel	Mavi	Hayır	132500	Benzin	5
30752	Volkswagen	Polo	1.4 TDI Tour	25500	2008	Hatchback	Manuel	Siyah	Hayır	136000	Dizel	5
30753	Volkswagen	Scirocco	1.4 TSI 160 HP DSP Sportline	64000	2012	Coupe	Tiptronik	Siyah	Hayır	64000	Benzin	2
30754	Volkswagen	Scirocco	1.4 TSI 160 HP DSP Sportline	81000	2015	Coupe	Tiptronik	Beyaz	Evet	10200	Benzin	2
30755	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	55000	2011	Coupe	Manuel	Füme	Hayır	53000	Benzin	2
30756	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	77500	2015	Coupe	Manuel	Metalik mavi	Hayır	21300	Benzin	2
30757	Volkswagen	Scirocco	1.4 TSI 160 HP DSP Sportline	69000	2009	Coupe	Tiptronik	Kırmızı	Hayır	63000	Benzin	2
30758	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	60500	2012	Coupe	Manuel	Beyaz	Hayır	60000	Benzin	2
30759	Volkswagen	Scirocco	1.4 TSI 160 HP DSP Sportline	53500	2011	Coupe	Tiptronik	Beyaz	Hayır	75000	Benzin	2
30760	Volkswagen	Scirocco	1.4 TSI 160 HP DSP Sportline	56000	2010	Coupe	Tiptronik	Beyaz	Hayır	150000	Benzin	2
30761	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	85000	2014	Coupe	Otomatik	Beyaz	Evet	13100	Benzin	2
30762	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	76000	2012	Coupe	Manuel	Mavi	Hayır	63000	Benzin	2
30763	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	62000	2012	Coupe	Manuel	Beyaz	Hayır	27000	Benzin	2
30764	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	45000	2009	Coupe	Manuel	Siyah	Hayır	158000	Benzin	2
30765	Volkswagen	Scirocco	1.4 TSI 160 HP DSP Sportline	60250	2010	Coupe	Tiptronik	Beyaz	Hayır	65000	Benzin	2
30766	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	63500	2012	Coupe	Manuel	Beyaz	Hayır	75000	Benzin	2
30767	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	80000	2015	Coupe	Manuel	Siyah	Evet	6300	Benzin	2
30768	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	61900	2012	Coupe	Manuel	Beyaz	Hayır	58000	Benzin	2
30769	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	63850	2011	Coupe	Manuel	Beyaz	Hayır	48000	Benzin	2
30770	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	52500	2012	Coupe	Manuel	Siyah	Hayır	66000	Benzin	2
30771	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	53000	2010	Coupe	Manuel	Füme	Hayır	58000	Benzin	2
30772	Volkswagen	Scirocco	1.4 TSi GTS	71750	2013	Hatchback	Otomatik	Beyaz	Hayır	23000	Benzin	2
30773	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	58000	2011	Coupe	Manuel	Beyaz	Hayır	81500	Benzin + LPG	2
30774	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	61000	2013	Coupe	Manuel	Beyaz	Hayır	20000	Benzin	2
30775	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	63000	2012	Coupe	Manuel	Beyaz	Hayır	38000	Benzin	2
30776	Volkswagen	Scirocco	1.4 TSI 160 HP DSP Sportline	68000	2012	Coupe	Tiptronik	Beyaz	Hayır	17000	Benzin	2
30777	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	85000	2013	Coupe	Otomatik	Beyaz	Evet	35000	Benzin	2
30778	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	65000	2012	Coupe	Manuel	Beyaz	Hayır	63000	Benzin	2

30779	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	51999	2011	Coupe	Manuel	Beyaz	Hayır	91000	Benzin	2
30780	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	44000	2009	Coupe	Manuel	Beyaz	Hayır	98000	Benzin	2
30781	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	67000	2013	Coupe	Manuel	Beyaz	Evet	4000	Benzin	2
30782	Volkswagen	Scirocco	1.4 TSI 160 HP DSG Sportline	75900	2013	Coupe	Tiptronik	Beyaz	Hayır	15000	Benzin	2
30783	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	61000	2011	Coupe	Manuel	Füme	Evet	55000	Benzin	2
30784	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	62500	2011	Coupe	Manuel	Beyaz	Hayır	115000	Benzin	2
30785	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	59000	2012	Coupe	Manuel	Beyaz	Hayır	100000	Benzin	2
30786	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	85500	2014	Coupe	Otomatik	Beyaz	Evet	23500	Benzin	2
30787	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	50000	2011	Coupe	Manuel	Beyaz	Hayır	132000	Benzin	2
30788	Volkswagen	Scirocco	1.4 TSI 160 HP Sportline	54500	2011	Coupe	Manuel	Beyaz	Hayır	133000	Benzin	2
30789	Volkswagen	Scirocco	1.4 TSI 160 HP DSG Sportline	56500	2011	Coupe	Tiptronik	Beyaz	Hayır	72000	Benzin	2
30790	Volkswagen	Scirocco	1.4 TSI 160 HP DSG Sportline	57000	2013	Coupe	Tiptronik	Metalik mavi	Hayır	16000	Benzin	2
30791	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	75000	2013	Coupe	Tiptronik	Lacivert	Hayır	19750	Benzin	2
30792	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	59000	2012	Coupe	Tiptronik	Beyaz	Hayır	49800	Benzin	2
30793	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	55000	2010	Coupe	Tiptronik	Gümüş	Hayır	67000	Benzin	2
30794	Volkswagen	Scirocco	1.4 TSi GTS	70000	2013	Coupe	Otomatik	Beyaz	Hayır	26000	Benzin	2
30795	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	75500	2013	Coupe	Tiptronik	Beyaz	Hayır	21000	Benzin	2
30796	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	53000	2011	Coupe	Manuel	Beyaz	Hayır	48000	Benzin	2
30797	Volkswagen	Scirocco	1.4 TSI 122 HP Sportline	52000	2009	Coupe	Manuel	Beyaz	Hayır	32000	Benzin	2
30798	Volkswagen	Sharan	1.9 TDI	40000	2002	Stationvagon	Manuel	Lacivert	Hayır	240000	Dizel	5
30799	Volkswagen	T Serisi	T1	37500	2001	Minibs	Manuel	Lacivert	Hayır	244354	Dizel	4
30800	Volkswagen	T Serisi	T2	54999	1979	Minibs	Manuel	Turuncu	Hayır	269000	Benzin	4
30801	Volkswagen	T Serisi	T1	23000	1998	Minibs	Manuel	Siyah	Hayır	200000	Dizel	4
30802	Volkswagen	T Serisi	T2	10250	1964	Minibs	Manuel	Yeşil	Hayır	758400	Benzin	4
30803	Volkswagen	T Serisi	T2	35000	1978	Minibs	Manuel	Ak Yeşil	Hayır	51000	Benzin + LPG	4
30804	Volkswagen	T Serisi	T2	7000	1979	Minibs	Manuel	Mavi	Hayır	200000	Benzin	4
30805	Volkswagen	T Serisi	T2	19000	1976	Minibs	Manuel	Ak mavi	Hayır	90000	Benzin	4
30806	Volkswagen	T Serisi	T2	21000	2000	Panelvan	Manuel	Ak mavi	Hayır	176000	Dizel	4
30807	Volkswagen	T Serisi	T1	57500	2012	Minibs	Manuel	Gümüş	Hayır	34000	Dizel	4
30808	Volkswagen	Tiguan	1.4 TSi BMT Sport & Style DSG	87000	2013	Stationvagon	S-Tronik	Beyaz	Hayır	33400	Benzin	5
30809	Volkswagen	Tiguan	2.0 CR TDI Sport & Style DSG 4Motion	110000	2013	SUV	Otomatik	Beyaz	Hayır	88000	Dizel	5
30810	Volkswagen	Tiguan	1.4 TSi 150 HP BlueMotion Sport&Style									
30811	Volkswagen	Tiguan	1.4 TSi Sport & Style BMT	149990	2016	SUV	Tiptronik	Beyaz	Hayır	-	Benzin	Bilinmiyor
30812	Volkswagen	Tiguan	1.4 TSi 150 HP BlueMotion Sport&Style									
30813	Volkswagen	Tiguan	1.4 TSi BMT CUP	69000	2010	SUV	Manuel	Beyaz	Hayır	65000	Benzin	5
30814	Volkswagen	Tiguan	1.4 TSi Sport & Style BMT	72000	2012	Stationvagon	Manuel	Beyaz	Hayır	26000	Benzin	5
30815	Volkswagen	Tiguan	1.4 TSi 150 HP 4Motion Sport&Style									
30816	Volkswagen	Tiguan	1.4 TSi Trend & Fun	60750	2010	SUV	Manuel	Beyaz	Hayır	112000	Benzin + LPG	5
30817	Volkswagen	Tiguan	1.4 TSi Sport & Style BMT	76500	2015	SUV	Manuel	Beyaz	Hayır	25000	Benzin	5
30818	Volkswagen	Tiguan	1.4 TSi White Night BMT	75000	2012	Stationvagon	Manuel	Beyaz	Hayır	58000	Benzin	5
30819	Volkswagen	Tiguan	1.4 TSi Sport & Style BMT	77500	2015	Stationvagon	Manuel	Beyaz	Hayır	21000	Benzin	5
30820	Volkswagen	Tiguan	1.4 TSi 150 HP 4Motion Sport&Style									
30821	Volkswagen	Tiguan	1.4 TSi Sport & Style BMT	72500	2013	Stationvagon	Manuel	Beyaz	Hayır	35000	Benzin	5

