

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

DERİN ÖĞRENME TABANLI KONUT DEĞERLEME

Mehmet Fatih TOPRAK

GAYRİMENKUL GELİŞTİRME VE YÖNETİMİ ANABİLİM DALI

ANKARA
2023

Her hakkı saklıdır

ÖZET

Doktora Tezi

DERİN ÖĞRENME TABANLI KONUT DEĞERLEME

Mehmet Fatih TOPRAK

Ankara Üniversitesi

Fen Bilimleri Enstitüsü

Gayrimenkul Geliştirme ve Yönetimi Anabilim Dalı

Danışman: Prof. Dr. Oğuz GÜNGÖR

İnsanların barınma amacıyla, hayatları boyunca hacim bakımından yaptıkları en önemli yatırım genel olarak konut satın alma üzerine olmuştur. Konut değerinin belirlenmesi bir problem olarak ortaya çıkmış ve bu amaçla çeşitli değerlendirme yöntemleri kullanılmıştır. Lisanslı Değerleme Uzmanları Kraliyet Kurumu (RICS), Yapay Sinir Ağları (YSA) yaklaşımı otomatik değerlendirme metodları arasında kullanılmaktadır.

Bu çalışma kapsamında, Kayseri ilinin merkezindeki üç ilçede çok katlı binalarda yer alan konutların satış verileri toplanmıştır. Konutun bulunduğu binaya ait özellikler, konutun iç özellikleri ve konum bilgileri gibi üç kategoriden oluşan öznitelikler belirlenmiştir. Toplam 45 değişken içeren 1365 konut verisi eğitim, doğrulama ve test verisi olarak ayrılmıştır.

Python yazılım dilinde, keras kütüphanesi kullanılarak 144 farklı DÖ mimarisi geliştirilmiştir. Bu mimarilerin başarıları, R-kare (r^2), Ortalama Mutlak Hata (OMH), Ortalama Kareli Hata (OKH), Ortalama Mutlak Yüzde Hatası (OMYH), Ortalama Kare Hata Karekökü (OKHK) ve hataların standart sapması hesaplanarak karşılaştırılmıştır. Ayrıca Çoklu Doğrusal Regresyon (ÇDR) ve Coğrafi Ağırlıklı Regresyon (CAR) yöntemleri de kullanılarak konut değerleri tahmin edilmiştir. Elde edilen bulgulara göre; DÖ yöntemi OMYH ölçütü bakımından 0,057 değeri ile, ÇDR yönteminden %9,1 ve CAR yönteminden ise %7,3 oranında daha iyi sonuç vermiştir.

Sonuç olarak, kentsel dönüşüm, toplu konut projeleri, yeni imara açılan bölgelerdeki konutlar, emlak vergi değerinin belirlenmesi, özniteliğe dayalı değer haritalarının oluşturulması, değer artış payı hesabını gerektiren imar planı tadilatları gibi toplu ve hızlı bir şekilde konut değerlemesinin yapılmasının gerekli olduğu durumlarda, Kayseri ilinde 3 ilçe merkezindeki çalışma sınırlarında kullanılabilecek başarılı bir DÖ mimarisi geliştirilmiştir.

Aralık 2023, 141 sayfa

Anahtar Kelimeler: Derin Öğrenme, Konut Değerleme, Toplu Değerleme

ABSTRACT

PhD Thesis

DEEP LEARNING BASED HOUSING VALUATION

Mehmet Fatih TOPRAK

Ankara University
Graduate School of Natural and Applied Sciences
Department of Real Estate Development and Management

Supervisor: Prof. Dr. Oğuz GÜNGÖR

The most significant investment that people make in terms of volume for housing purposes throughout their lives has generally been buying a house. Determining the value of a house has emerged as a problem, and various valuation methods have been used for this purpose. Artificial Neural Networks (ANN) approach is one of the automatic valuation methods used by Royal Institution of Chartered Surveyors (RICS).

In this study, sales data of residential properties located in multi-story buildings in three districts in the center of Kayseri province were collected. Attributes (variables) belonging to the building where the house is located, the internal features of the house, and the spatial characteristics of the building's location were determined as three categories. A total of 1365 housing data consisting of 45 variables were divided into training, validation, and test data.

In the Python programming language, 144 different DÖ architectures have been developed using the Keras library. The successes of these architectures were compared by calculating the R-squared (r^2) value, Mean Absolute Error (MAE), Mean Squared Error (MSE), Mean Absolute Percentage Error (MAPE), Root Mean Squared Error (RMSE) and the standard deviation of errors. In addition, Multiple Linear Regression (MLR) and Geographically Weighted Regression (GWR) methods were used to predict housing values. According to the findings, the DÖ method yielded better results in terms of the MAPE criterion with a value of 0.057, outperforming the MLR method by 9.1% and the GWR method by 7.3%.

Consequently, in cases where it is necessary to carry out mass and rapid housing valuation, such as urban transformation, mass housing projects, housing in newly opened areas, determination of property tax value, creation of attribute-based value maps, and zoning plan amendments requiring the calculation of increment value share, a successful real estate valuation architecture has been developed within the working boundaries of 3 districts in Kayseri province.

December 2023, 141 pages

Key Words: Deep Learning, Housing Valuation, Mass Appraisal

TEŞEKKÜR

Bu tez çalışmasına her yönüyle paha biçilemez katkıları olan danışmanım Prof. Dr. Oğuz GÜNGÖR'e, uzmanlıkları ile çok önemli katkılar sunan tez izleme komitesi üyeleri Doç. Dr. Yeşim TANRIVERMİŞ ve Doç. Dr. Furkan BAŞER'e, bilgi ve tecrübeye dayalı rehberlikleri ile her zaman yanımda olan tez savunma jürisi üyeleri Prof. Dr. Mustafa TÜRKER ve Prof. Dr. Cevdet Coşkun AYDIN Hocalarıma sonsuz teşekkürlerimi sunarım.

Mehmet Fatih TOPRAK
Ankara, Aralık 2023

İÇİNDEKİLER

TEZ ONAYI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iv
SİMGELER VE KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
1.1 Çalışmanın Amaç, Kapsam ve Yöntemi	3
1.2 Literatürde Yapay Sinir Ağı Tabanlı Konut Değerleme.....	4
2. DEĞERLEME YÖNTEMLERİ.....	10
2.1 Geleneksel Gayrimenkul Değerleme Yöntemleri.....	12
2.1.1 Karşılaştırmalı satış analizi yöntemi	12
2.1.2 Maliyet yöntemi.....	14
2.1.3 Gelir indirgeme yöntemi.....	15
2.2 İstatistiksel Gayrimenkul Değerleme Yöntemleri.....	15
2.2.1 Nominal değerleme yöntemi.....	15
2.2.2 Çoklu regresyon analizi	16
2.2.3 Coğrafi ağırlıklı regresyon analizi.....	17
2.2.4 Hedonik değerleme yöntemi.....	17
2.3 Modern Değerleme Yöntemleri	18
2.3.1 Yapay sinir ağları yöntemi	19
2.3.2 Bulanık mantık yöntemi	20
3. DERİN ÖĞRENME.....	22
3.1 Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Kavramlarının Ayrımı...25	
3.2 Derin Öğrenme Kavramları.....	30
3.2.1 Nöron.....	30
3.2.2 Ağırlıklar.....	31
3.2.3 Sapma	31
3.2.4 Aktivasyon fonksiyonu	32

3.2.5 Katmanlar	34
3.2.6 Çok katmanlı algılayıcı	35
3.2.7 Kayıp fonksiyonu	35
3.2.8 Eğimli iniş	36
3.2.9 Öğrenme oranı.....	37
3.2.10 İleri ve geri yayılım	39
3.2.11 Yığınlar	40
3.2.12 Epok sayıları.....	41
3.2.13 Bırakma.....	41
3.2.14 Yığın normalizasyonu	42
3.2.15 Evrişimli (Konvolüsyonel) sinir ağları	43
3.2.16 Havuzlama	43
3.2.17 Dolgu	44
3.2.18 Veri çoğaltma.....	44
3.2.19 Yinelemeli sinir ağları.....	44
3.2.20 Kaybolan eğim problemi	45
3.2.21 Patlayan eğim problemi.....	45
3.2.22 Derin öğrenme kütüphaneleri.....	46
3.2.23 Derin öğrenme algoritmaları	46
3.2.24 Karar ağaçları, rastgele orman ve gradyan hızlandırma makineleri	46
3.2.25 Alan kayması	48
3.3 Derin Öğrenme Modeli Geliştirmenin Aşamaları.....	49
3.3.1 Veri toplama	50
3.3.2 Veriyi hazırlama.....	50
3.3.3 Model oluşturma	52
3.3.4 Modeli eğitme	52
3.3.5 Modeli doğrulama	54
3.3.6 Modeli test etme.....	56
4. DERİN ÖĞRENME İLE KONUT DEĞERİ TESPİTİ.....	57
4.1 Örneklem Alanı	57
4.2 Kullanılan Veri Seti	60
4.3 Kullanılan Değişkenler	64
4.4 Uygulama ve Sonuçları.....	69
4.4.1 Verinin ön işlenmesi.....	69

4.4.2 Değere etki eden numerik değişkenler	75
4.4.3 Değişken sayısının azaltılması.....	76
4.4.4 Verinin bölünmesi	78
4.4.5 Verinin doğrulanması	80
4.4.6 Değer tahmini	82
4.5 Derin Öğrenme ile Değer Tahmin Sonuçlarının Değerlendirilmesi.....	93
4.6 Diğer MÖ Yöntemleriyle Değer Tahmini	96
4.6.1 ÇDR yöntemi ile konut değerlendirme.....	96
4.6.2 CAR yöntemi ile konut değerlendirme.....	98
4.6.3 ÇDR ve CAR yöntemleri ile konut değerlendirme sonuçları.....	100
4.7 DÖ ile Diğer MÖ Uygulama Sonuçlarının Karşılaştırılması	101
5. SONUÇ VE DEĞERLENDİRME	106
KAYNAKLAR	111
EKLER.....	116
ÖZGEÇMİŞ.....	141

SİMGELER VE KISALTMALAR DİZİNİ

r^2 R-kare değeri (Belirleme katsayısı)

Kısaltmalar

ABD	Amerika Birleşik Devletleri
AVM	Alışveriş Merkezi
CAR	Coğrafi Ağırlıklı Regresyon (Geographic Weighted Regression)
CBS	Coğrafi Bilgi Sistemleri (Geographic Information Systems)
ÇDR	Çoklu Doğrusal Regresyon (Multiple Linear Regression)
ÇKA	Çok Katmanlı Algılayıcı (Multi-Layer Perceptron)
DÖ	Derin Öğrenme (Deep Learning)
DVM	Destek Vektör Makineleri (Support Vektor Machines)
ESA	Evrişimli Sinir Ağları (Convolutional Neural Network)
GDE	Geriye Doğru Eleme (Recursive Feature Elimination)
GÖ	Gösterim Öğrenme (Representation Learning)
RICS	Lisanslı Değerleme Uzmanları Kraliyet Kurumu (Royal Institution of Chartered Surveyors)
MİB	Merkezi İşlem Birimi (Central Process Unit)
MÖ	Makine Öğrenmesi (Machine Learning)
OH	Ortalama Hata (Mean Error)
OMH	Ortalama Mutlak Hata (Mean Absolute Error)
OMYH	Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
OKH	Ortalama Kare Hata (Mean Square Error)
OKHK	Ortalama Kare Hata Karekökü (Root Mean Square Error)
TSA	Tekrarlayan Sinir Ağları (Recurrent Neural Network)
IAAO	Uluslararası Değerleme Çalışanları Birliği (International Association of Assessing Officers)
UKDB	Uzun Kısa Dönem Bellek (Long Short Term Memory)
ÜÖED	Üretken Önceden Eğitilmiş Dönüştürücü (Generative Pre-trained Transformer)
YSA	Yapay Sinir Ağı (Artificial Neural Network)
YiSA	Yinelemeli Sinir Ağları (Recurrent Neural Networks)
YZ	Yapay Zekâ (Artificial Intelligence)

ŞEKİLLER DİZİNİ

Şekil 2.1 Klasik ve bulanık küme farkı.....	21
Şekil 3.1 Biyolojik sinir hücresi.....	23
Şekil 3.2 Nöron	24
Şekil 3.3 YZ, MÖ ve DÖ gelişiminde kronolojik sıralama	27
Şekil 3.4 DÖ, GÖ, MÖ ve YZ kavramlarının ven şemasında gösterimi	28
Şekil 3.5 Nöron	31
Şekil 3.6 Bir nöronda girdi, ağırlıklar, net fonksiyonu, aktivasyon fonksiyonu ve çıktı.32	
Şekil 3.7 Relu aktivasyon fonksiyonu grafiği	33
Şekil 3.8 Sigmoid aktivasyon fonksiyonu grafiği	33
Şekil 3.9 Softmax fonksiyonu kullanarak rakam tanıma örneği	34
Şekil 3.10 Basit YSA ve DÖ sinir ağı.....	35
Şekil 3.11 Eğimli iniş.....	37
Şekil 3.12 Öğrenme oranı seviyeleri.....	38
Şekil 3.13 Öğrenme Oranı ve Gradyan İniş	38
Şekil 3.14 İleri Yayılım (Forward Propagation)	39
Şekil 3.15 Geri Yayılım (Back Propagation)	40
Şekil 3.16 Bırakma uygulanmadan önce ve sonra sinir ağının yapısı	42
Şekil 3.17 Karar ağacı yönteminin çalışma prensibi.....	47
Şekil 3.18 Algılayıcı	53
Şekil 4.1 Çalışma alanının konumu ve sınırları	58
Şekil 4.2 Konutların konumsal gösterimi ve çalışma alan sınırı.....	59
Şekil 4.3 Değer normal dağılım histogramı	59
Şekil 4.4 Konutların değer ısı haritası.....	60
Şekil 4.5 Verinin ay ve yıllara göre toplanma miktarı ve oranları.....	63
Şekil 4.6 Örnek bir kaydın kukla değişkene dönüştürülmüş halinin sorgu ekranındaki görünümü	74
Şekil 4.7 Numerik değişkenlerin konut değerine etkisinin korelasyon ısı haritasında gösterimi.....	75
Şekil 4.8 Verinin eğitim, doğrulama ve test olarak bölünmesi	78
Şekil 4.9 Çalışma alanındaki bölgeler.....	79
Şekil 4.10 Bölgelerdeki verilerin bölünmüş gösterimi	80

Şekil 4.11 Eğitim verisinin eğitim kısmının gerçek ve tahmin edilen değerlerinin frekansı.....	81
Şekil 4.12 Eğitim verisinin doğrulama kısmının tahminleri	81
Şekil 4.13 Konut değerlendirme DÖ mimarisi	84
Şekil 4.14 DÖ model parametreleri ve farklı kombinasyonları	84
Şekil 4.15 Eğitim verisinin kayıp fonksiyonu grafiği	92
Şekil 4.16 18 numaralı DÖ modelinin değer-tahmin dağılım grafiği	93
Şekil 4.17 ÇDR yöntemi kullanılarak eğitim verisi kullanılarak değer tahmini dağılım grafiği.....	97
Şekil 4.18 ÇDR yöntemi kullanılarak test verisi ile değer tahmini dağılım grafiği.....	98
Şekil 4.19 CAR yöntemi kullanılarak eğitim verisi ile değer tahmini dağılım grafiği ...	99
Şekil 4.20 CAR yöntemi kullanılarak test verisi ile değer tahmini dağılım grafiği.....	100
Şekil 4.21 DÖ, ÇDR ve CAR yöntemlerinin r^2 karşılaştırması	102
Şekil 4.22 DÖ, ÇDR ve CAR yöntemlerinin OMYH karşılaştırması	103
Şekil 4.23 DÖ, ÇDR ve CAR yöntemlerinin OMH karşılaştırması	103
Şekil 4.24 DÖ, ÇDR ve CAR yöntemlerinin OKH karşılaştırması	104
Şekil 4.25 DÖ, ÇDR ve CAR yöntemlerinin OKHK karşılaştırması	104
Şekil 4.26 DÖ, ÇDR ve CAR yöntemlerinin hataların standart sapma karşılaştırması	105

ÇİZELGELER DİZİNİ

Çizelge 4.1 Verinin toplandığı aylara ait konut fiyat endeksleri	64
Çizelge 4.2 Değişken listesi	65
Çizelge 4.3 Kategorik veri yapısı.....	70
Çizelge 4.4 Kukla değişkenli veri yapısı.....	70
Çizelge 4.5 Kukla değişkenler	71
Çizelge 4.6 GDE yöntemi ile belirlenen değişkenler	77
Çizelge 4.7 Kayseri için 144 farklı parametre kombinasyonu ile elde edilen mimarilere ait sonuçlar	86
Çizelge 4.8 Kayseri için belirlenen en iyi 4 DÖ mimarisinin sonuçları	94
Çizelge 4.9 Kayseri için belirlenen en iyi 4 DÖ mimarisinin parametreleri.....	95
Çizelge 4.10 DÖ ile ÇDR ve CAR sonuçlarının karşılaştırılması	101

1. GİRİŞ

Bir varlığın veya malın adil piyasa koşullarında değerinin belirlenmesi işine değerlendirme denilmektedir. Konut, işyeri, arsa, arazi, gibi gayrimenkullerin piyasa değerinin belirlenmesi işine ise gayrimenkul değerlendirme denilir. İnsanların hayatları boyunca yaptıkları en önemli yatırım genellikle konut olduğu gerçeğinden yola çıkıldığında, konut değerinin en doğru şekilde belirlenmesi önem ifade etmektedir.