30822	Volkswagen	Tiguan	1.4 TSI Chrome Edition BMT	80000	2013	Stationvagon	Manuel	Beyaz	Hayır	20000	Benzin	5
30823	Volkswagen	Tiguan	1.4 TSI Trend & Fun	83000	2015	SUV	Manuel	Beyaz	Evet	18000	Benzin	5
30824	Volkswagen	Tiguan	2.0 CR TDI Sport & Style DSG 4Motion	97000	2012	Stationvagon	Tiptronik	Beyaz	Hayır	86000	Dizel	5
30825	Volkswagen	Tiguan	1.4 TSI BMT CUP	70500	2012	SUV	Manuel	Beyaz	Hayır	46000	Benzin	5
30826	Volkswagen	Tiguan	1.4 TSI 150 HP BlueMotion Sport&Style									
30827	Volkswagen	Tiguan	2.0 CR TDI Sport & Style DSG 4Motion	108000	2013	Stationvagon	S-Tronik	Gri	Hayır	55000	Dizel	5
30828	Volkswagen	Tiguan	1.4 TSI BMT Sport & Style DSG	87500	2013	SUV	Otomatik	Beyaz	Hayır	49200	Benzin	5
30829	Volkswagen	Tiguan	1.4 TSI BMT Chrome Edition DSG	93000	2014	SUV	Otomatik	Beyaz	Evet	16000	Benzin	5
30830	Volkswagen	Tiguan	1.4 TSI BMT Sport & Style DSG	70500	2012	SUV	Tiptronik	Beyaz	Hayır	52000	Benzin	5
30831	Volkswagen	Tiguan	2.0 CR TDI Sport & Style DSG 4Motion	85000	2011	SUV	S-Tronik	Beyaz	Hayır	117000	Dizel	5
30832	Volkswagen	Tiguan	1.4 TSI 150 HP 4Motion Sport&Style									
30833	Volkswagen	Tiguan	2.0 CR TDI Sport & Style DSG 4Motion	110000	2014	Stationvagon	S-Tronik	Beyaz	Hayır	63500	Dizel	5
30834	Volkswagen	Tiguan	1.4 TSI 150 HP BlueMotion Sport&Style									
30835	Volkswagen	Tiguan	2.0 CR TDI Sport & Style DSG 4Motion	111500	2013	Stationvagon	Tiptronik	Kırmızı	Hayır	90000	Dizel	5
30836	Volkswagen	Tiguan	Sport&Style									
30837	Volkswagen	Tiguan	1.4 TSI 150 HP 4Motion Sport&Style									
30838	Volkswagen	Tiguan	1.4 TSI Trend & Fun	60500	2010	SUV	Manuel	Beyaz	Hayır	87965	Benzin	5
30839	Volkswagen	Tiguan	1.4 TSI 150 HP BlueMotion Sport&Style									
30840	Volkswagen	Tiguan	1.4 TSI Sport & Style BMT	66500	2012	Stationvagon	Manuel	Beyaz	Hayır	61600	Benzin	5
30841	Volkswagen	Tiguan	1.4 TSI 150 HP BlueMotion Sport&Style									
30842	Volkswagen	Tiguan	1.4 TSI White Night BMT	72000	2012	SUV	Manuel	Beyaz	Hayır	78000	Benzin	5
30843	Volkswagen	Tiguan	1.4 TSI BMT CUP	72800	2014	SUV	Manuel	Beyaz	Evet	50000	Benzin	5
30844	Volkswagen	Tiguan	1.4 TSI 150 HP 4Motion Sport&Style									
30845	Volkswagen	Tiguan	1.4 TSI Sport & Style BMT	66250	2012	Stationvagon	Manuel	Beyaz	Hayır	86000	Benzin	5
30846	Volkswagen	Tiguan	1.4 TSI Sport & Style 4Motion	72000	2012	Stationvagon	Manuel	Beyaz	Hayır	67400	Benzin	5
30847	Volkswagen	Tiguan	1.4 TSI 150 HP BlueMotion Sport&Style									
30848	Volkswagen	Tiguan	1.4 TSI Trend & Fun	73000	2016	SUV	Manuel	Kahverengi	Hayır	17200	Benzin	5
30849	Volkswagen	Tiguan	1.4 TSI 150 HP 4Motion Sport&Style									
30850	Volkswagen	Tiguan	1.4 TSI BMT CUP	90000	2015	SUV	Otomatik	Gri	Evet	11000	Benzin	5
30851	Volkswagen	Tiguan	2.0 CR TDI Sport & Style DSG 4Motion	99000	2012	Stationvagon	S-Tronik	Beyaz	Hayır	41000	Dizel	5
30852	Volkswagen	Tiguan	1.4 TSI 150 HP 4Motion Sport&Style									
30853	Volkswagen	Tiguan	1.4 TSI 150 HP BlueMotion Sport&Style									
30854	Volkswagen	Tiguan	1.4 TSI Trend & Fun	68000	2014	SUV	Manuel	Beyaz	Evet	2500	Benzin	5
30855	Volkswagen	Tiguan	2.0 CR TDI Sport & Style DSG 4Motion	115000	2012	SUV	Tiptronik	Beyaz	Hayır	42500	Dizel	5
30856	Volkswagen	Tiguan	1.4 TSI Sport & Style 4Motion	83000	2014	SUV	Manuel	Kahverengi	Hayır	30000	Benzin	5
30857	Volkswagen	Tiguan	1.4 TSI Trend & Fun	68000	2014	SUV	Manuel	Beyaz	Evet	28500	Benzin	5
30858	Volkswagen	Tiguan	Sport&Style									
30859	Volkswagen	Tiguan	1.4 TSI 150 HP BlueMotion Sport&Style									
30860	Volkswagen	Tiguan	1.4 TSI Sport & Style BMT	73000	2013	Stationvagon	Manuel	Siyah	Hayır	18500	Benzin	5
30861	Volkswagen	Tiguan	1.4 TSI Sport & Style BMT	71000	2013	Stationvagon	Manuel	Siyah	Hayır	47000	Benzin	5
30862	Volkswagen	Tiguan	1.4 TSI Trend & Fun	63000	2009	SUV	Manuel	Beyaz	Evet	112000	Benzin	5
30863	Volkswagen	Tiguan	1.4 TSI 150 HP 4Motion Fun&Function									
30864	Volkswagen	Tiguan	1.4 TSI 150 HP 4Motion Fun&Function									

30865	Volkswagen	Tiguan	1.4 TSi BMT Chrome Edition DSG	90000	2014	SUV	Tiptronik	Lacivert	Evet	5610	Benzin	5
30866	Volkswagen	Tiguan	1.4 TSi BMT CUP	74000	2012	SUV	Manuel	Beyaz	Hayır	28300	Benzin	4
30867	Volkswagen	Tiguan	1.4 TSi 150 HP BlueMotion Sport&Style									
30868	Volkswagen	Tiguan	1.4 TSi 150 HP BlueMotion Sport&Style									
30869	Volkswagen	Tiguan	1.4 TSi White Night BMT	75000	2012	Stationvagon	Manuel	Beyaz	Hayır	49000	Benzin	5
30870	Volkswagen	Tiguan	1.4 TSi BMT Sport & Style DSG	75000	2013	SUV	Manuel	Beyaz	Hayır	11000	Benzin	5
30871	Volkswagen	Tiguan	1.4 TSi Trend & Fun	62000	2013	SUV	Manuel	Siyah	Hayır	60000	Benzin	5
30872	Volkswagen	Tiguan	1.4 TSi Trend & Fun	69000	2012	SUV	Manuel	Siyah	Hayır	8800	Benzin	5
30873	Volkswagen	Tiguan	1.4 TSi 150 HP 4Motion Sport&Style									
30874	Volkswagen	Tiguan	1.4 TSi Trend & Fun	58500	2010	SUV	Manuel	Gri	Hayır	63000	Benzin	5
30875	Volkswagen	Tiguan	1.4 TSi Sport & Style BMT	59750	2012	SUV	Manuel	Mavi	Hayır	47000	Benzin	5
30876	Volkswagen	Touareg	3.0 V6 TDI Exclusive Tiptronic	179900	2012	SUV	Tiptronik	Beyaz	Hayır	113000	Dizel	Bilinmiyor
30877	Volkswagen	Touareg	3.2 V6 Tiptronic	64200	2003	SUV	Tiptronik	Petrol	Hayır	170000	Benzin	5
30878	Volkswagen	Touareg	3.2 V6 Tiptronic	68500	2004	SUV	Tiptronik	Mavi	Hayır	166000	Benzin + LPG	5
30879	Volkswagen	Touareg	2.5 R5 TDI Tiptronic	71500	2005	SUV	Tiptronik	Kırmızı	Hayır	226000	Dizel	5
30880	Volkswagen	Touareg	2.5 R5 TDI Tiptronic	75000	2005	SUV	Tiptronik	Gri	Hayır	208000	Dizel	5
30881	Volkswagen	Touareg	3.2 V6 Tiptronic	60000	2003	SUV	Tiptronik	Gri	Evet	201000	Benzin + LPG	5
30882	Volkswagen	Touareg	2.5 R5 TDI Tiptronic	75000	2005	SUV	Tiptronik	Siyah	Hayır	233000	Dizel	5
30883	Volkswagen	Touran	1.6 FSI Comfortline	34500	2004	Stationvagon	Manuel	Mavi	Hayır	106000	Benzin	5
30884	Volkswagen	Touran	1.6 FSI Comfortline	38000	2004	Stationvagon	Otomatik	Siyah	Hayır	96000	Benzin	5
30885	Volkswagen	Touran	1.6 FSI Comfortline	35000	2005	Hatchback	Tiptronik	Gri	Hayır	70000	Benzin + LPG	5
30886	Volkswagen	Touran	1.6 FSI Highline	29500	2004	Stationvagon	Manuel	Gri	Hayır	158000	Benzin	5
30887	Volkswagen	Touran	1.6 FSI Highline Tiptronic	34500	2005	Stationvagon	Tiptronik	Siyah	Hayır	137000	Benzin	5
30888	Volkswagen	Touran	1.6 Function	44750	2009	Stationvagon	Manuel	Siyah	Hayır	82000	Benzin	5
30889	Volkswagen	Touran	1.4 TSi Comfortline	29500	2008	ift kabinasi	Manuel	Gri	Hayır	134	Benzin	5
30890	Volkswagen	Touran	1.6 FSI Highline	26250	2004	Stationvagon	Manuel	Gri	Hayır	149000	Benzin	5
30891	Volkswagen	Touran	1.4 TSi Comfortline Tiptronik DSG	48500	2010	Stationvagon	Otomatik	Siyah	Hayır	115000	Benzin	5
30892	Volkswagen	Touran	1.6 FSI Highline	31500	2006	Stationvagon	Otomatik	Gri	Hayır	101000	Benzin	5
30893	Volkswagen	Touran	1.6 Comfortline	31250	2004	Stationvagon	Manuel	Gri	Hayır	128500	Benzin	5
30894	Volkswagen	Transporter	T5	55750	2012	Mimibs	Manuel	Gri	Hayır	148200	Dizel	4
30895	Volkswagen	Vento	1.8 CL	17750	1996	Sedan	Manuel	Metalik gri	Hayır	172000	Benzin	4
30896	Volkswagen	Vento	1.6 GL Executive	17000	1997	Sedan	Manuel	Mor	Evet	218000	Benzin + LPG	5
30897	Volkswagen	Vento	1.6 CL	13500	1993	Sedan	Manuel	Beyaz	Hayır	233682	Dizel	4
30898	Volvo	440		6000	1991	Hatchback	Manuel	Kırmızı	Hayır	140000	Benzin + LPG	5
30899	Volvo	440	1.9 Turbo D	80000	1996	ift kabinasi	Manuel	Kırmızı	Hayır	380000	Dizel	2
30900	Volvo	460	GLE	2500	1991	Sedan	Manuel	Koyu mavi	Hayır	370800	Benzin	4
30901	Volvo	850	2.0 T5	23500	1996	Sedan	Otomatik	Mavi	Hayır	164000	Benzin	4
30902	Volvo	850	2.0 T5	20750	1997	Sedan	Otomatik	Beyaz	Hayır	282070	Benzin + LPG	4
30903	Volvo	850	2.0 T5	23500	1996	Sedan	Otomatik	Mavi	Hayır	163000	Benzin + LPG	4
30904	Volvo	850	2.0 T5	17500	1996	Sedan	Otomatik	Gri	Hayır	213000	Benzin + LPG	4
30905	Volvo	850	2.5 TDI	25500	1996	Sedan	Manuel	Metalik gri	Hayır	200000	Dizel	4
30906	Volvo	960	3.0 24V Aut.	20000	1995	Sedan	Otomatik	Bej	Hayır	220000	Benzin + LPG	4
30907	Volvo	C30	1.6 Style Edition	39500	2008	Hatchback	Manuel	Siyah	Hayır	187000	Dizel	3