Değerleme farklı yöntemler kullanılarak yapılabilmektedir. Değerleme yönteminin seçimi değerlemenin amacına bağlı olarak değişmektedir. Değerleme satış, ipotek teminatı, kamulaştırma, kiralama gibi amaçlar için olabilmektedir. Değerlemenin amacına uygun doğru yöntemlerle yapılması, değerlemeyi gerektiren iş ve işlemlere olumlu katkı sağlamaktadır.

Konutun alım-satım işlemine konu olması halinde piyasa değerinin belirlenmesi gerekir. Konutun piyasa değeri birçok etkene bağlıdır. Konutun yer aldığı binanın özellikleri, konutun iç özellikleri ve binanın konumsal özellikleri konutun değerini etkilediği gibi konutun büyüklüğü, oda sayısı, banyo sayısı, konutun içinin durumu, manzara, sıcak su gibi faktörler de değerini etkilemektedir. Ayrıca, binanın yaşı, kapalı ve açık otopark durumu, imar planlarındaki fonksiyonu, yapı kalitesi, sığınak gibi yapısal özellikler de konutun değerini belirleyebilir. Bunlara ek olarak; kentsel donatılara uzaklık, şehir merkezine uzaklık, mahalle, ilçe, bölge, ulaşım gibi çevresel olanakların da konutun değerini etkileyen faktörler arasında sayılabileceği, konut piyasasındaki arz talep dengesinin, konut kredisine erişebilme ve ekonomik göstergelerin de konutun değerini etkileyebileceği göz ardı edilmemelidir. Konuta ilişkin özellikler şehrin farklı bölgelerinde farklı ağırlık oranları ile konutun değerine etki edebilmektedir.

Konutların değerlemesi, değerlendirme uzmanı tarafından daha çok karşılaştırmalı satış analizi yöntemi ile tek tek yapılmaktadır. Karşılaştırmalı satış analizi yöntemi, değerlendirme yapılacak olan konutun özelliklerini en çok taşıyan, en yakın konumda gerçekleşen satışların emsal alınması esasına dayanır. Emsal alınan konutların, değerlendirme yapılacak olan konut ile aralarındaki eksik veya fazla olan özelliklerin

maliyet ve piyasa değeri farklılıklarının, değerlemesi yapılacak olan konuta yansıtılması ile konutun piyasa değeri belirlenmiş olur.

Konutların tek tek değerlemesi yapılabileceği gibi toplu olarak da değerlemesi yapılabilir. Toplu değerlendirme işlemleri için otomatik değerlendirme yöntemlerinden faydalanılır. Özellikleri ve değeri bilinen çok sayıdaki konuta ait bilgilerin işleme alınması ile özellikleri bilinen ancak değeri bilinmeyen çok sayıdaki konutun değeri doğru bir modelleme ile tek seferde tespit edilebilmektedir. Matematiksel ve istatistiksel yöntemlerle yapılacak bir toplu değerlendirme işleminde doğru bir model oluşturulması önemlidir. Matematiksel ve istatistiksel bir modelin herhangi bir şehirde istenen sonuçları verebiliyor olması, farklı şehirlerde de beklenen doğru sonuçları verebileceği anlamına gelmemektedir. O nedenle her şehir ve bölge için ayrı ayrı otomatik değerlendirme modeli geliştirilmesi gerekmektedir. Çünkü her şehir için oluşturulacak veri seti aynı öznelik bilgilerine sahip olmayabilir. Ayrıca insanların edinmek istedikleri konutta olmasını istedikleri özelliklerin neler olduğu şehirden şehre farklılık gösterebilir. Bu nedenle insanların konutun hangi özellikleri için daha fazla para ödemeye razı oldukları, hangi özellikleri için ise daha fazla para ödemekten kaçındıkları her şehirde farklı olmaktadır. Çoklu Doğrusal Regresyon (ÇDR), Coğrafi Ağırlıklı Regresyon (CAR), Bulanık mantık ve Yapay Sinir Ağı (YSA) yöntemleri literatürde en fazla tercih edilen toplu değerlendirme yöntemlerine örnek olarak gösterilebilir.

Konutların değerlemesinin otomatik değerlendirme yöntemlerinden birisi olan Derin Öğrenmeyle (DÖ) de yapılması mümkündür. DÖ bir YSA ürünüdür. Kullanılan verinin nitelikli olması ve model parametreleri çok iyi belirlenmiş bir DÖ mimarisi, oldukça başarılı sonuçlar verebilir. DÖ yöntemi değişkenlerden (öznelik bilgileri) yola çıkarak konutun değerini belirleyen faktörleri öğrenir ve bu faktörlerin değere olan etkilerini bir araya getirerek değer tahmini yapabilir.

Geliştirilen bir DÖ mimarisi ile değer tahminlerinin doğruluğunun belirlenmesinde bazı ölçütler kullanılır. Bu ölçütler r-kare (r^2) değeri, Ortalama Mutlak Hata (OMH), Ortalama Kareli Hata (OKH), Kök Ortalama Kare Hata (KÖKH), Ortalama Mutlak Yüzde Hata (OMYH) ve hataların standart sapmasıdır. Bu ölçütler geliştirilecek olan DÖ mimarisinin

performansını ölçmek için kullanılmakta ve daha doğru konut değer tahminlerinin yapılması için mimarinin geliştirilmesine yardımcı olmaktadır.

1.1 Çalışmanın Amaç, Kapsam ve Yöntemi

Bu çalışma ile Kayseri’de çok katlı binada yer alan konutların piyasa değerlerinin toplu değerlendirme yöntemlerinden DÖ ile yapılabilmesine olanak sağlayacak mimarinin belirlenmesi ve ayrıca DÖ’nün diğer toplu değerlendirme yöntemlerinden olan ÇDR ve CAR yöntemleri ile kıyaslanması da amaçlanmıştır.

DÖ modelinin geliştirilebilmesi için ihtiyaç duyulan çok sayıdaki verinin, Kayseri şehir merkezinde belirli bir zaman diliminde toplanması, veri tabanına kaydedilmesi, DÖ yazılımı gereksinimleri doğrultusunda şekillendirilmesi ve DÖ mimarisinin geliştirilmesi çalışma kapsamını oluşturmaktadır.

DÖ ile yapılan değerlendirme çalışmasının başarı ölçütleri bakımından nasıl sonuç verdiğinin analiz edilmesinin yanı sıra, diğer Makine Öğrenme (MÖ) yöntemlerinden olan ÇDR ve CAR yöntemleri ile de karşılaştırılması, DÖ’nün performansını daha doğru bir şekilde ortaya koymaya olanak sağlayacaktır. ÇDR bağımsız değişkenlerden yola çıkarak değer bağımsız değişkenini açıklayacak bir fonksiyona dayanır. CAR’da ise ÇDR’den farklı olarak verilerin her birinin yer yüzündeki konumunu da baz alarak değer bağımsız değişkenini açıklamaya çalışır. Bağımsız değişkenlere ek olarak konum bilgisinin de değişken olarak eklenmesiyle, değer bağımlı değişkenini CAR’ın ÇDR’den daha iyi açıklayıp açıklamadığı da bu çalışma kapsamında bulunmaktadır.

Bu çalışma kapsamında DÖ modeli geliştirmek için kullanılan eğitim ve test verilerinin aynısı ÇDR ve CAR modellerinin geliştirilmesi için de kullanılmıştır. ÇDR ve CAR yöntemleri ile DÖ başarı bakımından kıyaslandıktan sonra Kayseri için geliştirilen DÖ yönteminin başka şehirlerde de kullanılabilir olup olmadığı gündeme gelmektedir. Kayseri’de eğitilen modelin başka şehirlerde de olumlu sonuç vermesi beklenemez. Her şehir için ayrı bir çalışma yapılması, o şehir için eğitim verileri ile oluşturulan model ile

ancak o şehre ilişkin test sonuçları anlamlı olacaktır. Bir başka deyişle, bir YSA'nın eğitim görmediği bir konuda teste tabi tutulması beklenemez.

Konutların özelliklerini içeren değişkenlerden oluşan verinin toplanması ve belirlenen ölçütler ışığında en iyi performans gösteren değer tahmin mimarisinin geliştirilmesi aşamalarından sonra, konutların değer haritalarının üretilmesi de gündeme gelmektedir. Değer haritaları, belirlenen bir bölgede, ilçe, mahalle, semt, cadde veya sokak ölçeğinde, konutların özelliklerinin ve değer aralıklarının görüntülenmesine imkân verecek unsurları içermektedir. Ayrıca, Coğrafi Bilgi Sistemi (CBS) teknikleri ile üretilen değer haritalarının konumsal bir nitelik taşıdığı da unutulmamalıdır. Bir gayrimenkulün konuma dayalı bir varlık olduğu göz önünde bulundurulduğunda değer haritaları, farklı bölgelerdeki konutların özelliklerinin ve değerlerinin karşılaştırılmasına olanak sağlayarak, konut almak-satmak isteyenlerin doğru karar vermelerine yardımcı olacak bilgi ve analizler sunmaktadır. Değer haritaları sayesinde konumsal analizler, taşınmazlar ile ilgili sorgulamalar, uygun yer analizi, bölgelere ait birim fiyatların tespiti, yatırım yapılacak bölgelerin seçilmesi ve vergi değerlerinin belirlenmesi gibi işlemler de gerçekleştirilebilmektedir.

Bu çalışmada, Kayseri ilinin Kocasinan, Melikgazi ve Talas ilçelerinin konut yoğunluğunun fazla olduğu merkezlerinde, çok katlı herhangi bir binada yer alan konut türündeki gayrimenkullerin piyasa değerinin tahmin edilmesi için DÖ mimarisi geliştirilmiştir. Buna ek olarak, aynı veri seti ile ÇDR ve CAR gibi başka MÖ yöntemler de kullanılarak değer tahminleri yapılmış, DÖ mimarisi sonuçları ile karşılaştırılmıştır.

1.2 Literatürde Yapay Sinir Ağı Tabanlı Konut Değerleme

Konut değerlendirme çalışmalarında kullanılan yöntemlerin arasında YSA da yerini daha net bir şekilde almaya başlamış ve pratiğe dönük uygulamaların geliştirilmesi bir ihtiyaç olarak ortaya çıkmıştır. Literatürdeki çalışmaların DÖ, MÖ veya Yapay Zekâ (YZ) yöntemi ile yapılmış olması YSA metodunun kullanıldığını gösterir. Yani DÖ, MÖ ve YZ çalışmalarının hepsi birer YSA ürünüdür.

Konut değerin tahmini için YSA'nın kullanılması ile ilgili dünyada ve Türkiye'de yapılmış çalışmalar bulunmaktadır. Borst (1991), Do ve Grudnitski (1992), Worzala, Lenk ve Silva (1995), Rossini (1997) ve Yılmazel (2018) konut değereleme çalışmalarında YSA yöntemi kullanmış ve bazı sonuçlara ulaşmışlardır. Konut değerelemlerinin tahmin edilmesi konusundaki ilk bilinen çalışma 1991 yılında Borst tarafından yapılmış ve bunu 1992'de Do ve Grudnitski'nin yaptığı çalışma takip etmiştir. Do ve Grudnitski (1992), bir konutun değerin tahmin etmede, YSA modelinin çoklu regresyon modelinden daha iyi sonuç verdiği sonucuna varmıştır. YSA kullanarak Türkiye'de yapılan konut değereleme çalışmalarının örneklerinden biri de Yılmazel (2018) tarafından Eskişehir örnekleminde yapılan araştırmadır. Bu çalışmada Yılmazel (2018) geliştirdiği YSA modellerinde gizli katmandaki nöron sayılarını farklılaştırarak en uygun modeli elde etmeye çalışmıştır. Bu amaçla 19 adet model geliştirilmiş ve hangi modelin daha iyi metriklerle sahip olduğu tartışılmıştır. Konutlara ait 12 adet öznitelik bilgisi kullanılarak YSA modelleri oluşturulmuştur (Yılmazel vd. 2018). Yılmazel vd. (2018) OKHK ve OMH değerelemlerinde en düşük ve en yüksek korelasyon katsayısı değerin sağlayan modelin 5 adet nörondan oluştuğunu tespit etmiştir. Modelin girdi ve çıktı değerekenleri arasındaki ilişkiyi en iyi şekilde açıklayan bu modelde $R = 0,9219$, OKHK = 0,192 ve OMH = 0,1441 olarak hesaplanmıştır (Yılmazel vd. 2018). Selim (2016) YSA'yı regresyon yaklaşımının esnek bir türü olarak tanımlamış ve bu nedenle YSA'nın konut fiyat tahminleri için daha esnek bir yöntem olduğu görüşünü ortaya atmıştır.

Ayrıca, Türel (1976) konutun konumunun değereine etki eden faktörlerden biri olduğunu ifade etmiştir. Marin ve Altıntaş (2004) konut-işyeri arasındaki mesafenin ve ulaşım imkânlarının konut yeri seçiminde etkili olduğunu belirtmişlerdir. Ayrıca Ekşioğlu ve Çubukçu (2011) konutun bulunduğu yerin sahip olduğu estetik unsurların bile konutun satın alınması veya kiralanması isteğini etkilemekte olduğunu, değereine de tesir ettiğini söylemiştir.

Aydemir vd. (2020), yaptıkları çalışmada internet ilanlarından otomatik veri toplayan bir sistem geliştirmişlerdir. Bu yöntemle internet üzerinden İstanbul'un Ataşehir ilçesinde yer alan 852 adet satılık konuta ilişkin 176 öznitelik verisi toplamışlardır. 14 farklı algoritma ile konut fiyatı tahmini gerçekleştirmişlerdir. Bu çalışmada konut fiyatları 142.500 TL ile

1.000.000 TL arasında deęişiklik göstermektedir. Elde edilen verilere bakıldığında ortalama fiyatın 472.196 TL, fiyatlardaki standart sapmanın 187702 TL olduęu, ayrıca konutların brüt alanının 37 metrekare ile 300 metrekare arasında deęişiklik gösterdiği, toplam 16 mahalleye ait konut fiyatlarının 300.000 TL ile 600.000 TL arasında yoğunlaştığı görülmüştür. Konutlar 2+1 ve 3+1 dairelerden oluşmakta ve bina yaşı 0 ile 10 yıl arasında deęişmektedir. Örneklem kümesinde yer alan dairelerin büyük bir çoęunluğu kombi ile ısınırken, kalanları merkezi sistemle ısıtılmaktadır. Bu çalışmada konut fiyatlarının tahmini Weka programı ile yapılmıştır. Elde edilen sonuçlar içerisinde en başarılı sonucu rastgele orman algoritması vermiştir. Aydemir vd. (2020) elde ettikleri tahmin edilen fiyat ile gerçek fiyat arasında korelasyon kat sayısını 0,86 olarak bulmuşlardır. OMH 80.207,46 ve OKHK ise 105.105,38 olarak bulunmuştur. Kullanılan dięer alternatif yöntemler ise daha kötü sonuç vermiştir.

YSA yönteminin beklendięi gibi daha iyi sonuç vermedięi bir çalışma da bulunmaktadır. Rossini (1997), 334 adet konut verisi kullanmış ve veriyi 223 adedi eğitim, 111 adedi ise test verisi olacak şekilde ayırmıştır. Çoklu regresyon analizi %90 ortalama uyum verirken %89 oranında doğruluk sonucunu ortaya çıkarmıştır. YSA yöntemi ise ortalama uyum için %78 oranını verirken, doğruluk için %81 oranını vermiştir.

İlhan ve Öz (2020) bir literatür taraması yaparak gayrimenkul deęerlemede regresyon ve sinir aęları çalışmalarının listesini çıkartmıştır. Buna göre regresyon ve sinir aęları çalışmalarının birbirlerine üstünlük sağladığı durumların olduęu görülmektedir. Örneğin Rossini (1997) Avustralya'da konut fiyatları araştırmasına göre ölçüt olarak r^2 kullanmış ve regresyonun %90, sinir aęlarının ise %78 başarı gösterdiğini ortaya koymuştur. Buna karşın 200 örnek sayısı ile Limsombunchai vd. (2004) Yeni Zelanda'da yaptığı çalışmanın sonucunda regresyon analizinin %78, sinir aęlarının ise %95 başarı gösterdiğini bildirmiştir.

Güneş ve Yıldız (2015), Tapu ve Kadastro Genel Müdürlüğü için yaptıkları toplu deęerleme çalışmasında Mamak ve Fatih ilçelerini çalışmışlardır. Fatih ilçesinde 2.702 adet konut verisi kullanılmış olup, regresyonun başarısı %84, YSA'nın başarısı ise %89 çıkmıştır. Çalışma sonucunda YSA'nın daha iyi sonuç vermiş olmasına karşın, regresyon

yönteminin kullanılmaya devam edilmesine karar verilmiştir. Çünkü YSA ile çalışmak yüksek seviyede uzmanlık ve donanım gerektirmektedir. Regresyon modeli ise kurulması ve analiz sonuçlarının tartışılması hususunda daha basit bir yöntemdir.

Cechin vd. (2000) tarafından Brezilya'nın Porto Alegre kentindeki satılık ve kiralık bina verileri, doğrusal regresyon ve YSA yöntemleri kullanılarak analiz edilmiştir. Analizde toplam 7 değişken kullanılmıştır. Bu değişkenler, konutun iç özelliklerinin yanı sıra çevresel özelliklerini de içermektedir. Çalışmada, çoklu regresyon yönteminin YSA kadar iyi sonuç vermediği tespit edilmiştir. Çoklu regresyon yöntemi 33 dolar mutlak yaklaşık sonuç verirken, YSA yönteminde bu değer 11 dolar olduğu görülmüştür.

Madrid'de Gallego ve Esperanza (2004) tarafından yapılan bir çalışmada, YSA yönteminde 12 değişken kullanılmıştır. Bu çalışma, 100 adet konutun satış değerlerini gerçek değer olarak varsaymaktadır. Sonuç olarak, çalışmanın %95 ortalama uyum ve %86 doğruluk oranlarını verdiği görülmüştür.

Limsombunchai vd. (2004) tarafından Yeni Zelanda'nın Christchurch şehrinde konut fiyatlarını tahmin etmek için çoklu regresyon ve YSA yöntemleri kullanılmıştır. Konutun alanı, binanın yaşı, binanın tipi, konutun oda sayısı, konutun banyo sayısı, garaj, sosyal tesisler ve konutun konumu olacak şekilde 7 adet değişken kullanılmış ve çalışma %84 doğruluk oranına ulaşmıştır. Nghiep, Nguyen ve Crips Al (2001) ise doğru verilerin seçilmesi halinde YSA yönteminin daha başarılı sonuç verdiği sonucuna varmıştır. Özkan vd. (2007)'de benzer şekilde, Konya'nın Selçuklu ilçesinde çoklu regresyon ve YSA yöntemleri kullanarak değer tahmini yapmışlardır. Çalışmada 7 adet değişken kullanılmış ve 170 adet veri incelenmiştir. Çoklu regresyon yöntemi ile %83, YSA yöntemi ile %84,5 doğruluk oranına ulaşılmıştır.

Mimis, Rovolis ve Stamou (2013) tarafından Atina'da konut fiyat tahmini için YSA yöntemi kullanılmıştır. Bu çalışma, 2000 ve 2006 yılları arasındaki dönemi içeren, 3150 adet daireden oluşan bir veri seti ile yürütülmüştür. Verilerin CBS ortamında da gösterimi sağlanmış ve beş adet değişken kullanılarak model geliştirilmiştir. Verideki değişkenliğin

%76'sı CBS modeli ile, %87'si ise YSA modeli ile açıklanmıştır. Sonuçlar, 16.625 euro OMH ile tahmin edilebilmiştir.

Khalafallah (2008) çalışmasında, YSA yöntemi kullanarak gayrimenkul satışlarının analizini yapmıştır. Çalışmada kullanılan değişkenler; zaman, faiz oranı, satışların yıllara göre değişimi, bir önceki yıla göre satış birim değerinin değişimi, ortalama satış süresi ve işlem hacmidir. Sonuç olarak, YSA yöntemiyle satış değerine %2 tolerans oranıyla ulaşılmıştır.

Selim (2009), konut fiyatlarını tahmin etmek için YSA ve hedonik regresyon yöntemlerini kullanmıştır. Çalışma, 2004 hane halkı ile yapılan bir anket ile yürütülmüş ve konutun iç özellikleri ve binaya ilişkin özellikler dikkate alınmış ancak çevresel özellikler dikkate alınmamıştır. Sonuç olarak, YSA yönteminin hedonik regresyondan daha iyi sonuç verdiği bulgusuna ulaşılmıştır.

Zurada, Levitan ve Guan (2011), konut değerlendirme analizi için bulanık mantık ve YSA yöntemlerini kullanmışlardır. Çalışmada, banyo sayısı, ısıtma sistemi, şömine, alan, garaj ve inşaat tipi olmak üzere 7 adet değişken kullanılmıştır. Sonuç olarak, bu yöntemlerin kullanılabilmesi için yeterli sayıda veriye ve doğru analize ihtiyaç olduğu ortaya konulmuştur.

Ecer (2014) çalışmasında, İzmir'in Karşıyaka ilçesinde 2013 yılının Ocak ve Temmuz ayları arasında 610 adet konuta ait değişkenleri hedonik regresyon ve YSA yöntemleriyle karşılaştırmak için kullanmıştır. Çalışmada 83 adet değişken yer almaktadır ve YSA yönteminin hedonik modele göre daha iyi sonuçlar verdiği bulgusuna varılmıştır.

Abidoye ve Chan (2017) tarafından gerçekleştirilen çalışmada, Nijerya'da konut fiyat tahminleri YSA yöntemi kullanılarak yapılmıştır. 370 adet veri ve 11 bağımsız değişken kullanılarak yapılan araştırmada, YSA yönteminin konut değerlendirme alanında yapılan işlerin doğruluğunu artırabileceği sonucuna varılmıştır.

Yılmaz vd. (2018) tarafından gerçekleştirilen bir çalışmada, internet ilanlarından elde edilen veriler kullanılarak YSA ile bir model geliştirilmeye çalışılmıştır. Çalışmada, Ankara'nın Keçiören ilçesindeki 149 adet satılık konut ilanının 12 farklı öznitelik bilgisi veri setine dâhil edilmiştir. 20 farklı alternatif model belirlenmiş ve bu modellerin performansları karşılaştırılmıştır. Araştırma sonucunda veri sayısının artırılması önerilmektedir.

Fiyat tahmini konusunda YSA kullanımında farklı bir yaklaşım sergileyen bir çalışma da Yeni Zelanda'da yapılmıştır. Konut fiyatlarını tahmin etmek için yapılan bu çalışma Abraham (2016) tarafından gerçekleştirilmiştir. Çalışma kapsamında, 2000 ve 2015 yılları arasındaki konut fiyat endeksi verileri kullanılarak konut arzını ve talebini etkileyen değişkenler incelenmiştir. Sonuç olarak, YSA yöntemiyle Yeni Zelanda'daki konut fiyatlarını belirleyen unsurların tahmin edilebildiği ortaya çıkmıştır.

Konutların maliyeti de şüphesiz ki konutun değerine etki eden faktörler arasındadır. Konutun piyasa değerini tahmin etmenin yanı sıra, literatürde konutun maliyetini tespit etme konusunda da YSA çalışmaları bulunmaktadır. Bu yönde bir çalışmayı Erdem (1996), konutlar inşa edilmeden önce inşaat maliyetini hesaplamak için yapmıştır. Demirel (2007) de benzer bir çalışma yaparak toplu konut inşaat maliyetlerinin YSA ile nasıl yapılacağı üzerine bir model geliştirmiştir. 21 farklı yığma konut projesine ait veriler kullanılarak Uğur vd. (2011) tarafından da maliyet belirleme çalışması yapılmış ve sonuç olarak %5 hata oranına ulaşılmıştır.

Konuttan farklı bir gayrimenkul türü olan arsaların değerlemesine yönelik, YSA kullanılmış bir çalışma da bulunmaktadır. İlhan ve Öz (2020), yaptıkları çalışmada bir YSA modeli kullanarak Ankara ili Gölbaşı ilçesinde hazineye ait arsa vasıflı 2017 yılında satışı gerçekleştirilmiş taşınmazlar kullanmıştır. Bu çalışmada arsa birim fiyatlarının tahmin edilmesinde YSA kullanılmış ve sonuçların değerlendirilmesi için klasik istatistiki yöntemlerden ÇDR kullanılmıştır. Çalışmanın özü bu 2 yöntem ile elde edilen sonuçların karşılaştırılmasına dayanmaktadır. Arsa fiyatını etkileyen 13 farklı bağımsız değişken kullanılmıştır. Çalışma sonucunda YSA yönteminin ÇDR yönteminden daha başarılı olduğu sonucuna ulaşılmıştır.

2. DEĞERLEME YÖNTEMLERİ

Bir gayrimenkule ilişkin faydalar, nitelik, çevre koşulları ve gayrimenkulün kullanımına ilişkin faktörler değerlendirilerek, gayrimenkulün değeri belirlenir. Bu işlem, İngilizcedeki “Appraisal” veya “Valuation” kelimelerinin karşılığıdır. Kıymet takdiri, değer biçme, değer takdiri, değerleme ve ekspertiz gibi kavramlar taşınır ve taşınmazların değerlemesi işine denilmekte ve aynı anlamı ifade etmektedir. Değerleme; arazi, arsa, bina, diğer taşınmaz ve taşınır mallar ile hakların değerlerinin tam ve güvenilir olarak ve çeşitli amaçlar için takdiri ve raporlanmasıdır. Gayrimenkulün değerinin belirlenmesini gerekli kılan durumlar vardır. Kamu ve özel sektör ve bireylerin taşınmaz alım-satım bedellerinin tespiti, kamu ve özel sektör ve bireylerin her türlü taşınmaz kiralama işleri, bankalar, finans kurumları ve aracı kurumların (leasing & factoring şirketleri) kredi değerlemeleri değerlendirme yapılmasını gerektirir (Tanrıvermiş 2013).

Gayrimenkul değerlendirme çalışmalarında genel olarak Uluslararası Değerleme Standartlarında (UDS) 3 kategoride ele alınan geleneksel değerlendirme yöntemleri kullanılmaktadır. Bunlar; pazar, gelir ve maliyet yaklaşımlarıdır. Bununla birlikte Lisanslı Değerleme Uzmanları Kraliyet Kurumu (RICS) tarafından otomatik değerlendirme metodları arasında Yapay Sinir Ağları (YSA) yaklaşımı da bir değerlendirme standardı olarak yer almıştır (İlhan ve Öz, 2020).

Değerleme Yöntemlerini Tanrıvermiş (2013) şu şekilde sınıflandırmıştır:

- Pazar Değeri Yöntemleri
 - Karşılaştırmalı Satış Analizi Yöntemi
 - İkamé Fiyatı Yöntemi
 - Dönüşüm (Transformasyon) Fiyatı/Çıkartma Yöntemi
- Gelir (Hasıla/Gelirlerin Kapitalizasyonu) Yöntemleri
 - Artık Gelir Yaklaşımı
 - Kira Geliri Yaklaşımı
 - Brüt Gelir veya Kira Çarpanı Yaklaşımları
 - İndirgenmiş Nakit Akımları (bugünkü değer analizi)

- Tamamlayıcı Değer Yaklaşımı
- Maliyet Yöntemleri
 - Maliyet Fiyatı (Yeni inşa edilmiş olanlar)
 - Yeniden Üretim Maliyeti (Eski Yapılar)
- Kantitatif Değerleme Yöntemleri
 - Regresyon Modelleri (Hedonik Değerleme Eşitliği gibi)
 - Diğer Matematiksel Modeller ve Değer Haritalarının Üretilmesi

Tanrıvermiş (2013), amacına göre değerlendirme yönteminin kullanılması gerektiğini, bu bakımdan bazı ilkelerin dikkate alınması gerektiğini söylemiştir. Yani amacı bilinmeden bir malın değerini biçmek mümkün değildir. Ayrıca bir malın değeri her zaman aynı değildir. Bir malın değeri zamana, mevcut koşullara ve değerlemedeki amaca göre değişim göstermektedir. Değerleme çalışmalarında; piyasa değeri, bazen gelir değeri, kimi zaman da maliyet değeri veya tasfiye değeri dikkate alınırken, bazen de yatırım değeri önem taşımaktadır. Konut değerlemesi yapılırken, karşılaştırmaya dayalı yöntemler öncelikle kullanılması gereken, bir bakıma da zorunlu yöntemlerdir. Ayrıca konut değerlemesinde gelir yöntemlerinin kullanılması da doğru bir yaklaşımdır (Tanrıvermiş 2013). Bir gayrimenkulün değeri, o gayrimenkulün taşıdığı özelliklere bağlıdır. Taşınmazın konumu, fiziksel, ekonomik ve yasal nitelikleri yani taşınmazın tanımlanması, adresi, yasal tanıtımı, pafta, ada, parsel numarası gibi özelliklerinin yanı sıra, mülkiyet durumu ve hisseli ise, hisse özellikleri de değerinin belirlenmesinde etkilidir. Tanrıvermiş (2013) konutun değerini belirleyen kriterleri içsel ve dışsal olarak sınıflandırmıştır. İçsel faktörler arasında fayda, kıtlık, fiziki koşullar ve devredebilme yer alırken, dışsal faktörler arasında ekonomik, sosyal, kültürel faktörler, nüfus, hukuki düzenlemeler, doğal afetlere karşı korunma, çevre, güvenlik önlemleri, pazarlanabilir olma durumu, sosyal alanlara ve alışveriş alanlarına uzaklık, kamu hizmetlerinden yararlanabilme gibi etmenler bulunmaktadır. Bir gayrimenkulün fiziki koşulları da değerini etkileyebilir. Örneğin, arsanın büyüklüğü, cephesi, konumu, şekli, altyapısı, topografyası, çevresindeki yollar ve manzarası gibi unsurlar önem taşır. Değerleme uzmanı ayrıca yapılacak yapılarda işçilik, malzeme ve eskime gibi faktörleri de dikkate almalıdır.

2.1 Geleneksel Gayrimenkul Değerleme Yöntemleri

Karşılaştırmalı satış analizi, maliyet ve gelir indirgeme yöntemleri geleneksel gayrimenkul değerleme kategorisinde değerlendirilmektedir.

2.1.1 Karşılaştırmalı satış analizi yöntemi

Benzer özelliklere sahip birden fazla gayrimenkulü, seçilen karşılaştırma ögeleri baz alınmak suretiyle karşılaştırarak bir başka gayrimenkulün değerini tahmin etme yöntemini, Tanrıvermiş (2013) “Karşılaştırmalı Satış Analizi” başlığında değerlendirirken, Açlar (2008) “Karşılaştırma Yöntemi” ifadesini kullanmayı uygun görmüştür.

Karşılaştırma yöntemi ile konut değerlemesi, karşılaştırılması mümkün olan konutların aynı öznitelik bilgilerinden yola çıkarak, bir başka konutun değerinin hesaplanmasına dayanır. Aynı olmayan farklı nitelikler varsa bunlar değer birimi üzerinden saptanabilir. Açlar (2008) karşılaştırma yöntemini açıklarken arsa örneğini vermiştir. Buna karşın konut değerlemesinde de karşılaştırma yönteminin kullanılabileceği bilinmektedir. Bu yöntemin uygulanabilirliği için, yakın zamanda satılmış ve değerlemesi yapılacak taşınmaza benzer özelliklere sahip başka taşınmazların satış fiyatları bilinmelidir. Bu yöntem üç aşamalıdır. Öncelikle yakın zamanda satılmış ve değerlemesi yapılacak taşınmaza benzer özelliklere sahip taşınmazların satış fiyatı tespit edilir. Daha sonra, uygun karşılaştırma kriterleri belirlenir ve son olarak ise seçilen karşılaştırma ögelerine göre bulunacak birim emsal değerlerde varsa gerekli düzeltmeler yapılarak taşınmazın değerinin tespiti süreci tamamlanır.

Bu yöntemin uygulanma aşamaları aşağıda sıralanmıştır.

1. Konu taşınmaza benzer taşınmazlar için, piyasayı inceleyerek gerçekleşmiş işlemler, satış listeleri ve diğer belgelerin toplanması.
2. Her satış işlemindeki verinin doğrulanması.

3. Uygun karşılaştırma birimleri seçilerek her birim için karşılaştırmalı analizin yapılması.
4. Karşılaştırma birimlerini kullanarak, konu taşınmazla emsal taşınmazların karşılaştırılması, her bir karşılaştırma kriterine göre değer üretilmesi ve düzeltme işlemlerinin yapılması.
5. Değer için belirlenen birden fazla ve farklı sonucun tek bir değere veya değer aralığına indirgenmesi.