30908	Volvo	C70	2.5 T5 Geartronic	71000	2007	Cabrio	Otomatik	Siyah	Hayır	103000	Benzin	2
30909	Volvo	C70	2.0 T Coupe	25000	2002	Coupe	Manuel	Gri	Hayır	184000	Benzin	2
30910	Volvo	S40	1.8ü	24750	2001	Sedan	Manuel	Gri	Hayır	249400	Benzin + LPG	4
30911	Volvo	S40	1.8ü	22750	2001	Sedan	Manuel	Mor	Hayır	202000	Benzin	4
30912	Volvo	S40	1.6 D 1.6	42750	2006	Sedan	Manuel	Gri	Hayır	129000	Benzin + LPG	4
30913	Volvo	S40	1.8	23000	2000	Sedan	Manuel	Gümüş	Hayır	225000	Benzin	5
30914	Volvo	S40	1.6 D	43800	2006	Sedan	Manuel	Titanyum gri	Hayır	218000	Dizel	4
30915	Volvo	S40	1.6 D Premium Edition	46500	2009	Sedan	Manuel	Siyah	Hayır	195000	Dizel	4
30916	Volvo	S40	1.8 Aut.	26000	2001	Sedan	Otomatik	Gri	Hayır	103000	Benzin	4
30917	Volvo	S40	1.6 D	35500	2006	Sedan	Manuel	Lacivert	Hayır	252000	Dizel	4
30918	Volvo	S60	2.4 D5 Premium Edition Geartronic	55000	2007	Sedan	Tiptronik	Gri	Hayır	270000	Dizel	4
30919	Volvo	S60	2.0 D4	135000	2014	Sedan	Otomatik	Beyaz	Hayır	66000	Dizel	4
30920	Volvo	S60	1.6 D Drive Premium Powershift	85000	2012	Sedan	S-Tronik	Beyaz	Hayır	69999	Dizel	4
30921	Volvo	S60	1.6 D Drive Premium Powershift	102750	2015	Sedan	S-Tronik	Siyah	Evet	30000	Dizel	4
30922	Volvo	S60	1.6 D Drive Premium Powershift	77000	2012	Sedan	Otomatik	Siyah	Hayır	150000	Dizel	4
30923	Volvo	S60	1.6 D Drive Advance Powershift	83900	2013	Sedan	Tiptronik	Beyaz	Hayır	89000	Dizel	Bilinmiyor
30924	Volvo	S60	1.6 D Drive Premium Powershift	82000	2013	Sedan	S-Tronik	Beyaz	Hayır	52400	Dizel	4
30925	Volvo	S60	1.5 T3 Premium	122000	2015	Sedan	Otomatik	Beyaz	Evet	-	Benzin	4
30926	Volvo	S60	1.6 DRIVe	78000	2011	Sedan	Manuel	Beyaz	Hayır	70000	Dizel	4
30927	Volvo	S60	1.6 D Drive Advance Powershift	92000	2013	Sedan	Otomatik	Siyah	Hayır	52000	Dizel	4
30928	Volvo	S60	Geartronic	43500	2006	Sedan	Otomatik	Metalik gri	Hayır	239000	Benzin + LPG	4
30929	Volvo	S60	1.6 T4 180 HP Powershift	72250	2011	Sedan	Otomatik	Siyah	Hayır	96000	Benzin	4
30930	Volvo	S60	1.6 D Drive Premium Powershift	79750	2013	Sedan	Otomatik	Beyaz	Hayır	100000	Dizel	4
30931	Volvo	S60	1.6 T4 180 HP Powershift	66000	2011	Sedan	Otomatik	Siyah	Hayır	109625	Benzin	4
30932	Volvo	S60	1.6 D Drive Premium Powershift	76000	2012	Sedan	Manuel	Beyaz	Hayır	80000	Benzin	4
30933	Volvo	S60	2.0 T Business Edition Otomatik	49000	2009	Sedan	Otomatik	Mavi	Hayır	268000	Benzin + LPG	4
30934	Volvo	S60	1.6 D Drive Powershift	82000	2013	Sedan	S-Tronik	Beyaz	Hayır	77000	Dizel	4
30935	Volvo	S60	1.6 T4 180 HP R-design Powershift	86000	2012	Sedan	Tiptronik	Beyaz	Hayır	34000	Benzin	4
30936	Volvo	S60	1.6 D Drive Advance Powershift	74900	2012	Sedan	Otomatik	Koyu mavi	Hayır	105000	Dizel	4
30937	Volvo	S60	1.6 D Drive R-Desing Powershift	89750	2013	Sedan	S-Tronik	Beyaz	Hayır	88000	Dizel	4
30938	Volvo	S60	1.6 D Drive Premium Powershift	83750	2013	Sedan	Otomatik	Beyaz	Hayır	69000	Dizel	4
30939	Volvo	S60	1.6 D Drive R-Desing Powershift	103000	2014	Sedan	S-Tronik	Mavi	Hayır	80000	Dizel	4
30940	Volvo	S60	1.6 DRIVe	97000	2012	Sedan	Otomatik	Metalik gri	Hayır	14900	Benzin	4
30941	Volvo	S60	2.0 T Sports Edition Otomatik	48500	2008	Sedan	Otomatik	Gri	Hayır	159000	Benzin	4
30942	Volvo	S60	1.6 D Drive Advance Powershift	73000	2012	Sedan	Manuel	Beyaz	Hayır	88000	Dizel	4
30943	Volvo	S60	1.6 T4 180 HP Powershift	64000	2011	Sedan	Otomatik	Siyah	Hayır	95000	Benzin	4
30944	Volvo	S60	1.6 D Drive R-Desing Powershift	86500	2012	Sedan	Otomatik	Beyaz	Hayır	145000	Dizel	4
30945	Volvo	S60	1.6 D Drive Advance Powershift	105000	2014	Sedan	Otomatik	Siyah	Evet	11400	Dizel	4
30946	Volvo	S60	1.6 T4 180 HP Powershift	68500	2011	Sedan	Tiptronik	Beyaz	Hayır	134000	Benzin	4
30947	Volvo	S60	2.0 T	34750	2004	Sedan	Manuel	Mavi	Hayır	295000	Benzin	4
30948	Volvo	S60	1.6 D Drive Advance Powershift	113500	2014	Sedan	S-Tronik	Siyah	Evet	11300	Dizel	4
30949	Volvo	S60	1.6 D Drive Premium Powershift	79000	2014	Sedan	Otomatik	Beyaz	Hayır	18000	Dizel	4
30950	Volvo	S60	1.6 D Drive Advance Powershift	116000	2013	Sedan	Manuel	Beyaz	Evet	18000	Dizel	4