Karşılaştırmalı satış analizi için benzer taşınmazların satış fiyatlarına ilişkin serinin oluşturulması gerekmektedir. Piyasa fiyatları serisinin oluşturulması ve doğru sonuç için seri oluşturmada kullanılacak fiyatların mümkün olduğu kadar değerlendirme zamanına yakın ve yakın geçmişe ait olması gerekir. Aksi halde, seriyi oluşturan fiyatlar değerlendirme için esas teşkil etmezler (Tanrıvermiş 2013).

Zaman yönünden emsalin düzeltilmesi gerekebilir. Bu durumda değerlendirme tarihinden altı ay ve daha önceki zamanlarda yapılan alım ve satımlar, TÜFE (Tüketici Fiyat Endeksi) veya ÜFE'deki (Üretici Fiyat Endeksi) artış dikkate alınarak güncellenir. Bu yöntem amaç için uygun emsal alım-satımın hiç veya yeterli olmaması durumunda kullanılabilir. Değer güncellemede aşağıdaki formül kullanılır:

$$X = a \times (D \div b) \quad (2.1)$$

X : değerlendirme zamanına göre düzeltilmiş taşınmaz değeri, b : gerçek alım-satım değerinin ait olduğu aya ait indeks sayısı, D : herhangi bir yılda taşınmazın gerçekleşmiş olan alım-satım değeri ve a : değerlendirme yapılacak zamana (aya) ilişkin indeks sayısını gösterir.

Tanrıvermiş (2013) Yargıtay'ın 5 H.D. E:1971/9451 ve K: 10666 numaralı kararına dikkat çekerek; emsal düzeltme işleminin zaman açısından ele alındığında, yakın çevrede uygun emsal gayrimenkul bulunmaması durumunda, daha uzak mesafelerdeki emsal satışlar veya geçmişte gerçekleştirilen satışlarla karşılaştırma yapılmasının gerekebileceğini söylemiştir. Bu durumda, mesafe veya zaman içindeki değer değişimleri de dikkate alınmalı ve son 3 aydan önceki taşınmaz satışlarının güncellenmesi

gerekmektedir. Çok daha eski yıllara ait gerçekleşen satışlara ilişkin verilerin kullanılması ise uygun görülmemektedir.

2.1.2 Maliyet yöntemi

Maliyet yöntemi, ekonomik anlamda yerine koyma ilkesine dayanır ve yapının değerlendirme zamanındaki maliyetine odaklanır. Bu yöntem, taşınmazın dış tesis, özel işletme donatıları, yapı değeri ve arsa değerini içerir. Kamulaştırma Kanunu ve Emlak Vergisi Kanunu'na göre yapıların maliyet yöntemiyle değerlemesinin yapılması gerekmektedir. Bu yöntem, bir şeye değer biçme sürecinde maliyetin temel alınmasını gerektirir. Pazar değeri kadar olmasa da birçok özel durumda da kullanılabilir. Bir malın maliyeti, o mal için yapılan veya yapılacak tüm harcamaları ifade eder (Tanrıvermiş 2013).

Maliyet yöntemine göre piyasa değeri aşağıdaki şekilde hesaplanır:

$$PD = ((İM + GK) - a) + AD \quad (2.2)$$

PD: Piyasa Değeri

İM: İnşaat Maliyeti

GK: Girişimci Kârı

a: amortisman

AD: Arsa/Arazi Değeridir.

Maliyet yöntemi; yapı değerlerinin ayrı ayrı tespit edildiği sigortacılık, kamulaştırma, yeniden iskân ve kentsel dönüşüm uygulamalarında kullanılır. Malın maliyeti, her zaman değerine eşit olamaz. Maliyet, piyasa değerinin altında veya üzerinde olabilir. Diğer değerlendirme yöntemleri ile değerlendirme mümkün ise, maliyet bedelinin kullanılması uygun olmaz (Tanrıvermiş 2013). Nuhoğlu (2007)'ye göre maliyet yöntemi, bir gayrimenkulün satın alınması yerine gayrimenkulün aynısının ya da aynı faydaları sağlayabilen başka bir gayrimenkulün inşa edilmesi olasılığına dayanır. Yomralıoğlu (1997)'ye göre maliyet yöntemi genellikle otel, fabrika sanayi kompleksi, iş yeri, yönetim yapıları veya bahçeli

ev gibi yapıları olan ve kira bedeli bilinmeyen veya benzeri bulunmayan taşınmazların değerlemesinde kullanılır.

2.1.3 Gelir indirgeme yöntemi

Gelir indirgeme (kapitalizasyon) yöntemi, bir gayrimenkulün niteliği dikkate alınarak, o gayrimenkulden beklenen gelirin tahmin edilmesi için çevresindeki benzer nitelikteki gayrimenkullerin özellikleri ve getirileri ile karşılaştırılarak değer tespiti yapılmasına dayanır (Kaya 2011).

Örneğin bir konut için gayrimenkulün potansiyel kira geliri belirlenir. Kira geliri üzerinden beklenen giderler (bakım, işletme, vergi vb.) düşülerek net kira geliri hesaplanır. Net kira geliri, uygun bir iskonto oranı kullanılarak bugünkü değere indirgenir. Son olarak elde edilen bugünkü değer, gayrimenkulün piyasa değeri olarak kabul edilir. Başka bir deyişle, konutun gelecekteki kira gelirlerinin bugünkü değeri hesaplanarak değerlendirilmesidir.

2.2 İstatistiksel Gayrimenkul Değerleme Yöntemleri

İstatistiksel yöntemlerin temelinde istatistiksel veri ve istatistiksel işlemler vardır. Klasik yöntemlerin eksikliklerini gidermenin bir yoludur ve aynı zamanda daha kesin sonuçlara ulaşma kolaylığı sağlamasından dolayı da tercih edilmektedir. Genellikle gelişmiş ülkelerde yapılan değerlendirme çalışmalarında görülebilecek olan istatistiksel değerlendirme yöntemleri maalesef diğer birçok ülkede teorik çalışmalarla sınırlı kalmıştır. Ayrıca istatistiksel yöntemlerle yapılan değerlendirme çalışmalarının sonuçları değerlendirme uzmanlarının görüşleriyle desteklenmeye de muhtaçtır. En yaygın yöntemler nominal değerlendirme, ÇDR, CAR ve hedonik değerlemedir.

2.2.1 Nominal değerlendirme yöntemi

İstatistiksel bir değerlendirme yaklaşımı olarak nominal değerlendirme, gayrimenkulün değerine etki eden faktörlerin her birinin değere hangi ağırlıkta etki ettiğinin belirlenmesidir. Her

bir deęişkenin deęere etkisinin nominal olarak sayısal anlamda ifade edilmesine dayanır. Deęere etki eden gayrimenkule ilişkin özelliklerin sayısal olarak bir katsayı ile ifade edilmesi esastır.

Bir gayrimenkulün deęerini etkileyen birçok faktör vardır. Birçok faktörün gayrimenkulün deęerine etki etmesi ise söz konusu gayrimenkulün deęerinin belirlenmesini güçleştirmektedir. Alpaslan (2015)'e göre; gayrimenkul sayısının fazla olduęu alanlarda, sayısı sınırlanamayan faktörler nedeniyle gelir indirgeme yöntemi etkili olabilmektedir. Bu yöntem, gayrimenkullerin deęerinin belirlenmesinden sonra faktörlerin gayrimenkul üzerindeki etkisini açıklayabilecek deęişkenleri ifade eder.

Bir gayrimenkulün parametrik deęeri aşağıdaki formül ile hesaplanır.

$$V_i \times S_i (F_{ji} \times W_i) \quad (2.3)$$

V_i : Nominal deęer toplamı

S_i : i parselinin alanı

F_{ji} : Faktör j'nin i gayrimenkulündeki etkisi

W_i : i gayrimenkulündeki faktör ağırlığı

Karapınar (2013)'a göre gayrimenkulün deęerine etki eden deęişkenler normalize edilerek 1 ile 100 arasında veya 1 ile 10 arasındaki bir deęere dönüştürülmelidir. Bu şekilde her taşınmaz için normalize edilmiş taban ve tavan puan hesaplanmış olur. Sonuç olarak katsayılar deęer deęişkenine dönüştürülebilir.

2.2.2 Çoklu regresyon analizi

Alpaslan (2015)'e göre regresyon analizi, en küçük kareler yöntemi olarak da bilinir ve gayrimenkulün deęerini belirleyen özelliklerin doğrusal olarak deęer deęişkenini açıklamaya imkân veren bir istatistiksel analiz türüdür. Bu analiz, bir bağımlı deęişken ve bir bağımsız deęişken arasındaki ilişkiyi inceleyen doğrusal regresyon veya birden

fazla bağımsız değişkenin bağımlı değişkene etkisini inceleyen çoklu regresyon olarak uygulanabilir.

Yani, bağımlı değişkeni açıklamaya çalışan bağımsız değişken sayısı eğer bir tane ise bu yönteme, doğrusal regresyon denirken, bağımlı değişkeni açıklamaya çalışan bağımsız değişken sayısı birden fazla ise bu yöntem ÇDR olarak tanımlanmaktadır.

2.2.3 Coğrafi ağırlıklı regresyon analizi

CAR, coğrafi verilerin analizi için kullanılan istatistiksel bir yöntemdir. Bu yöntem, coğrafi konumun etkisini dikkate alarak, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi belirlemeye çalışır. CAR'da, coğrafi olarak yakın noktaların birbirine benzer olduğu varsayılır ve analizde bu yakınlık faktörü dikkate alınır. Bu yöntem, coğrafi verilerin incelenmesinde kullanılarak, coğrafi konumun analiz sonuçları üzerindeki etkisini değerlendirmeye yardımcı olur.

Bağımsız değişkenlerin bağımlı değişken üzerinde olumlu ya da olumsuz yönde etkisi olabilir. Bu durumu açıklamak için bağımsız değişkenlere ek olarak konum bilgisinin de bağımlı değişkeni nasıl açıkladığı üzerinde durulmaktadır. Farklı konumlardaki veriler bağımlı değişkeni farklı ağırlıklarda açıklayabilmektedir. Bu durumu modellemek için CAR yöntemi kullanılmaktadır.

2.2.4 Hedonik değerlendirme yöntemi

Emlak piyasasında bir gayrimenkulün satın alma veya kiralama değeri genel olarak mikro ekonomik teoriye dayanmakta ve büyük veriler kullanılarak analiz edilmesi hedonik yöntem olarak ifade edilmektedir. Hedonik model ile bir gayrimenkulün değerini etkileyen değişkenler tespit edilir, değere ne kadar etki ettiği belirlenir ve böylece bir gayrimenkule bir özellik daha eklendiğinde gayrimenkulün yeni değerinin ne olacağı hedonik analiz yöntemi ile belirlenmiş olur (Temurlenk ve Özçelik 2003).

Hedonik deęerleme ynteminde mlkn fiziksel zelliklerinin yanı sıra, evresel zellikler ve yařam kalitesi gibi sbjektif unsurlar da gz nnde bulundurulmaktadır.

2.3 Modern Deęerleme Yntemleri

Khamrabaeva (2020)'ye gre modern deęerleme yntemleri, dięer geleneksel yntemlere kıyasla daha az hata payı iermektedir. Bu yntemler, deęerleme uzmanının bilgisini ve teknolojik yetkinlięini gerektirmektedir. Modern deęerleme yntemleri kullanılırken genellikle ok sayıda veriye ihtiya duyulmaktadır.

“Geliřmiř Deęerleme Yntemleri” bařlıęı altında Odabařı (2020) bilgisayar sistemlerine dayalı deęerleme yntemlerinden bahsetmiřtir. “Bilgisayar sistemleri ile yapılan deęerleme”yi Khamrabaeva (2020) “modern deęerleme yntemi” olarak nitelendirmiřtir.

Yalpır (2007) tarafından yapılan alıřmada, bilgisayar teknolojisinin insan yařamının her alanında ve her anında kullanıldıęı vurgulanmaktadır. Teknolojinin saęladıęı olanaklar sayesinde daha fazla veri analiz edilebilmekte ve daha detaylı sonular elde edilebilmektedir. İnsanın sahip olduęu mantıęın biliřim teknolojileri kapsamında kullanılması YZ yntemleriyle gerekleřtirilmektedir.

zkan vd. (2007)'e gre, bilgi sistemlerine dayalı sistemlerden olan YSA, bulanık mantık, uzman sistemler, M, doku tanımlama, bilgisayar aracılıęı ile ęrenme ve evrimsel programlama yntemleri, modern deęerleme yntemleri arasında en sık kullanılanlardır. D, M'den sonra daha detaylı ve etkili bir yntem olarak ne ıkmıřtır. Derinpınar ve Aydınoęlu (2015), bulanık mantık metodolojisini ekonomi, makine sistemleri, tıp vb. alanlarda sıklıkla kullanılan YZ teknikleri arasında saymıřtır. Gayrimenkul deęerleme uygulamalarında ise YSA ve bulanık mantık yntemleri en ok tercih edilenler arasındadır.

Modern deęerleme yntemleri genelde toplu deęerleme iin kullanılmaktadır. Birden fazla gayrimenkuln deęerinin hızlı ve gvenilir bir řekilde belirlenebilmesi amacıyla,

bir örneklem kümesi kullanılarak istatistiksel yöntemlerle gerçekleştirilen değerlendirme süreci toplu değerlendirme olarak tanımlanmıştır (Tanrıvermiş, 2018). Toplu değerlemeyi Zou vd. (2018), fazla sayıda gayrimenkulün piyasa değerinin belirlenmesini sağlayan matematiksel modellerin, CBS ve bilgisayarlı istatistik ile analiz edilmesi şeklinde açıklamıştır. Uluslararası Değerleme Çalışanları Birliği (IAAO) toplu değerlemeyi, belirli istatistiksel metotlar kullanılarak, çok sayıda veri kümesini işleyerek, hızlı ve güvenilir bir sonuç elde etmeye imkân tanıyan bilgisayar programlarının çıktıları olarak tanımlar (İlhan ve Öz, 2020).

2.3.1 Yapay sinir ağı yöntemi

Alpaslan (2015)'e göre YSA, bazı çalışmalarda YZ olarak da adlandırılrsa da, bu yöntem insan beynini taklit etme amacını içerir. Yani, biyolojik sinir ağlarına benzeyen bilgisayar yazılımlarıdır. İlhan ve Öz (2020), Chiarazzo vd. (2014), Arıkan Kargı (2015) ve Basheer ve Hajmeer (2000)'den aktararak YSA metodolojisini açıklamıştır. YSA, gizli doğrusal olmayan bağıntıların ortaya çıkmasını sağlamak için fonksiyonel modeller geliştirmek amacıyla tasarlanmıştır (Chiarazzo vd. 2014). Bir YSA, nöronlar arasındaki bağlantının bir modeli olarak tanımlanır. Ayrıca, bağlantılardaki ağırlıkların hesaplanması ve transfer fonksiyonu da YSA'nın unsurları arasında yer almaktadır. YSA'lar, girdi-çıkı sinirlerinden oluşur ve sinirler arasındaki bağlantıların ağırlıklarını öğrenme veya eğitme yeteneğine sahiptir. Bu sayede ağ, bir girdi grubuna karşı etkili bir çıktı üretebilmektedir (Arıkan Kargı 2015). YSA'ların cazibesi, doğrusal olmama, yüksek paralellik, hata ve gürültü toleransı, öğrenme ve genelleme yetenekleri gibi dikkate değer bilgi işleme özelliklerinden kaynaklanır (Basheer ve Hajmeer 2000). Dolayısı ile konut özellikleri YSA'nın giriş katmanlarını temsil ederken, konutun değeri ise çıktı katmanını temsil etmektedir.

Bir YSA'nın başarısını değerlendirmek için yaygın olarak kullanılan ölçütler Ortalama Mutlak Yüzde Hatası (OMYH), Ortalama Kareli Hata (OKH) ve Ortalama Kare Hata Karekökü (OKHK) olup, formüller (3.4-5-6) aşağıda gösterilmiştir.

$$MAPE = \frac{1}{n} \sum \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (2.4)$$

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n} \quad (2.5)$$

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}} \quad (2.6)$$

Bu eşitliklerde y_i tahmin değerlerini, $\hat{y}_i$ ölçüm değerlerini, n örnek sayısını göstermektedir.

OKHK ölçülen değerler ile tahmin edilmiş değerler arasındaki hatayı belirlemeye yarar. OMYH, tahmin edilen değerler ile ölçülen değerler arasındaki hataların mutlak ortalama yüzdesini ifade eder. Belirleme katsayısı r^2 ise değişkenler arasındaki korelasyonu göstermektedir (İlhan ve Öz, 2020).

İlhan ve Öz'ün (2020) açıkladığı bu ölçütlere ek olarak OMH de ağırlığın doğruluğunu belirlemede bir ölçüt olarak kullanılabilir. Bu ölçüt hata miktarlarının mutlak değerlerinin ortalamasıdır.

$$MAE = \frac{\sum_{t=1}^n |u_t|}{n} \quad (2.7)$$


2.3.2 Bulanık mantık yöntemi

İlk defa California Berkeley Üniversitesinden Profesör Lotfi Zadeh 1965 yılında bulanık mantık (fuzzy logic) kavramını ortaya atmıştır. Bulanık kümeler ve alt kümeler bulanık mantığın temelini oluşturmaktadır. Klasik bilgisayar mantığının yetmediği durumları açıklamak için bu yöntem geliştirilmiştir. Bir probleme ait belirsizliklerin matematiksel olarak ifade edilmesini sağlar. Bilgisayar mantığında bir olay ya 1 ya da 0'dır. Ama bulanık mantıkta bu durum kesin bir rakamla değil belli bir aralıkla ifade edilir.

Bulanık mantığın temel amacı, bir önermenin doğruluğunun, tamamen doğru ya da yanlış olması yerine, sonsuz sayıda doğruluk değerleri arasında bulunan sayısal bir değerle (genellikle 0-1 aralığı) ifade edilmesidir. Bu yaklaşım, belirsizlik içeren problemlerin çözümüne yardımcı olur ve gerçek hayatta karşılaşılan pek çok konuda kullanılabilir (Yıldız 2009).

Bulanık küme teorisi, belirsizlik içeren verileri modellemek ve analiz etmek için kullanılan bir matematiksel yaklaşımdır. Bulanık küme, elemanların tamamen ya da kısmen bir kümeye ait olma derecesini ifade eden bir kavramdır. Yani, bir elemanın bir küme içinde bulunma derecesi kesin bir sınıflandırma yerine, belirli bir olasılıkla ifade edilir. Bu teori, gerçek hayatta karşılaşılan belirsizliklerin modellenmesi için kullanılır. Örneğin, hava durumu tahminleri, trafik yoğunluğu analizleri, tıbbi teşhisler gibi alanlarda bulanık küme teorisi uygulanabilir. Bu teori, kesin sınıflandırmaların yapılamadığı durumlarda daha esnek ve gerçekçi sonuçlar elde etmeyi sağlar.

Bulanık küme teorisi bağlamında klasik küme ile bulanık küme farkı Şekil 2.1’de ifade edilmeye çalışılmıştır.



Şekil 2.1 Klasik ve bulanık küme farkı (Topaloğlu, 2018)

Yani bulanık mantık yöntemi kesin bir sonuç değeri yerine, belirli bir değer aralığına odaklanır. Bu yöntem bir gayrimenkulün değerini belirleyen faktörler arasındaki ilişkileri ve etkileşimleri hesaba katarak daha gerçekçi sonuçlar elde edebilmektedir. Örneğin, bir gayrimenkulün değerini belirleyen faktörler arasında konum, büyüklük, yaş, yapı kalitesi, çevre düzenlemesi ve yakınlığı gibi birçok etken bulunabilir. Bu faktörler arasındaki ilişkiler ve etkileşimler, bulanık mantık yöntemiyle hesaplanarak, gayrimenkulün piyasa değer aralığı belirlenebilir.

3. DERİN ÖĞRENME

DÖ, YZ alanında kullanılan bir öğrenme tekniğidir. YZ ise YSA mantığına dayanmaktadır. Bu teknik ilk olarak, insan beyninin çalışma şekline benzetilerek geliştirilmiştir. Bu tip modellerin amacı öğrenmenin nasıl gerçekleştiği ya da biyolojik beyinde gerçekten gerçekleşip gerçekleşmediğini açıklamaktır. O nedenle DÖ'nün adlarından biri de YSA'dır. DÖ modellerinde buna karşılık gelen bakış açısı, bu modellerin biyolojik beyinlerden (insan ya da hayvan beyni) esinlenilerek geliştirilmiş sistemler olduğudur.


DÖ'deki sinir kavramına bakış açısı iki ana fikre dayanır. Fikirlerden biri, beynin zeki davranışlara dair bir örnek olarak görülmesi ve zekâyı anlatmanın kavramsal olarak en basit yolunun beynin yapısındaki hesaba dayalı prensipleri tersine mühendislikten geçirmek ve beynin işlevselliğini aynen kopyalamak olduğudur. Diğer fikir ise MÖ modellerinin mühendislik uygulamalarının yanı sıra, beynin ve zekânın altında yatan prensiplerin anlaşılması için gereken temel bilim problemlerini aydınlayabileceği beklentisidir.

YSA'nın biyolojik beyinden esinlenmediği yönünde görüşler de vardır. Sinir ağları bazı durumlarda beyin fonksiyonlarını anlamak için kullanılmış olsa da Hinton ve Stallice (1991)'e göre genelde biyolojik fonksiyonları gerçekçi olarak taklit etmek için tasarlanmamıştır. Buna ek olarak, Goodfellow vd. (2021) DÖ araştırmalarında sinir biliminin rolünün azaldığı yönünde görüşlerin de bulunduğunu belirtmiştir. Bunun ana nedeni, beyin hakkında onu bir rehber olarak kullanmak için yeterli bilgiye sahip olunamamasıdır. Beynin kullandığı gerçek algoritmaları derinlemesine anlamak için, en azından birbirine bağlı binlerce nöronun aktivitesinin aynı anda izlenebilmesi gerekir. Bu yapılamadığı için beynin en basit ve en iyi çalışılmış kısımları bile anlaşılmaktan uzaktır. DÖ'yü beyni tam olarak simüle etme girişimi olarak görmemek gerekir. Modern DÖ birçok alandan, özellikle de doğrusal cebir, olasılık, bilgi teorisi ve sayısal optimizasyon gibi uygulamalı matematik temellerinden ilham alır.

Ancak en yaygın kanı; YZ, MÖ ve DÖ'nün temelinde biyolojik anlamdaki sinir sisteminin yapısından esinlenilmiş olması ve bu nedenle YSA olarak adlandırılmış olmasıdır. Biyolojik anlamdaki bir sinir hücresinin yapısı Şekil 3.1'de gösterilmiştir. Bir sinir hücresinin nöron ve sinapsis denilen iki ana kısmı vardır.


Dolayısıyla, YSA'lar bilgi depolayabilme ve çağrışım içeren bir bellek gibi çalışabildiği için, insan beynine benzer bir özellik taşımaktadır. Bir veri tabanına sahip olduğu için, yeni veriler ekleyerek öğrenebilirler ve bu işleri yapmak için programlanabilirler. Kendilerine gösterilen az sayıdaki örnek veriden yola çıkarak, genellemeler yapabilirler. Veride ortak hangi özellikler varsa ortaya çıkarabilirler (Lin 1991).

Sistem girdi, işlem ve çıktı öğelerinden oluşur. Girdiler sistemin üzerinde sinapsisler vasıtasıyla taşınır. Yani sinapsisler iletim sistemi ve nöronlarda karar verme süreçleri gibi düşünülebilir (Şekil 3.1).



Şekil 3.1 Biyolojik sinir hücresi (Anonim, 2023f)

MÖ'nün bazı modelleri bağımsız değişken olarak eksik veriyi, sayısal veriyi veya kategorik veriyi kabul etmemektedir. YSA'ya has olan durum ise verilerin standardize olarak gelmesi gerekliliğidir. Yani 0 ve 1 arasında normalize edilmiş olmalıdır. Başka bir deyişle, verilerin double (0 ve 1 arasında ondalıklı veriler) olması gereklidir. Çıktı 0 ve 1 arasında, binominal (kadın, erkek gibi) veya kategorik de olabilir. Sinapsislerin (Şekil 3.2) üzerinde veriler ağırlıklandırılarak taşınır.



Şekil 3.2 Nöron (Şeker 2021)

Sabit kodlanmış algoritmalar veya sabit, kural tabanlı sistemler, görüntü tanıma veya metinden anlam çıkarma gibi şeyler için pek iyi çalışmamıştır. Çözümün sadece insan davranışını taklit etmek değil, aynı zamanda insanların nasıl öğrendiğini de taklit etmek olduğu ortaya çıkmıştır. YSA teknolojisi; insanların doğayı anlama ve aynı özellikleri ile taklit etmeye çalışma örneklerinden birisidir. YSA girdi katmanı ile çıktı katmanı arasındaki ilişkiyi belirleyerek bir fonksiyon üretmeye dayanır (Rende vd. 2016). Bu fonksiyon “kara kutu” olarak da tarif edilebilir. Gerçek bir sinir hücresi ile bir YSA modeli birbiri ile aynı prensipler çerçevesinde çalışmaktadır (Sorias 2005). Gemici (2007)’ye göre, YSA’lar biyolojik nöronların matematiksel modelleridir. Nöronlar, birbirlerine sinapslar aracılığıyla bağlı olan işlem birimlerinden oluşmaktadır. Simüle edilen sinir hücreleri (nöronlar), bir ağ oluşturmak için birbirlerine bağlıdır. Bu ağlar genellikle farklı katmanlardan oluşmaktadır. YSA’lar, veri tabanına yazma ve veriler arasındaki ilişkileri keşfetme yeteneğine sahiptir. Başka bir deyişle, YSA’lar insanların gözlemlene ve düşünme gibi yeteneklerinin gerektiği problemlere çözümler üretebilmektedir. İnsanların deneyimleyerek ve öğrenerek kazandığı bilgi, düşünme ve gözlemlene gerektiren problemlerin çözümünde önemli bir rol oynamaktadır.

DÖ birçok işte kullanılmaktadır. Görüntü sınıflandırma, ses tanıma, el yazısı tanıma, otomatik tercüme edebilme, yazıdan ses üretimi, insan gibi araç sürüşü, dijital reklamlar için en iyi hedef kitle tespiti yapabilme, sorulan sorulara cevap verebilme yeteneği ve go oynayabilme bunlardan bazılarıdır.

DÖ ile hâlâ daha neler yapılabileceği araştırılmaktadır. DÖ'yü, makine algılaması/tanımaları ve doğal dili anlamının ötesinde akıl yürütmeyi öğrenmek gibi alanlarda da kullanabilmek için DÖ konusunda araştırmalar yapılmaktadır. DÖ'nün bilim, yazılım geliştirme ve daha birçok alanda insanlara yardım edebileceği öngörülmektedir. Örneğin; GPT3 ve GPT4'ün yazılım geliştirme konusunda insanlara yardımcı olduğu ve bu konuda ileri bir noktada olduğu bilinmektedir. Üretken Önceden Eğitilmiş Dönüştürücü (ÜÖED), yani orijinal adı ile Generative Pre-trained Transformer (GPT), OpenAI tarafından geliştirilen DÖ temelli bir YZ dil modelidir. GPT, büyük bir veri setiyle eğitilmiş ve doğal dil işleme, metin üretimi ve anlam çıkarımı gibi görevlerde oldukça başarılı sonuçlar sergilemektedir. GPT, çeşitli alanlarda kullanılabilen esnek yapısıyla dikkat çekmektedir. Ancak, GPT'nin 3. versiyonunun bazı sınırlamaları da bulunmakta ve hâlâ her türlü soru veya görevi tam anlamıyla çözmemektedir. GPT'nin 4. versiyonunun faaliyette olduğu da bilinmektedir.

DÖ birçok problemin çözümünde yüksek performans sağlamaktadır. Bu nedenle kullanımı hızlı bir şekilde yaygınlaşmıştır. MÖ'deki en kritik adımlardan biri olan öznitelik çıkarımı adımını DÖ otomatikleştirmiştir. Daha önceki MÖ teknikleri -sığ öğrenme- genellikle Destek Vektör Makineleri (DVM) ya da karar ağaçlarını kullanarak, basit dönüşümler ile veriyi bir veya iki birbirini takip eden gösterim uzayına dönüştürebilmektedir. Ancak daha iyi gösterimlere gereksinim duyan karmaşık problemlerde bu teknikler yetersiz kalmaktadır. İnsanlar bu teknikleri kullanabilmek adına verilerinin tekniklere uyumlu olması için uzun süren ön işlemler (daha iyi gösterimler elde etmek için) yapmak durumunda kalmaktaydılar. Bu işleme öznitelik çıkarma denilmektedir. Buna karşın, DÖ tüm özellikleri kendiliğinden öğrenerek tüm bu süreci otomatikleştirmektedir.

3.1 Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Kavramlarının Ayrımı

DÖ, MÖ ve YZ temelde farklı kavramlar olmakla birlikte, ortak özellikler ihtiva ettiklerinden, birbirlerine yakın anlamlar içermekte ve zamanla değişim göstermişlerdir (Şekil 3.3).

YZ, akademik bir disiplin olarak 1956'da kuruldu. Amacı bilgisayarların sadece insanın yapabileceği görevler olarak kabul edilen işleri yerine getirmesini sağlamaktı. Zamanla bazı problemler YZ için çok zor olarak nitelendirilmeye başlandı. 1980'lerde daha teknik bir terim olarak MÖ ortaya çıktı ve daha yaygın kullanılmaya başlandı.

DÖ zaman içinde değişim göstermiştir. Aslında bilgisayarlı görü için DÖ'nün iki anahtarı Evrişimli Sinir Ağları (ESA) ve geriye yayılım 1989'dan itibaren tamamen anlaşılmıştır. Zaman dizisi analizi için temel DÖ algoritması olan Uzun Kısa Dönem Bellek (UKDB) 1997 yılında geliştirilmiş ve çok az değişmiştir. DÖ ancak 2012 yılından sonra insan hayatına girebilmiştir. Bunun en temel ifade ile 3 nedeni vardır. Bunlar donanım, veri setleri ve algoritmalarda yapılan iyileştirmelerdir. Bu alandaki ilerlemeler teorikten çok, uygulamalar sonucunda elde edilmiştir. Dolayısıyla yeni fikirleri denemek için gerekli donanım ve veri setlerinin varlığının sonucu olarak algoritmalarda iyileştirmeler olabilmektedir.


1990 ile 2000'ler arasında bu tip işler için ana darboğaz, verilerin ve donanımların eksikliği olmuştur. Tam da bu noktada internet ve oyun pazarı için geliştirilen yüksek kapasiteli ekran kartları insan hayatına girmiştir. 1990 ile 2000 yılları arasında Merkezi İşlem Birimi (MİB), diğer bir deyişle işlemciler 5000 kat hızlanmıştır. Bunun sonucunda, 25 yıl önce hayal bile edilemeyecek ölçüde küçük bir DÖ modelini dizüstü bir bilgisayarda çalıştırmak mümkün olabilmektedir. İnternet kullanımının yaygınlaşması ile MÖ'de ihtiyaç duyulan büyük veri setlerinin toplanması ve dağıtımının mümkün olabilmesi ve veri depolamada elde edilen imkânların artışı, veri anlamında önemli noktalara erişilmesini sağlamıştır. Ayrıca, 2009-2010 yıllarında çok basit ve de çok önemli birkaç algoritmanın keşfi ile hata miktarlarının geriye daha iyi yayımı mümkün hale gelmiştir. Bu algoritmalar, katmanlar için çok daha uygun aktivasyon fonksiyonları, daha etkili ilk ağırlık başlatma yöntemleri ve daha iyi eniyileme yöntemleri sunmaktadır. Bu ilerlemeler sayesinde 10 veya daha fazla katmanlı modeller oluşturmak mümkün olabilmektedir. Sonuç olarak; 2014, 2015, 2016 yıllarında gradyanın daha iyi yayılımını sağlayan yığın normalleştirme, artık bağlantı ve derinliğine ayrılabilir evrişim gibi ileri yöntemler geliştirilmiştir. Artık binlerce katmandan oluşan ağların sıfırdan eğitilebilmesi mümkün hale gelmiştir.



Şekil 3.3 YZ, MÖ ve DÖ gelişiminde kronolojik sıralama (Anonim, 2023g)

Tıpkı insan beyinde olduğu gibi, DÖ sürekli bir şekilde öğrenileni daha çok artırmaya odaklanmaktadır. Yani kümülatif olarak en çok öğrenme oranını ortaya çıkarana kadar öğrenme sürecini tekrar etmektedir.

Goodfellow (2021) Gösterim Öğrenmeyi (GÖ) de ihtiva edecek şekilde DÖ, GÖ, MÖ ve YZ kavramlarının kapsamalarını Şekil 3.4’de bir ven şeması ile göstermiştir. Bu şemaya göre DÖ, YZ’nin alt küme elamanıdır.



Şekil 3.4 DÖ, GÖ, MÖ ve YZ kavramlarının ven şemasında gösterimi (Goodfellow 2021)

YZ ile ilgili en yaygın tanımı Keleş (2007) yapmıştır. YZ, insanlar tarafından yapılan zekâ gerektiren işlerin makinelere yaptırılması konusunda uğraşan bir bilim dalıdır ve bilişim teknolojilerinin içinde bir kavram olarak doğmuştur. Üreticisinin öngördüğü kriter ve veriler doğrultusunda öğrenebilme yeteneği ile diğer bilişim teknolojilerinden ayrılan YZ, artık bir terim olmaktan çıkıp bir teknoloji haline gelmiştir.