30951	Volvo	S60	2.0 T Premium Edition Otomatik	55500	2009	Sedan	Otomatik	Gri	Hayır	109000	Benzin	4
30952	Volvo	S60	1.6 D Drive Premium Powershift	80000	2012	Sedan	Manuel	Beyaz	Hayır	78000	Dizel	4
30953	Volvo	S60	1.6 D Drive Advance Powershift	105000	2013	Sedan	S-Tronik	Beyaz	Evet	64500	Dizel	4
30954	Volvo	S60	1.6 T4 180 HP Powershift	67450	2011	Sedan	Tiptronik	Siyah	Hayır	82000	Benzin	4
30955	Volvo	S60	1.6 D Drive Premium Powershift	78900	2012	Sedan	S-Tronik	Siyah	Hayır	69000	Dizel	4
30956	Volvo	S60	2.0 T Premium Edition Otomatik	57500	2010	Sedan	Otomatik	Gri	Hayır	94000	Benzin	4
30957	Volvo	S60	1.6 T4 180 HP Powershift	75000	2011	Sedan	Tiptronik	Beyaz	Hayır	25000	Benzin	4
30958	Volvo	S60	2.0 D3 163 HP Geartronic	95000	2011	Sedan	Otomatik	Beyaz	Hayır	83000	Dizel	4
30959	Volvo	S60	1.6 D Drive Premium Powershift	85450	2013	Sedan	Otomatik	Siyah	Hayır	36000	Dizel	4
30960	Volvo	S60	1.6 DRIVe	79500	2012	Sedan	Manuel	Beyaz	Evet	36000	Dizel	4
30961	Volvo	S60	1.6 D Drive Powershift	77300	2012	Sedan	Otomatik	Siyah	Hayır	59653	Dizel	Bilinmiyor
30962	Volvo	S60	1.6 D Drive Premium Powershift	78900	2012	Sedan	Manuel	Beyaz	Hayır	17200	Dizel	Bilinmiyor
30963	Volvo	S60	2.0 D3 163 HP Geartronic	102500	2011	Sedan	Tiptronik	Beyaz	Hayır	66800	Dizel	4
30964	Volvo	S60	2.5 T	31000	2002	Sedan	Otomatik	Yeşil	Hayır	185000	Benzin + LPG	4
30965	Volvo	S60	1.6 D Drive Premium Powershift	83000	2013	Sedan	Otomatik	Beyaz	Hayır	37700	Dizel	Bilinmiyor
30966	Volvo	S60	1.6 T4 180 HP Powershift	83000	2013	Sedan	Otomatik	Beyaz	Hayır	49728	Dizel	Bilinmiyor
30967	Volvo	S60	1.6 D Drive Powershift	97000	2014	Sedan	Otomatik	Siyah	Hayır	18130	Dizel	Bilinmiyor
30968	Volvo	S60	1.6 D Drive Powershift	97000	2014	Sedan	Otomatik	Beyaz	Hayır	11438	Dizel	Bilinmiyor
30969	Volvo	S60	2.0 T5 240 HP Powershift	101000	2014	Sedan	Otomatik	Siyah	Hayır	18599	Dizel	Bilinmiyor
30970	Volvo	S60	2.0 T5 240 HP Powershift	98000	2014	Sedan	Otomatik	Siyah	Hayır	19484	Dizel	Bilinmiyor
30971	Volvo	S60	1.6 D Drive Premium Powershift	80000	2011	Sedan	Manuel	Beyaz	Hayır	55200	Dizel	5
30972	Volvo	S60	1.6 D Drive Premium Powershift	95000	2013	Sedan	S-Tronik	Siyah	Evet	39000	Dizel	4
30973	Volvo	S60	2.0 T Premium Edition Otomatik	41500	2008	Sedan	Otomatik	Kahverengi	Hayır	175000	Benzin	4
30974	Volvo	S60	1.6 T4 180 HP Powershift	70000	2011	Sedan	Otomatik	Beyaz	Hayır	43000	Benzin	4
30975	Volvo	S60	2.0 D3 163 HP R-design Geartronic	112000	2012	Sedan	Otomatik	Beyaz	Hayır	23500	Dizel	4
30976	Volvo	S60	1.6 T4 180 HP Powershift	83000	2012	Sedan	Tiptronik	Gri	Hayır	32400	Benzin	4
30977	Volvo	S60	2.0 T	32000	2002	Sedan	Manuel	Okyanus mavı	Hayır	250000	Benzin + LPG	4
30978	Volvo	S60	1.6 D Drive Advance Powershift	98000	2013	Sedan	Otomatik	Siyah	Evet	19000	Dizel	4
30979	Volvo	S60	2.0 T Aut.	41000	2004	Sedan	Otomatik	Gri	Hayır	153000	Benzin	4
30980	Volvo	S60	2.4 D	31000	2003	Sedan	Otomatik	Gri	Hayır	320000	Benzin + LPG	5
30981	Volvo	S60	1.6 T4 180 HP Powershift	77500	2011	Sedan	Otomatik	Siyah	Hayır	28000	Benzin	4
30982	Volvo	S60	2.4 D5 Premium Edition Geartronic	60000	2008	Sedan	Tiptronik	Siyah	Hayır	141000	Dizel	4
30983	Volvo	S60	2.0 D3 163 HP R-design Geartronic	81000	2011	Sedan	Tiptronik	Beyaz	Hayır	98000	Dizel	Bilinmiyor
30984	Volvo	S60	1.6 D Drive Advance Powershift	84500	2012	Sedan	Tiptronik	Kahverengi	Hayır	131880	Dizel	4
30985	Volvo	S60	2.0 T 203 HP R-design Powershift	83000	2011	Sedan	Tiptronik	Beyaz	Hayır	79000	Benzin	4
30986	Volvo	S60	1.6 D Drive Advance Powershift	106000	2013	Sedan	Otomatik	Beyaz	Evet	27000	Dizel	4
30987	Volvo	S60	1.6 D Drive Premium Powershift	72000	2012	Sedan	Manuel	Beyaz	Hayır	113000	Dizel	4
30988	Volvo	S60	2.0 T	36000	2004	Sedan	Otomatik	Kırmızı	Hayır	219000	Benzin	4
30989	Volvo	S60	1.6 D Drive Premium Powershift	95000	2014	Sedan	Otomatik	Beyaz	Hayır	46500	Dizel	4
30990	Volvo	S60	2.0 T Premium Edition	45500	2006	Sedan	Otomatik	Siyah	Hayır	145200	Benzin	4
30991	Volvo	S60	2.4 D5 Premium Edition Geartronic	44900	2007	Sedan	Tiptronik	Gri	Hayır	198000	Dizel	4
30992	Volvo	S60	1.6 D Drive Advance Powershift	77000	2011	Sedan	Manuel	Siyah	Hayır	83000	Dizel	4
30993	Volvo	S60	2.3 T-5 Aut.	36500	2001	Sedan	Otomatik	Kırmızı	Hayır	320000	Benzin + LPG	4

30994	Volvo	S60	2.0 T Premium Edition Otomatik	47000	2007	Sedan	Otomatik	Metalik mavi	Hayır	129000	Benzin	4
30995	Volvo	S60	1.6 T4 180 HP Powershift	79500	2012	Sedan	Tiptronik	BakA+r	Hayır	39950	Benzin	4
30996	Volvo	S60	1.6 D Drive Premium Powershift	92000	2014	Sedan	Manuel	Beyaz	Evet	14500	Dizel	5
30997	Volvo	S60	2.0 D3 163 HP Geartronic	98500	2014	Sedan	Otomatik	Siyah	Hayır	17941	Dizel	Bilinmiyor
30998	Volvo	S60	1.6 T4 180 HP Powershift	86000	2013	Sedan	Otomatik	Beyaz	Hayır	84811	Dizel	Bilinmiyor
30999	Volvo	S60	2.0 D3 163 HP Geartronic	100000	2014	Sedan	Otomatik	Siyah	Hayır	32600	Dizel	Bilinmiyor
31000	Volvo	S60	1.6 D Drive Advance Powershift	87000	2012	Sedan	S-Tronik	Beyaz	Hayır	51000	Dizel	4
31001	Volvo	S60	2.0 T	33000	2004	Hatchback	Manuel	Metalik mavi	Hayır	187000	Benzin	5
31002	Volvo	S60	1.6 D Drive Premium Powershift	87000	2012	Sedan	S-Tronik	Bej	Evet	30000	Dizel	4
31003	Volvo	S60	2.0 T Premium Edition Otomatik	54000	2010	Sedan	Otomatik	Gri	Hayır	60000	Benzin	4
31004	Volvo	S70	2.0 T-5	30500	1999	Sedan	Otomatik	Kahverengi	Hayır	245000	Benzin	4
31005	Volvo	S70	2.0 T-5	23500	1996	Sedan	Otomatik	Siyah	Hayır	364000	Benzin	4
31006	Volvo	S70	2.0 T	23000	1998	Sedan	Manuel	Gri	Hayır	250000	Benzin	4
31007	Volvo	S80	1.6 D Drive	95000	2012	Sedan	Tiptronik	Siyah	Hayır	73000	Dizel	4
31008	Volvo	S80	2.0 T	35500	2000	Sedan	Manuel	Bej	Hayır	139000	Benzin	4
31009	Volvo	S80	2.0 T	27000	2001	Sedan	Otomatik	Metalik gri	Hayır	345000	Benzin + LPG	4
31010	Volvo	S80	2.0 T	35500	2000	Sedan	Otomatik	Gri	Hayır	212000	Benzin	4
31011	Volvo	S80	2.8 T6	35500	2001	Sedan	Otomatik	Gümüş	Hayır	385000	Benzin	4
31012	Volvo	S80	2.4 D [D5] Premium Edition Geartronic	67000	2007	Sedan	Tiptronik	Siyah	Hayır	230000	Dizel	4
31013	Volvo	S80	2.0 T-5	23500	1999	Sedan	Otomatik	Gri	Hayır	236000	Benzin + LPG	4
31014	Volvo	S80	1.6 D2 Advance Powershift	98000	2012	Sedan	Otomatik	Beyaz	Hayır	75000	Dizel	4
31015	Volvo	S80	2.4 D [D5] VIP Edition Geartronic	85000	2007	Sedan	Otomatik	Siyah	Hayır	131000	Dizel	4
31016	Volvo	S80	2.0 T-5	32000	2000	Sedan	Otomatik	Gri	Hayır	326000	Benzin + LPG	4
31017	Volvo	S80	2.0 T	22000	2000	Sedan	Otomatik	Gri	Hayır	44000	Benzin	4
31018	Volvo	S80	2.8 T6	32000	2000	Sedan	Tiptronik	Gri	Hayır	196000	Benzin + LPG	4
31019	Volvo	S80	1.6 D Drive	115000	2012	Sedan	Otomatik	Beyaz	Evet	73850	Dizel	4
31020	Volvo	S80	2.8 T6	20500	2001	Sedan	Otomatik	Kırmızı	Hayır	200206	Benzin + LPG	4
31021	Volvo	S80	1.6 D2 Powershift	113000	2013	Sedan	S-Tronik	Beyaz	Evet	81000	Dizel	4
31022	Volvo	S80	2.5 D	32500	2005	Sedan	Otomatik	Füme	Hayır	520000	Dizel	4
31023	Volvo	S80	2.0 T	35000	2001	Sedan	Manuel	Siyah	Hayır	150000	Benzin	4
31024	Volvo	S80	2.0 D3 163 HP Otomatik Vites	87500	2011	Sedan	Otomatik	Siyah	Hayır	170000	Dizel	4
31025	Volvo	S80	1.6 T4 180 HP Powershift	99000	2012	Sedan	Tiptronik	Siyah	Hayır	34000	Benzin	4
31026	Volvo	S80	1.6 T4 180 HP Powershift	102000	2012	Sedan	Otomatik	Beyaz	Hayır	20000	Benzin	4
31027	Volvo	S80	1.6 D2 Premium Powershift	105000	2012	Sedan	S-Tronik	Gri	Hayır	37700	Dizel	4
31028	Volvo	S80	2.5 T	26000	2000	Sedan	Otomatik	Bordo	Hayır	262000	Benzin + LPG	4
31029	Volvo	S80	2.0 T-5	22000	2000	Sedan	Otomatik	Lacivert	Hayır	340000	Benzin + LPG	5
31030	Volvo	S80	2.0 T	29500	2000	Sedan	Otomatik	Okyanus mavi	Hayır	242000	Benzin	4
31031	Volvo	S80	2.0 D4 Advance Geartronic	127000	2012	Sedan	Tiptronik	Siyah	Hayır	26800	Dizel	4
31032	Volvo	S80	2.4 D [D5] AWD VIP Edition Geartronic	59500	2007	Sedan	Otomatik	BakA+r	Hayır	201000	Dizel	4
31033	Volvo	S80	2.8 T6	24900	2000	Sedan	Tiptronik	Koyu mavi	Hayır	202000	Benzin + LPG	4
31034	Volvo	S80	2.0 T	28500	2001	Sedan	Otomatik	Açık gri	Hayır	283000	Benzin + LPG	4
31035	Volvo	S80	1.6 D2 Advance Powershift	122500	2012	Sedan	Tiptronik	Beyaz	Hayır	23000	Dizel	4
31036	Volvo	S80	2.4 D5 205 HP AWD Otomatik Vites	95000	2010	Sedan	Otomatik	Koyu mavi	Evet	140000	Dizel	4