YZ ile sıradan bir bilgisayar programını birbirinden ayıran en temel özelliğin YZ programlarının öğrenebilme yeteneğinin olmasıdır. Keleş (2007)'e göre araştırmacıların programlanabilir makineler yerine, öğrenebilen makineyi yapma arzusu YZ alanındaki

gelişmeleri ortaya çıkarmıştır. YZ’yi herhangi bir bilgisayar yazılımından ayıran bir diğer özelliği ise, kendi kendine bazı konularda karar alabilmesidir. Örneğin, bir fabrika sahası içerisinde otomatik olarak hareket edebilen bir robot tasarlanması yazılım iken, fabrika sahasının tasarımının değişmesi halinde de işlev görebilen robotlar bir YZ ürünüdür.

DÖ’nün başarısının odağında ‘bana balık verme, balık tutmayı öğret’ anlayışı vardır. Yani modele veriye ne yapması gerektiği söylenmez. Bunun yerine modele çok fazla miktarda veri ve etiket verilip, bunlar arasındaki ilişkiyi öğrenmesi beklenir. Bu sayede model sadece tek bir veride değil, genel olarak o tip verilerde başarılı sonuçlar üretir. Aslında diğer MÖ teknikleri de bunu uygular. Fakat bu teknikler karmaşık verilerde iyi değildir. Ama DÖ karmaşık verileri de iyi analiz eder. Çünkü çok fazla miktarda veri ister ve bunları kullanma konusunda iyidir. Diğer MÖ teknikleri her bir katmanın doğru sonucu vermesine odaklanırken, DÖ metotları katmaların hepsinin bir bütün olarak doğru sonucu vermesine yönelik olarak ağırlıklandırma işlemleri gerçekleştirilerek doğru sonucu tahmin etmeye çalışmaktadır.

Aktaş (2020) MÖ, YZ’nin alt kümesinde yer alırken, DÖ ise MÖ’nün alt kümesinde yer almaktadır demiş, DÖ ile çok büyük veri kümeleri üzerinde çalışabilmenin mümkün olduğunu söylemiştir. Buna ek olarak DÖ ile büyük veri kümeleri ile tahmin etme ve sınıflandırma işlemlerinin rahatlıkla yapılabileceği üzerinde durmuştur.

Lecun vd. (2015)’nin dil işleme, görüntü işleme ve sınıflandırma gibi alanlarda DÖ’nün önemli başarı oranları elde edebilmiş olmasına dikkat çekmiştir. DÖ, aslında çok katmandan oluşan bir YSA modeli olduğu için, bir önceki katmandan elde ettiği sonuçları daha iyileştirecek bir fonksiyon üretmek suretiyle geriye dönüşler yapmaktadır (Aktaş, 2020). Geriye dönüşler yaparak DÖ mimarisinin iyileştirilmesi mümkün olabilmekte ve çok büyük veri kümeleri ile çalışabilmek ancak bu şekilde mümkün olabilmektedir.

Chollet (2021)’e göre DÖ’yü diğer MÖ yöntemlerinden ayıran özelliklerinden biri katmanlar halinde çok daha karmaşık problemleri çözebiliyor olmasıdır. Diğer ise, tüm katmanların öğrenmeyi birlikte yapabiliyor olmasıdır. Bütün katmanların kendinden

önceki ve sonraki katmanların ihtiyaçlarına göre kendisini güncelleyebiliyor olması, DÖ'yü daha yetenekli kılmaktadır.

Özetle, YZ, MÖ ve DÖ, birbirine bağlı ancak farklı kavramlar ve tekniklerdir. YZ, matematiksel bir modeldir. MÖ bilgisayar sistemlerinin verilere dayalı deneyimlerle öğrenmesini sağlayan bir alanı ifade eder. DÖ ise çok katmanlı YSA kullanarak verilerden otomatik olarak özellikler ve temsiller çıkaran bir MÖ alt alanıdır. DÖ sinir bilimin yeni nesil MÖ modellerine olan bakış açısının ötesindedir ve öğrenmeyle ilgili daha genel bir prensibin çoklu bileşim seviyeleri peşindedir. Bu prensip, sınırlardan esinlenilmemiş makine öğrenme yöntemlerine de uygulanabilir.

DÖ'nün ataları, sinir biliminin bakış açısından yola çıkılarak geliştirilmiş basit doğrusal modellerdir. Bu modellerle $x_1, \dots, x_n$ olarak n adet girdi alınıp, y çıktısıyla ilişkilendirilir. Bunun için $w_1, \dots, w_n$ olarak verilen ağırlıklar öğrenilip, çıktı

$$f(x, w) = x_1 w_1 + \dots + x_n w_n \quad (3.1)$$


formülü kullanılarak hesaplanır.

3.2 Derin Öğrenme Kavramları

DÖ'nin temelinde YSA vardır. YSA yöntemi “İnsan beynindeki sinir hücrelerinin yapısı bilgisayarda modellenenirse, insan gibi çalışan bir bilgisayar yapılabilir mi?” sorusunun cevabını arar. DÖ'ye ilişkin kavramlar başlıklar halinde aşağıda açıklanmıştır.

3.2.1 Nöron

YSA'nın temelini nöronlar oluşturur. Nöronlar insandaki sinir hücrelerine benzetilmektedir. Sinirler birbirine bağlanarak nöral ağı oluştururlar. Nöral ağda, nörona gelen bir girdi alınır, işlenir ve bir sonraki işlem için diğer nöronlara gönderilir. En son nöron ise çıktı veya bir sonuç çıktısı üretir (Şekil 3.5).



Şekil 3.5 Nöron (Şeker 2021)

Bir YSA'daki girdi değerleri bağımsız değişkenleri ifade ederken, çıktı değeri bağımlı değişkeni ifade etmektedir. Bir nöron aldığı girdiyi çıktıya dönüştürmeden önce ağırlıklandırma işlemine de tabi tutmaktadır.

3.2.2 Ağırlıklar

Bir nörona girdi geldiğinde belirli bir ağırlıkla çarpılarak işleme alınır. Bu ağırlıklar ilk başta rastgele belirlenir ve eğitim süresince bu ağırlıklar sürekli güncellenir. YSA sonuca katkısı daha çok olan girdilere daha çok ağırlık verirken, sonuca katkısı daha önemsiz olan girdilere daha az ağırlık verir.

Bir YSA'nın amacı en doğru çıktı değerini üretmektir. En doğru çıktı değerine ulaşmak için en doğru ağırlık değerlerine ulaşmak hedeflenmektedir. Bu nedenle ağırlık öğrenme sürecinde ağırlıklar önemli bir rol oynamaktadır.


3.2.3 Sapma

Girdiye ağırlıktan farklı olarak uygulanan doğrusal bileşen sapma (bias)'dır. Sapma ağırlık katsayılı girişin aralığını değiştirmek için kullanılan sabit bir değerdir. Sapma, nöronun çıktısını etkileyerek ağırlık esnekliğini artırıp, doğruluk oranını iyileştirebilmektedir.

Eğer bir modelin sapması yüksekse, bu modelin gerçek değerden daha fazla sapma gösterdiği anlamına gelir. Bu durumda, modelin tahminleri gerçek değere göre daha yanıltıcı olabilir. Düşük sapma ise, modelin gerçek değere daha yakın tahminlerde bulunduğunu gösterirken, yüksek sapma ise modelin gerçek değere daha uzak tahminlerde bulunduğunu gösterir.


3.2.4 Aktivasyon fonksiyonu

Giriş sinyallerini, çıkış sinyallerine çeviren aktivasyon fonksiyonunun doğrusal bileşime uygulanması; doğrusal bileşenin girdiye uygulanmasından sonra doğrusal olmayan fonksiyon uygulanması ile gerçekleştirilir. Aktivasyon fonksiyonu uygulandıktan sonra bir çıktı olacaktır. Ağırlıklar önce kendilerine karşılık gelen girdi ile çarpılır ve sonra sapma çarpım sonucuna eklenir. Ağırlık toplamalarına karşılık gelen girdi toplamalarının çarpımına sapma değeri eklenmesi ile oluşan sonuca aktivasyon fonksiyonu uygulanır ve fonksiyonun sonucu çıktıdır. Relu, softmax ve sigmoid en yaygın kullanılan aktivasyon fonksiyonlarıdır. **Şekil 3.6**'da “n” tane girdinin bir nörona girmesi ve bir çıktının üretilmesi aşamaları gösterilmektedir.



Şekil 3.6 Bir nörona girdi, ağırlıklar, net fonksiyonu, aktivasyon fonksiyonu ve çıktı (Anonim 2023d)

Relu aktivasyon fonksiyonuna göre fonksiyon çıktısı v , sıfırdan küçükse sonuç 0 (sıfır) alınır, fonksiyon çıktısı v 0 (sıfır)'dan büyükse sonuç v alınır. Relu aktivasyon fonksiyonunun grafiği Şekil 3.7'de gösterilmektedir.




Şekil 3.7 Relu aktivasyon fonksiyonu grafiği (Anonim 2023a)

Relu aktivasyon fonksiyonu 0 (sıfır)'dan büyük tüm girdiler için ağıın daha hızlı eğitilmesini sağlar. Relu aktivasyon fonksiyonu matematiksel olarak (3.2) eşitliğindeki gibi ifade edilir.

$$f(x) = \max(0, x) \quad (3.2)$$

Sigmoid aktivasyon fonksiyonu, herhangi bir gerçel sayıyı 0 ile 1 arasında bir değere dönüştürür. Bu dönüşüm pürüzsüz eğrilere sahiptir. Girdi değerlerindeki küçük değişikliklerin gözlemlenebilmesine imkân vermektedir (Şekil 3.8).



Şekil 3.8 Sigmoid aktivasyon fonksiyonu grafiği (Anonim, 2023a)

Sigmoid aktivasyon fonksiyonu matematiksel olarak (3.3) eşitliği ile ifade edilmektedir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.3)$$

Softmax fonksiyonu genellikle sınıflandırma problemleri için kullanılır. Softmax fonksiyonu sigmoid fonksiyonuna benzer ancak tek farkı çıktıların 1'e kadar olan toplamalarının normalize edilmesidir. Örneğin görüntü işlemede 8 rakamının tanımlanmasında, bu fonksiyon her rakama bir olasılık değeri atar. 6 ve 0 rakamları 8'e benzediği için onlara da bir olasılık değeri atandığı Şekil 3.9'da gösterilmektedir.




Şekil 3.9 Softmax fonksiyonu kullanarak rakam tanıma örneği (Yılmaz ve Kaya, 2021)

3.2.5 Katmanlar

DÖ modelleri katmanlardan oluşur. Bu katmanlar üçe ayrılır giriş katmanı veriyi alır. Çıkış katmanı ise veri ile ilgili çıktıyı oluşturur. Buna ek olarak, giriş katmanı ile çıkış katmanı arasındaki bağlantıyı sağlayan gizli katmanlar da bulunmaktadır.

Ağdaki süreç girdi katmanı ve çıktı katmanı arasında ilerler. Bunlara gizli katmanlar denir. Gizli katmanlar girdileri alıp, belirli görevleri uyguladıktan sonra oluşan çıktıyı bir sonraki katmana aktaran katmanlardır. Gizli katmanların sayısı veriye göre ayarlanır ve genelde birden fazladır. Bu yüzden DÖ adı da buradan gelir.

Katman sayısı veriye göre seçilir. Genelde nöron sayısı çıktı katmanı haricinde 2'nin katları şeklindedir. Çıkış katmanındaki nöron sayısı ise genelde sınıflandırmadaki sınıf sayısı kadardır. Şekil 3.10'da derin sinir ağının giriş, çıkış ve çoklu gizli katmandan oluşan yapısı sembolize edilmiştir.



Şekil 3.10 Basit YSA ve DÖ sinir ağı (Anonim 2023a)

3.2.6 Çok katmanlı algılayıcı

Çok katmanlı algılayıcı (ÇKA), DÖ alanında yaygın olarak kullanılan bir YSA türüdür. Bu algoritma, birçok girdi ve çıktı arasında karmaşık bir bağlantıyı öğrenmek için tasarlanmıştır. ÇKA'lar genellikle sınıflandırma ve regresyon problemlerinde kullanılır. Bu tür ağlarda her bir katmanda birden fazla nöron bulunmakta ve tüm katmanlardaki nöronlar kendisinden sonraki katmanlarda bulunan nöronlar ile bağlantılıdır.

Basit bir YSA'da bir giriş, bir gizli katman ve bir de çıktı katmanı bulunurken, DÖ ağında birden fazla gizli katman bulunmaktadır. ÇKA'lar sinir ağlarında çıktı değerinin doğruluğunu artırmada önemli bir rol oynamaktadır.

3.2.7 Kayıp fonksiyonu

Oluşturulan ağda amaç gerçek değerlere en yakın çıktıları tahmin edebilmektir. Ağın doğruluğu kayıp (maliyet) fonksiyonu kullanılarak hesaplanmaktadır. Başka bir ifadeyle,


model tahminlerinin gerçek değerlerden ne kadar farklı olduğu kayıp fonksiyonuyla hesaplanır. Ağırlıklandırılmasıyla kayıp fonksiyonunun minimize edilmesi amaçlanır. Kayıp fonksiyonunun hesaplanmasında kullanılan hata ölçütleri OH, OMH, OKH, OKHK ve OMYH'dir.

Ayrıca bir ölçütte çok iyi sonuç veren bir çalışma başka bir ölçütte iyi sonuç vermeyebilmektedir. O nedenle, yapılan bir çalışmanın başarısını belirlemek için birden fazla ölçüt sonucunun hesaplanarak değerlendirmeye tabi tutulmasında fayda bulunmaktadır.

3.2.8 Eğimli iniş

Eğimli iniş (gradient descent), bir optimizasyon algoritmasıdır. MÖ alanında model parametrelerini güncellemek için kullanılan eğimli iniş, bir fonksiyonun (ağırlık değerinin) minimum veya maksimum noktasını bulmak için iteratif bir yaklaşım sergilemektedir (Şekil 3.11).

Algoritma, bir başlangıç noktasından başlayarak, her adımda fonksiyonun eğimine (gradyanına) göre doğru ağırlığı (w) bulmaya çalışmaktadır. Eğim, fonksiyonun belirli bir noktadaki değişim hızını temsil etmektedir. Eğimli iniş, eğimin negatif yönünde ilerleyerek fonksiyonun minimum noktasına yaklaşmaktadır. Eğimli iniş algoritması her adımda eğimi hesaplamakta ve bu eğim doğrultusunda parametreleri güncellemektedir. Bu güncelleme, fonksiyonun minimum noktasına doğru yaklaşmayı sağlamaktadır. Algoritma, belirli bir durma kriterini sağladığında durmaktadır. Örneğin, belirli bir iterasyon sayısı veya maliyet fonksiyonunun belirli bir değerine ulaşıldığında iterasyon durmaktadır. Bu algoritma, modelin maliyet fonksiyonunu minimize etmek için kullanılmaktadır. Bu sayede, model daha iyi tahminler yapabilmekte ve performansını artırmaktadır.




Şekil 3.11 Eğimli iniş (Anonim 2023b)

3.2.9 Öğrenme oranı


Kayıp fonksiyonunu minimize etmek için yapılan, her tekrar sayısında (iterasyon) elde edilen en aza indigeme miktarı, öğrenme oranı olarak ifade edilmektedir. Şekil 3.12’de farklı öğrenme oranları gösterilmektedir.

DÖ öğrenme oranı, ağıın öğrenme hızını belirleyen önemli bir hiperparametredir. Hiperparametreler, MÖ modellerinin performansını etkileyen ve kullanıcının belirlediği ayarları ifade etmektedir. Öğrenme oranı, ağıın hızlı veya yavaş öğrenmesini belirlemektedir. Yüksek öğrenme oranı, hızlı öğrenmeyi sağlar ancak ağı kararsız hale getirebilmektedir. Düşük öğrenme oranı ise daha istikrarlı bir ağı oluşturur ancak daha uzun sürelerde eğitim gerektirebilmektedir. Doğru öğrenme oranının seçimi, DÖ modelinin başarısı için kritik öneme sahiptir ve dikkatle belirlenmelidir.



Şekil 3.12 Öğrenme oranı seviyeleri (Yılmaz ve Kaya 2021)

Öğrenme oranı eğitim esnasında geri dönüşler ile en doğru aktivasyon fonksiyonunu elde etme esnasında önemli bir etkindir. Yanlış bir öğrenme oranı YSA'nın yanlış öğrenmesine de neden olabilir. Doğru bir öğrenme oranı hem yazılım optimizasyonu hem de doğru bir öğrenmeye gidebilmek için önem taşımaktadır. Büyük veya küçük öğrenme oranı öğrenememeye neden olur (Şekil 3.13).