31037	Volvo	V40	1.6 D2	99000	2014	Hatchback	Tiptronik	Mavi	Hayır	31000	Dizel	5
31038	Volvo	V40	1.6 D2	104000	2015	Hatchback	Otomatik	Kahverengi	Evet	23300	Dizel	5
31039	Volvo	V40	1.6 D2	90000	2015	Hatchback	Otomatik	Beyaz	Hayır	25000	Dizel	5
31040	Volvo	V40	1.6 D2	82000	2013	Hatchback	Manuel	Beyaz	Hayır	45000	Dizel	5
31041	Volvo	V40	1.6 D2	97000	2015	Hatchback	Otomatik	Beyaz	Evet	25000	Dizel	5
31042	Volvo	V40	1.6 D2	96000	2014	Hatchback	Otomatik	Beyaz	Hayır	32900	Dizel	5
31043	Volvo	V40	2	24000	2000	Sedan	Otomatik	Gri	Hayır	160000	Benzin + LPG	5
31044	Volvo	V40	1.6 D2	91000	2014	Hatchback	Otomatik	Siyah	Evet	21640	Dizel	5
31045	Volvo	V40	1.8ü	26500	2001	Stationvagon	Otomatik	Bej	Hayır	210000	Benzin	5
31046	Volvo	V40	1.Haz	24250	2001	Stationvagon	Manuel	Siyah	Hayır	242000	Benzin	5
31047	Volvo	V40	1.8ü	26000	2001	Stationvagon	Otomatik	Siyah	Hayır	268000	Benzin + LPG	5
31048	Volvo	V40	1.Haz	94000	2014	Hatchback	Otomatik	Beyaz	Hayır	29000	Dizel	5
31049	Volvo	V40	1.6 D2 Advance	97000	2013	Hatchback	Otomatik	Beyaz	Evet	18600	Dizel	5
31050	Volvo	V40	1.6 T4	87000	2013	Hatchback	Otomatik	Mavi	Evet	34400	Benzin	5
31051	Volvo	V40	1.6 D2	91500	2014	Hatchback	Otomatik	Beyaz	Evet	26000	Dizel	5
31052	Volvo	V40	1.6 D2	82000	2013	Hatchback	Otomatik	Siyah	Evet	72000	Dizel	5
31053	Volvo	V40	1.6 D2	79250	2014	Hatchback	Otomatik	Bordo	Evet	5700	Dizel	5
31054	Volvo	V40	1.6 T4	80000	2013	Hatchback	Otomatik	Beyaz	Evet	26000	Benzin	5
31055	Volvo	V40	1.6 D2	84500	2013	Hatchback	Manuel	Beyaz	Evet	49850	Dizel	5
31056	Volvo	V40	1.6 D2	84500	2013	Hatchback	Manuel	Beyaz	Evet	49850	Dizel	5
31057	Volvo	V40	1.6 D2	89000	2014	Hatchback	Otomatik	Beyaz	Hayır	19000	Dizel	5
31058	Volvo	V40	2	17000	1998	Stationvagon	Manuel	Mavi	Hayır	290000	Benzin	5
31059	Volvo	V40	1.6 D2	91500	2014	Hatchback	Otomatik	Siyah	Hayır	11000	Dizel	5
31060	Volvo	V40	2.0 T	21750	1998	Stationvagon	Manuel	Gri	Hayır	336600	Benzin	5
31061	Volvo	V40	2	21000	1998	Stationvagon	Manuel	Siyah	Hayır	200000	Benzin	5
31062	Volvo	V40	1.6 D2	82500	2013	Hatchback	Otomatik	Beyaz	Hayır	70000	Dizel	5
31063	Volvo	V40	1.6 D2	83000	2013	Hatchback	Tiptronik	Beyaz	Hayır	22500	Dizel	5
31064	Volvo	V40	1.6 D2	82000	2013	Hatchback	Tiptronik	Mavi	Evet	19000	Dizel	5
31065	Volvo	V40	1.6 D2	84000	2014	Hatchback	Tiptronik	Kırmızı	Evet	26000	Dizel	5
31066	Volvo	V40	1.6 D2	100000	2013	Hatchback	Manuel	Bordo	Hayır	16420	Dizel	5
31067	Volvo	V40	1.8ü	16750	2000	Stationvagon	Manuel	Gri	Hayır	180000	Benzin + LPG	5
31068	Volvo	V40	2	19500	1998	Stationvagon	Manuel	Kırmızı	Hayır	19500	Benzin	5
31069	Volvo	V40	1.6 D2	88500	2013	Hatchback	Tiptronik	Beyaz	Hayır	27000	Dizel	5
31070	Volvo	V40	1.6 D2	78500	2014	Hatchback	Otomatik	Beyaz	Hayır	21000	Dizel	5
31071	Volvo	V40	2.0 T	17600	2000	Stationvagon	Manuel	Siyah	Hayır	170000	Benzin	5
31072	Volvo	V40	1.6 D2	70000	2013	Hatchback	Manuel	Beyaz	Evet	70000	Dizel	5
31073	Volvo	V40	1.6 D2	81000	2013	Hatchback	Manuel	Beyaz	Hayır	39500	Dizel	5
31074	Volvo	V50	2.0 D	41500	2006	Stationvagon	Manuel	Gri	Hayır	270000	Dizel	5
31075	Volvo	V50	1.6 D	44000	2005	Stationvagon	Manuel	Mavi	Hayır	230000	Dizel	5
31076	Volvo	V50	1.6 D 1.6	35000	2006	Stationvagon	Manuel	Mavi	Hayır	210000	Benzin + LPG	5
31077	Volvo	V60	1.6 D Drive Premium Powershift	86000	2012	Stationvagon	Manuel	Titanyum grisi	Hayır	50000	Dizel	5
31078	Volvo	V60	1.6 DRIVe	88000	2012	Sedan	Manuel	Siyah	Hayır	90000	Dizel	4
31079	Volvo	V70	2.4 D [D5] Premium Edition Geartronic	77000	2009	Stationvagon	Tiptronik	Füme	Hayır	154000	Dizel	5