Şekil 3.13 Öğrenme Oranı ve Gradyan İniş (Anonim 2023c)

YSA optimum noktayı bulma problemidir ve öğrenilmiş en doğru nokta Şekil 3.13'deki eğrinin en alt noktasıdır. Bu noktaya ulaşacak parametrelerin belirlenmesi hedeflenmektedir (Şeker 2021).

3.2.10 İleri ve geri yayılım


İleri ve geri yayılım algoritması, bir YSA'nın öğrenme sürecinde oldukça etkilidir. Bu algoritma sayesinde, YSA daha iyi tahminler yapmayı öğrenir ve performansını artırır.

İleri yayılım, YSA'nın öğrenme sürecindeki bir adımdır. Bu adımda, YSA'nın girdi katmanından başlayarak çıktı katmanına kadar ilerleyen bir işlem gerçekleştirilir. İleri yayılım sırasında, her katmandaki nöronlar, önceki katmandaki nöronların çıkışlarına dayalı olarak hesaplanır. Bu hesaplama işlemi, ağırlıklar ve sapmalar ile gerçekleştirilir. Her nöronun çıkışı, aktivasyon fonksiyonu tarafından belirlenir ve bu çıkışlar, bir sonraki katmanda girdi olarak kullanılır (Şekil 3.14) (Şeker 2021).



Şekil 3.14 İleri Yayılım (Forward Propagation) (Şeker 2021)

Geri yayılım algoritması, önce ileri yayılım işlemiyle YSA'nın çıktısını hesaplar. Daha sonra, hedef çıktılarla gerçek çıktılar arasındaki farkı hesaplar ve bu hatayı geriye doğru katmanlara doğru yayarak ağırlıkların ve sapmaların güncellenmesini sağlar (Şekil 3.15) (Şeker 2021).



Şekil 3.15 Geri Yayılım (Back Propagation) (Şeker 2021)

3.2.11 Yığınlar

Yığınlar verinin büyüklüğüne bağlı olarak kullanılır. Büyük veri kümeleriyle çalışırken tüm verilerin aynı anda işlenmesi zaman alıcı olabilir ve bellek sınırlamalarına yol açabilir. Bu nedenle veriyi daha küçük parçalara bölüp, her parçayı ayrı ayrı işlemek daha etkili bir yaklaşımdır.

Yığınlar eğitim sırasında modelin parametrelerini güncellemek için kullanılır. Bir yığın işlendiğinde, modelin çıktıları hesaplanır, hata fonksiyonu değerleri elde edilir ve bu değerlere göre modelin parametreleri güncellenir. Ardından bir sonraki yığın işlenir ve bu süreç tekrarlanır. Bu şekilde model yavaş yavaş veri setinin genel yapısını öğrenir.

Yığınlar eğitim sürecini hızlandırabilir ve bellek kullanımını optimize edebilir. Ayrıca, stokastik gradyan iniş gibi optimizasyon algoritmalarında da kullanılabilir. Yığın boyutu, bir denge noktasıdır; çok küçük bir yığın boyutu modelin kararlılığını azaltabilirken, çok büyük bir yığın boyutu eğitim süresini uzatabilir. Optimal yığın boyutu, veri seti ve modelin karmaşıklığına bağlı olarak değişebilir.

3.2.12 Epok sayıları

Epok (epoch) sayısı, DÖ modellerinde eğitim sürecinin kaç kez tekrarlandığını ifade eder ve modelin eğitim veri seti üzerinde ne kadar çalışacağını belirlemektedir. Bir epok, modelin tüm eğitim veri seti üzerinde bir kez çalıştığı zamandır. Epok sayısı, veri setinin boyutuna ve modelin karmaşıklığına bağlı olarak değişebilir. Daha büyük veri setleri ve daha karmaşık modeller, daha fazla epok sayısı gerektirebilir. Epok sayısının belirlenmesi, modelin doğru bir şekilde eğitilmesi için önemlidir.


Eğitim süreci, veri setinin yığınlar halinde işlenmesiyle gerçekleştirilir. Bir epok boyunca, model tüm yığınları işler ve her bir yığın sonrasında parametreleri günceller.

Epok sayısı, modelin performansını etkileyebilir. Eğer epok sayısı çok düşükse, model yeterince eğitilmez ve veriler üzerinde iyi bir performans gösteremez. Ancak, epok sayısı çok yüksekse, model aşırı öğrenme yapabilir ve yeni veriler üzerinde iyi sonuçlar veremeyebilir.

3.2.13 Bırakma

Ağın aşırı uyum göstermesini önlemek için kullanılan bir standartlaştırma tekniğidir. Eğitim sırasında gizli katmandaki belirli sayıdaki nöronun rastgele devre dışı bırakılmasıdır (Şekil 3.16).

Bırakma işlemi ağın aşırı öğrenmesine de engel olarak iyi bir öğrenme oranının yakalanmasına katkı sunmaktadır. Ayrıca bırakma işlemi ağın genelleştirme yeteneğini de artırarak, aşırı öğrenmeye engel olmaktadır. Böylece ağın test verileri üzerinde daha iyi performans göstermesi sağlanmış olur.



Şekil 3.16 Bırakma uygulanmadan önce ve sonra sinir ağının yapısı (Yılmaz ve Kaya 2021)

3.2.14 Yığın normalizasyonu

Yığın normalizasyonu (batch normalization), DÖ modellerinde kullanılan bir normalizasyon tekniğidir ve her bir eğitim yığınınındaki özelliklerin ortalamasını sıfıra ve standart sapmasını bir birime dönüştürerek verinin dağılımını stabilize etmeyi amaçlamaktadır. Ağın her katmanında yığın normalizasyonu yer alabilmektedir. Her bir yığın için, özelliklerin ortalaması ve standart sapması hesaplanmaktadır. Ardından, bu hesaplamalar kullanılarak özellikler normalize edilmekte, böylece eğitim patlaması ve kaybolması sorunu azalır ve ağ daha kararlı hale gelerek, eğitimlerin daha tutarlı olması sağlanmış olur. Bu şekilde daha hızlı ve daha istikrarlı bir eğitim süreci ortaya çıkmaktadır. Ağın daha hızlı öğrenmesinde yığın normalizasyonunun da etkisi vardır. Normalize edilmiş özellikler, daha uygun bir aralıkta olduğu için, optimizasyon algoritmaları daha etkili bir şekilde çalışmaktadır. Regülerizasyon etkisi ile modelin genelleştirme yeteneğinin artırılarak, aşırı öğrenmenin engellenmesi de yığın normalizasyonu ile mümkün olmaktadır. Ancak, yığın normalizasyonunun her durumda faydalı olacağından söz edilemez, modelin özelliklerine göre bu durum değişebilmektedir.

3.2.15 Evrişimli (Konvolüsyonel) sinir ağıları

ESA'lar, DÖ alanında yaygın olarak kullanılan bir sinir ağı mimarisidir. Özellikle görüntü işleme gibi alanlarda başarılı sonuçlar verir. ESA'lar, veri üzerinde konvolüsyon (convolution) işlemi yaparak özelliklerin ortaya çıkarılmasını sağlar. Bu işlem, filtrelerin girdi veri üzerinde kaydırılması ve her bir konumda bir çıktı değeri üretilmesi esasına dayanmaktadır. Bu sayede, görüntülerdeki özellikler (kenarlar, köşeler, desenler vb.) tespit edilebilir.

ESA'da ilk katmanlar, girdi veriyi alır ve filtrelerle konvolüsyon işlemini gerçekleştirir. Ardından, aktivasyon fonksiyonları (relu gibi) ve havuzlama (pooling) işlemleri kullanılarak özellik haritaları oluşturulur. Son katmanlarda ise bu özellik haritalarını sınıflandırma veya tahmin yapma gibi görevler gerçekleştirilir.

3.2.16 Havuzlama

Havuzlama (pooling), görüntü işleme ve sinir ağı mimarilerinde kullanılan bir işlemdir. Özellik içeren haritaların boyutunu azaltarak hesaplama yükünü azaltır ve aynı zamanda özelliklerin öğrenilmesi havuzlama işlemi sayesinde mümkün olmaktadır. Veri üzerinde bir pencere (genellikle 2×2 boyutunda) kaydırılarak her bir bölgeden tek bir çıktı değeri üretilir. Bu çıktı değerleri, sonraki katmanda girdi olarak kullanılır.

Havuzlama işlemi, özellikle görüntü işleme uygulamalarında sıklıkla kullanılmakta, görüntülerdeki özelliklerin boyutunu azaltıp, hesaplama yükünü azaltmakta ve aynı zamanda özelliklerin öğrenilmesini sağlamaktadır. Sinir ağı mimarilerinde ise havuzlama sayesinde, özelliklerin boyutu azaltılarak modelin daha hızlı öğrenmesi sağlanır ve aynı zamanda modelin genelleştirme yeteneği artırılır.

3.2.17 Dolgu

Çıktı görüntüsünün girdi ile aynı boyutta olması için görüntülerin karşısına (köşelerine) fazladan sıfır veya başka bir değer katmanının eklenmesine dolgu denilmektedir. Bu işlem, genellikle konvolüsyon işlemi öncesinde kullanılır ve girdi verinin boyutunu koruyarak, çıktı verinin boyutunu kontrol etmektedir.

Dolgu işlemi sınırlardaki veri kaybını engellemek için de kullanılmaktadır. Ayrıca daha çok görüntü işlemede kullanılan dolgu işlemi ile kenar piksellerinin gereğinden fazla vurgulanması da önlenmiş olur.

3.2.18 Veri çoğaltma

Veri çoğaltma ile mevcut veri kümesini çeşitli dönüşümler ve manipülasyonlarla genişleterek daha fazla eğitim örneği elde etme amaçlanır. Bu yöntem, modelin genelleme yeteneğini artırır ve aşırı uyum (overfitting) sorununu azaltmada işe yarayabilmektedir.

Ayrıca veri çoğaltma ile modelin farklı varyasyonları görmesi sağlanarak, daha genel ve daha iyi bir performans elde etmesi de hedeflenir.

3.2.19 Yinelemeli sinir ağları

Yinelemeli Sinir Ağları (YiSA), önceki adımlardan gelen bilgiyi hafızalarında tutarak sıralı verilerin bağlamsal ilişkilerini modelleyebilen ve geri besleme döngüsü ile çalışan ağlardır. Her adımda, bir girdi verisi alınır ve önceki adımlardan gelen bilgiyi de içeren bir çıktı üretilir. Bu çıktı, bir sonraki adımda tekrar girdi olarak kullanılır ve bu döngü sürekli olarak devam eder. Bu tür ağlar, sıralanmış bir şekilde verileri işlemek için dizayn edilmiş sinir ağları olduğu için, $x_1, \dots, x_r$ gibi sıra oluşturan verileri işlemek için özelleştirilmiştir (Rumelhart vd., 1986a).

ESA'lar bir matrise sahip görüntülere ölçeklenebilir ya da çok değişken boyutlardaki görüntüleri işleyebilmektedir. Bunun gibi YiSA'lar da sıra bazlı veriler için özelleşmiş olmayan ağların işleyebileceğinden daha büyük sıralı dizilere ölçeklenerek, bu dizileri işleyebilmektedir.

3.2.20 Kaybolan eğim problemi

Kaybolan eğim problemi (vanishing gradient problem), DÖ modellerinde özellikle YiSA gibi uzun süreli bağımlılıkların önemli olduğu modellerde karşılaşılan bir sorundur. Bu sorun, bir YiSA'nın eğitim sırasında, geriye doğru hesaplama yaparken, bazı katmanlarda eğim (gradient) değerlerinin çok küçük olması veya sıfıra yakın olması nedeniyle, bu katmanların güncellenememesi veya güncellenmesinin çok yavaş olmasıdır.

Eğim bir fonksiyonun belirli bir noktadaki eğimini ve yönünü temsil etmektedir. Eğim değerlerinin küçük olması, ağırlıkların doğru şekilde güncellenememesine ve sonuç olarak modelin yanlış sonuçlar üretmesine neden olabilmektedir.

3.2.21 Patlayan eğim problemi

Patlayan eğim problemi (exploding gradient problem), DÖ modellerinde özellikle YiSA gibi uzun süreli bağımlılıkların önemli olduğu modellerde karşılaşılan bir sorundur. Bu sorun, bir YiSA'nın eğitimi sırasında, geriye doğru hesaplama yaparken, bazı katmanlarda eğim (gradient) değerlerinin çok büyük olması nedeniyle, bu katmanların güncellenememesi veya güncellenmesinin çok hızlı olmasıdır.

Eğim değerlerinin çok büyük olması, ağırlıkların doğru şekilde güncellenememesine ve sonuç olarak modelin yanlış sonuçlar üretmesine neden olabilmektedir.

3.2.22 Derin öğrenme kütüphaneleri

DÖ kütüphaneleri, modeller oluşturmak, eğitmek ve test etmek için gerekli olan araçları sağlamaktadır. Bu kütüphaneler matematiksel işlemleri gerçekleştirmek ve DÖ algoritmalarını uygulamak için geliştirilmiştir.

Çok sayıda DÖ kütüphanesi bulunmakta ve zamanla yenileri de eklenmektedir. En çok kullanılan kütüphaneler Pytorch, TensorFlow, Caffe, Keras, DeepLearning4J ve OpenAI Gym'dir. Ayrıca görüntü işleme için OpenCV, vektörel işlemler için Numpy, MÖ için Scikit-Learn, veri analizi için Pandas, veri görselleştirme için Matplotlib kullanılmaktadır.


3.2.23 Derin öğrenme algoritmaları

DÖ algoritmaları öğrenmek suretiyle, büyük veri setlerindeki karmaşık desenleri tanımlamak, sınıflandırmak veya tahmin etmek için kullanılır.

DÖ için 3 çeşit YSA türü literatürde yer almaktadır. Bunlar; Tekrarlayan Sinir Ağları (TSA), ESA ve UKDB'dir. ESA'lar genellikle görüntü işleme çalışmalarında kullanılmaktadır. TSA'larda ise ardışık bilgileri kullanmak amaçlanmaktadır. Daha çok doğal dil işleme çalışmalarında kullanılır. UKDB'ler ise özellikle zaman serisi verileri veya uzun bağımlılıkların olduğu problemlerde etkilidir.

3.2.24 Karar ağaçları, rastgele orman ve gradyan hızlandırma makineleri

Karar ağaçları verileri sınıflandırmaya veya girdilerden beklenen çıktıları tahmin etmeye imkân veren akış diyagramlarına benzeyen yapılardır (**Şekil 3.17**). Bu metot ile görselleştirmek ve yorumlamak oldukça kolay olmaktadır. Karar ağaçları 2000'lerde oldukça fazla araştırmaya konu olmuş ve 2010'lara kadar genellikle kernel metotlarında tercih edilmiştir.



Şekil 3.17 Karar ağacı yönteminin çalışma prensibi (Anonim 2023e)

Özellikle de rastgele orman algoritması birden fazla karar ağacını ve sonuçlarını birleştirerek karar ağacı öğrenmesine uygulanabilir ve sıhhatli bir çözüm olarak ortaya çıkmıştır. Rastgele orman algoritması çok geniş bir uygulama alanı olmasıyla sığ MÖ görevleri düşünüldüğünde en iyi ikinci algoritma olmuştur. Rastgele ormanlar 2014 yılında gradyan hızlandırma makinelerinin ortaya çıkışına kadar en yaygın kullanılan algoritmaydı.

Rasgele orman algoritması doğruluk oranı bakımından toplu öğrenme algoritmalarına göre daha yüksek doğruluk oranı verdiği için daha çok tercih edilmektedir. Bu algoritma hızlı çalışması ve doğruluk oranının yüksekliği nedeniyle tercih edilmektedir (Akar ve Güngör, 2013).

Rasgele orman gibi karar ağaçlarını kullanan MÖ modellerinden biri de gradyan hızlandırma makineleridir. Gradyan hızlandırması şeklinde ifade edilen ve herhangi bir MÖ modelinin yinelemeli olarak zayıf yanlarını kapatan yeni modeller eğiten bir yaklaşım sunarlar. Karar ağaçlarına uygulandıklarında çoğunlukla karar ağaçlarından daha iyi performans sunarlar, aynı işlevselliği gösterirler. Bilişsel olmayan

problemlerde en iyi olmasalar bile hala yüksek performans gösteren algoritmalarındandır. Kaggle yarışmalarında DÖ'nün yanında en çok kullanılan tekniklerdir.