31080	Volvo	V70	2.4 D [D5] AWD Geartronic	105000	2010	Stationvagon	Tiptronik	Gri	Hayır	230000	Dizel	5
31081	Volvo	XC 60	2.0 D3 163 HP Otomatik Vites	135000	2012	SUV	Otomatik	Siyah	Hayır	98000	Dizel	5
31082	Volvo	XC 60	2.0 D4 Premium Geartronic	178000	2014	SUV	Tiptronik	Gri	Hayır	19000	Dizel	5
31083	Volvo	XC 60	2.0 D3 163 HP R-design Otomatik Vites	115000	2012	SUV	Otomatik	Siyah	Hayır	80	Dizel	5
31084	Volvo	XC 60	2.0 D3 163 HP R-design Otomatik Vites	162000	2013	SUV	Otomatik	Beyaz	Hayır	26000	Dizel	5
31085	Volvo	XC 60	2.0 D4 Volvo Ocean Race Geartronic	161000	2015	Stationvagon	Tiptronik	Kahverengi	Evet	14500	Dizel	5
31086	Volvo	XC 60	2.0 D4 Premium Geartronic	135000	2013	Stationvagon	Tiptronik	Beyaz	Hayır	78000	Dizel	5
31087	Volvo	XC 60	2.0 D4 Advance Geartronic	250000	2015	SUV	Otomatik	Beyaz	Evet	10	Dizel	5
31088	Volvo	XC 60	2.4 D5 215 HP AWD Otomatik Vites	180000	2011	SUV	Otomatik	Siyah	Hayır	120000	Dizel	5
31089	Volvo	XC 60	2.0 D3 163 HP Otomatik Vites	137500	2012	SUV	Otomatik	Gri	Hayır	72600	Dizel	5
31090	Volvo	XC 60	2.4 D AWD Geartronic	145000	2010	SUV	S-Tronik	Siyah	Hayır	75000	Dizel	5
31091	Volvo	XC 60	2.4 D AWD Geartronic	135000	2010	SUV	S-Tronik	Kahverengi	Evet	48000	Dizel	5
31092	Volvo	XC 60	2.4 D AWD Geartronic	122000	2010	SUV	Otomatik	Siyah	Hayır	136500	Dizel	5
31093	Volvo	XC 60	2.0 D3 163 HP Otomatik Vites	145000	2012	SUV	Otomatik	Bej	Hayır	40000	Dizel	5
31094	Volvo	XC 90	2.4 D D5 AWD (7 Koltuk) Adventure Edition	72500	2006	SUV	Tiptronik	Siyah	Hayır	240000	Dizel	5
31095	Volvo	XC 90	2.4 D5 200 HP AWD 7 Koltuk R-design Otomatik Vites	155000	2011	SUV	Tiptronik	Beyaz	Hayır	73500	Dizel	5
31096	Volvo	XC 90	2.9 T6 Aut.	52500	2003	SUV	Tiptronik	Siyah	Hayır	113650	Benzin	5
31097	Volvo	XC 90	2.4 D AWD (5 Koltuk) Geartronic	80000	2008	SUV	Tiptronik	Siyah	Hayır	136000	Dizel	5

Veri setinin tamamına erişmek için: <https://goo.gl/8iaa11>

ÖZGEÇMİŞ

SAİT UĞUR GÜLTEKİN

KİŞİSEL BİLGİLER

- Uyuşu: Türkiye Cumhuriyeti
- Doğum Yeri: Tunceli
- Doğum Tarihi: 31.05.1987
- Medeni Durumu: Bekar
- Askerlik Durumu: Muaf
- E-posta: ugurgultekin@munzur.edu.tr
- Adres: Munzur Üniversitesi İ.İ.B.F. İşletme Bölümü

ÖĞRENİM DURUMU

- 2013-Halen: Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Sayısal Yöntemler Anabilim Dalı Tezli Yüksek Lisans Programı
- 2008-2011: Anadolu Üniversitesi İşletme
- 2006-2008: Dicle Üniversitesi Muhasebe
- 2001-2005: Tunceli Anadolu Lisesi

YABANCI DİL VE DÜZEYİ

- İngilizce / İyi (KPDS 81,25)