3.2.25 Alan kayması

Alan kaymasını (Domain shift) Baydilli (2020); Storkey vd. (2008), Ben-David vd. (2006), Gong vd. (2013), Csurka (2017), Patel vd. (2015), Zhang vd. (2019), Pan ve Yang (2010)'den aktararak anlatmıştır. MÖ yöntemleri, eğitim ve test verilerinin aynı kaynaktan gelmesi ve bağımsız ve aynı dağılıma sahip olması durumunda yüksek başarı elde edebilmektedir (Ben-David vd. 2006). Ancak eğitim ve test verileri arasındaki farklılıklar, modelin başarısız sonuçlar üretmesine neden olabilmektedir. Bu farklılıklar, verinin elde edilme sürecinde kullanılan farklı görüntüleme araçlarından kaynaklanabilmektedir (Storkey vd. 2008). Özellikle görüntülerin parlaklık, yakınlık-uzaklık, arka plan gibi kendine has özellikleri, sınıflandırmaya olumsuz etki yapabilir (Gong vd. 2013), (Csurka 2017). Bu problem, literatürde “domain değişimi” veya “veri seti değişimi” olarak adlandırılır (Storkey vd. 2008), (Patel vd. 2015). Araştırmacılar tarafından uzun yıllardır üzerinde çalışılan bu problemi çözebilmek için geçmişten günümüze birçok yöntem önerilmiştir (Zhang vd. 2019). Bu sorunun üstesinden gelmek için transfer öğrenme ve domain adaptasyonu gibi yöntemler önerilmektedir (Pan ve Yang 2010).

Alan kayması problemine Baydilli (2020) fotoğraf makinesi ile çekilen görüntüler örneği ile açıklamıştır. Taşıt sınıflandırma problemi çözümü için eğitilmek üzere herhangi bir fotoğraf makinesi ile çekilen taşıt fotoğrafları YSA eğitiminde kullanılmış olması varsayımıyla hareket edilmiştir. YSA eğitildikten sonra, test etmek üzere başka bir fotoğraf makinesi ile çekilen taşıt görüntüleri kullanılmış olsa YSA'nın başarısı hiç de tatminkâr olmayacaktır. Zira her iki fotoğraf makinesinin parlaklık, yakınlık-uzaklık, arka plan gibi çekim yapma özellikleri farklıdır. Yani eğitim yapılan veri seti ile test edilen veri setinin farklı kaynaklara ait olması YSA'nın başarısını düşüren önemli bir etken olarak ortaya çıkacaktır.

3.3 Derin Öğrenme Modeli Geliştirmenin Aşamaları

DÖ tekniklerini başarılı bir şekilde uygulamak için hangi algoritmaların var olduğunu ve bu algoritmaların nasıl çalıştığını anlatan prensipleri iyi bilmekten daha fazlası gerekir. İyi bir DÖ uygulayıcısının bir uygulama için gerekli algoritmayı nasıl seçeceğini, deneylerden elde edilen geri beslemeleri, DÖ sistemini geliştirmek için nasıl gözlemleyeceğini ve cevaplandıracağını bilmesi gereklidir.

Bir DÖ modelinin geliştirilmesi, algoritmanın aşamalarına bağlıdır. DÖ eldeki verilerden yola çıkarak yeni şeyler öğrenebilen algoritmalar. Fakat burada öğrenme ile kastedilenin ne olduğunu Mitchell (1997) şöyle açıklamaktadır; bir bilgisayar programının performans göstergesi P, T görevleri ile belirlenmiş E deneyimleri üzerine tanımlanmış olsa ve eğer bu programın P performansı T görevlerinde E deneyimleri ile artıyorsa, bu yazılımın öğrenme yeteneği olduğu anlamına gelmektedir. Bu öğrenme süreci, farklı E deneyimleri, T görevleri ve P ölçütleri ile tasarlanabilmektedir.

Genel bir DÖ algoritmasının işlem adımları sırayla aşağıda listelenmiştir.

1. Bütün ağ rasgele sayılarla (sıfıra yakın ama sıfırdan farklı) ilklendirilir.
2. Veri kümesinden ilk satır (her öznitelik bir nöron olacak şekilde) giriş katmanından verilir.
3. İleri yönlü yayılım yapılarak, YSA istenen sonucu verene kadar güncellenir. İstenen çıktı elde edilene kadar ağırlıklar (weight) güncellenir.
4. Gerçek ve çıktı arasındaki fark alınarak hata (error) hesaplanır.
5. Geri yayılım yapılarak, her sinapsis üzerindeki ağırlık, hatadan sorumlu olduğu miktarda değiştirilir. Değiştirilme miktarı ayrıca öğrenme oranına da bağlıdır.
6. 1-5 arasındaki adımları istenen sonucu elde edene kadar güncellenir (takviyeli öğrenme (reinforced learning)) veya eldeki bütün veriler ilgili ağda çalıştırıldıktan sonra bir seferde güncelleme yapılır (yığın öğrenme (batch learning))
7. Bütün eğitim kümesi çalıştırıldıktan sonra bir epok (epoch) tamamlanmış olur. Aynı veri kümeleri kullanılarak çağ/tur tekrarları yapılır.

Girdi katmanı girdileri (öznitelik verileri) dışında iki tür girdi daha bulunmaktadır. Bunlardan birincisi öğrenme oranı (learning rate), diğeri ise epok sayısıdır. Öğrenme oranı ne kadar hızlı öğreneceğini belirler. Epok ise, verileri verdikten sonra en doğru sonucu elde etmek için kaç tur atılacağıdır. Genelde giriş (input) olarak bu iki parametre YSA'ya verilir. Çünkü sistem öğrenmek için kaç tur atacağını, ne kadarlık bir öğrenme oranı uygulayacağını bilmelidir. Yoksa sistemin kendi içinde gelgitler yaşayarak sonsuz döngüye girme olasılığı vardır. Verilen bu girdiler sonucunda YSA öğrenebildiği kadar öğrenecektir. Burada epok sayısı çok verilirse, belki de zaten ulaştığı öğrenmeyle YSA'yı tekrar tekrar çalıştıracaktır. Epok sayısı az verilirse YSA öğrenmeyi tamamlamadan sonlanmış olacaktır. Bu noktada iş veri bilimcisine düşmekte ve parametre değerleri denenerek sahada bulunmalıdır (Şeker 2021).

Sonuç olarak DÖ'de bir modele giriş verisi verilir. Modelden geçer ve bir çıktı alınır. Örneğin; resimde kedi olup olmadığını tahmin eden bir modelde resimler veridir. Resimde kedinin bulunma ihtimali ise modelin çıktısıdır. Ayrıca modele, veri ile birlikte insan tarafından oluşturulan etiketler de verilir. Etiketler ise resimde kedinin olup olmadığını belirtmektedir. DÖ'nün temel amacı etiketler ile çıktının olabildiğince birbirine yakın olmasını sağlamaktır.

3.3.1 Veri toplama

Veri toplama aşamasında istenen amaca yönelik veri toplanır. En önemli aşamalardan birisidir çünkü genelde veri ne kadar iyi ve çeşitli olursa modelin başarılı olma ihtimali de o kadar yüksek olur.

Veri toplandıktan sonra veriye etiketleme işlemi yapılır. Ayrıca veriyi modele yüklemekten önce yapılması gereken işler genelde bu aşamada yapılır.

3.3.2 Veriyi hazırlama

Verilerin ön işlenmesi ham verileri sinir ağlarının kullanabileceği hale getirme işlemidir. Ön işleme vektör hâline getirme, normalize etme, eksik verilere yapılacak

işlemler ve niteliklerin vektörel hâle getirilmesini içerir. Vektör hâline getirme işleminde, sinir ağlarını besleyen tüm veri ve hedefler ondalık sayı tensörleri olmalıdır. Ses, görüntü ya da metin gibi elde hangi veri olursa olsun ilk aşama veriyi tensörlere dönüştürmektir. Bu işleme vektör hâline getirme denir. Sayı sınıflandırma ve ev değeri gibi tahmin örneklerinde veriler zaten vektör biçiminde olduğundan bu aşama atlanır.

Hazırlanan veri seti bu aşamada modele yüklenir. Ardından bu veri setine bazı işlemler uygulanır. Örneğin resimler genelde 0 ile 1 arasında normalize edilir. Bu aşamada yapılanlar genelde kod ile yapılır. İlk aşamadan farkı budur. İlk aşamada yapılan işlemler kod olmadan elle yapılır. Son olarak da veri 3'e ayrılır. Bunlar eğitim seti doğrulama seti ve test setidir. Bunların hangi oranda ayrılacağı genelde veri sayısına göre değişmektedir. Örneğin veri çok fazla ise %98 eğitim seti, %1 doğrulama seti, %1 test seti gibi bir dağılım olabilir. Ayrıca birçok çalışmada %80 eğitim seti, %20 test seti gibi bir dağılım da yapılmaktadır. Fakat aslında doğrusu veriyi 2 değil, 3 parçaya ayırmaktır.

Ön hazırlık işlemleri değerlerin normalize edilmesini de içermektedir. Değerlerin normalize edilmesi işleminde, konut değer tahmin örneği ele alınacak olursa evin nitelikleri farklı tiplerde ve aralıklarda olduğundan sinir ağını beslemeden önce değişken değerlerinin ortalaması 0 (sıfır) ve standart sapması 1 (bir) olacak şekilde normalizasyonu yapılır. Genelde çok büyük değerler (örneğin; ağırlıklarından çok daha büyük birden çok basamaklı tam sayılar) ya da heterojen (örneğin; bir niteliğin 0-1 aralığında başka bir niteliğin ise 100-200 aralığında olması) veriler ile sinir ağlarının beslenmesi güvenli değildir. Bunları yapmak ağırlık çok büyük gradyan güncellemeleri yapmasına neden olacağından yakınsamasına imkân vermeyecektir. Ağırlık daha kolay öğrenmesi için, küçük değerler kullanılarak, değerlerin genel olarak 0-1 aralığında olması sağlanmalıdır. Ayrıca değişken aralıkları da kabaca aynı aralıkta ve homojen olmalıdır.

Ek olarak; bazı normalizasyon adımları her ne kadar her zaman gerekli olmasa da hem çok yaygın olarak kullanılmakta, hem de oldukça yardımcı olmaktadır. Örneğin, tüm niteliklerin kendi içinde ortalamasını 0, standart sapmasını 1 yapmak, bu anlamda olumlu sonuç verebilmektedir. Bu işlem numpy dizileri ile kolayca yapılabilmektedir.

Bazen verilerde eksik değerler olabilmektedir. Genelde sinir ağlarında eksik değerleri 0 ile doldurmak emniyetli bir seçenek olarak tercih edilmektedir. Ancak bu durumda 0 anlamlı bir değere karşılık gelmemelidir. Çünkü bir süre sonra ağ 0 değerlerin eksik veriler için olduğunu anlayacak ve 0 değerlerini göz ardı etmeye başlayacaktır. Eksik verileri tamamlama imkânı yok ise, ayrı bir kategori oluşturmak da bir çözümdür.

3.3.3 Model oluşturma

Bu aşamada sıfırdan bir model oluşturulur. Model oluşturulurken, modelin veriye uygun olmasına dikkat edilmelidir. Örneğin; veriler resim ise, bu durumda evrişim katmanları kullanılmalı ya da veriler fazla karmaşık değil ise, bu durumda daha basit bir model oluşturmak mantıklıdır. En baştan bir model oluşturmak yerine hazır bir model seçilip, bu modelde değişiklik yaptıktan sonra da bu model kullanılabilir.


Modeli oluştururken modelin katman sayısı, katmanlardaki nöron sayısı, optimizasyon algoritması (optimizer), kayıp fonksiyonu gibi birçok seçim yapmak gerekir. Bu aşamada en iyi sonuca götürecek seçimleri yapmak önemlidir. Genelde deneme yanılma yöntemi ile doğrulama setindeki modelin başarısına göre seçimler yapılır. Hangi kombinasyonlar en iyi sonucu veriyorsa nihai model buna göre oluşturulur.

3.3.4 Modeli eğitme

Modeli eğitme aşamasında, eğitim seti kullanılarak model eğitilir. Modeldeki parametreler ilk başta rastgele değerlere sahiptir. Fakat bu değerler eğitim süresince değişir. Bu değişim modelin veri seti üstünde yaptığı tahminlerin daha iyi olması yönünde gerçekleştirilir. Yani eğitim devam ettikçe model daha iyi sonuç vermeye başlamaktadır. Çünkü parametreler daha iyi sonuç verecek şekilde güncellenmektedir.

Örneğin; boy ve kilo girdilerinden yola çıkarak cinsiyet tahmini gerçekleştirmeye çalışan bir YSA ağırlık (w) değerini her satır veride deneyerek bulmaya çalışır. Algılayıcı (perceptron) ise tahmin edilen cinsiyet ile tahmin edilen değer arasındaki farkı geri

beslemek için kullanır. Yani cinsiyet tahmini yapıldıktan sonra, sonuç doğru ise bu nöronda artık hiçbir değişiklik yapılmaz, artık burada öğrenilecek hiçbir şey yoktur, tahmin doğru yapılmıştır. Ama doğru değilse, yani tahmin ile gerçek arasında bir fark varsa, YSA bu bilgiyi geri yansıtır, ağırlıkları değiştirerek doğru sonucu bulmaya çalışır. Gerçek değer değişmez ama tahmin edilen değer değişir. Zaten amaç da tahmin ile gerçek değer arasındaki farkı sürekli deneyerek azaltmaktır (Şekil 3.18).



Şekil 3.18 Algılayıcı (Şeker 2021)

YSA eğitilirken ağırlık rastgele verilir. Rastgele çok hatalı bir ağırlık verilmiş olsa bile, YSA doğru ağırlığı bulmaya çalışmaktadır. DÖ'deki Güçlendirme Öğrenmesi (Reinforcement Learning) veya Uyarlamalı Öğrenmenin (Adaptive Learning) amacı da zaten en iyi sonucu elde etmektir. Çok kötü bir algoritmayla, çok kötü bir yerden başlansa bile, sistem zaman içinde kendini iyileştirerek daha iyi bir konuma gelecektir. Dolayısıyla en kötü eşik değeri ve en kötü ağırlıklar verilse de sistem kendisini eğiterek daha iyi bir yere gelmeye çalışacaktır.

3.3.5 Modeli doğrulama

DÖ’de önemli olan YSA’nın eğitimden sonra daha önce hiç görmediği test verisinde nasıl bir başarı sağladığıdır. Dolayısıyla, DÖ’de eğitim verileri ile alınan sonuçların, test verileri için de alınması gereklidir. DÖ uygulayıcıları sürekli yeni algoritmaları uygulamak suretiyle eğitim ve test verileri üzerinde en iyi sonucu elde etmeye çalışır.

Veri temelde aslında eğitim ve test olmak üzere ikiye bölünür ancak eğitim verisi de kendi içinde eğitim ve doğrulama olacak şekilde ikiye bölünür. Dolayısı ile veri eğitim, doğrulama ve test olmak üzere 3 parçaya bölünmüş olur. Eğitim verisi ile eğitilen DÖ modeli doğrulama verisi ile doğrulanır, test verisi ile test edilmiş olur ve sonuç olarak model yeni gelecek veriler için hazır hâle getirilmiş olur. Düzenleştirme olarak tanımlanan bu etkinlik sürekli geliştirmeyi gerektirmektedir.

Model oluşturulurken doğrulama ve test verileri üzerinde parametre uzayında en iyi sonucu verenler tespit edilmeye çalışılır. Bu ince ayarlar modelin doğrulama veri seti üzerinde verdiği geri bildirimlere göre yapılır. Bu ince ayar işlemi aslında bir çeşit öğrenmedir. Sonuç olarak, modelin doğrulama verisi üzerinde eğitilmemiş olmasına rağmen, doğrulama verisi üzerindeki performansına bakılarak yapılandırılması, modelin doğrulama verisini aşırı uydurmasına neden olmaktadır. Bu olgunun merkezine bakıldığında bilgi kaçağı olduğu görülmektedir. Modelin doğrulama verisi üzerindeki performansına bakılarak yapılan her ince ayar, doğrulama veri setinden modele doğru bilgi kaçağı oluşmaktadır. Bu ince ayar bir parametre için bir kere yapıldığında, çok küçük bir bilgi kaçağı olacağından elde hâlâ güvenilir bir model olmaktadır. Ancak her denemeden sonra doğrulama verisi üzerinde değerlendirme yapılır ve sonuçta model güncellendiğinde giderek artan bir şekilde doğrulama verisinden modele bilgi kaçağı meydana getirilmiştir.

Sonuç olarak model doğrulama verisi üzerinde en iyilendiği için doğrulama verisinde suni olarak çok iyi performans gösteren bir modele ortaya çıkmış olur. Aslında doğrulama verisinde değil, tamamen yeni verilerdeki performansa dikkat edilmelidir. Değerlendirme daha önce hiç görmediği bir veride yani test verisinde yapılmalıdır. Dolaylı bile olsa

model test verisi hakkında hiçbir bilgiye sahip olmamalıdır. Eğer model test verisindeki performansa bakılarak güncellenirse genelleştirmeye zarar verilmiş olur.

Verinin eğitim, doğrulama ve test olarak ayrılması apaçık görünse de özellikle de elde az veri olduğunda bunu yapmanın daha ileri ve kolay yolları bulunmaktadır. Bu yollar; hold-out doğrulama, k-fold doğrulama ve karıştırılmış döngüsel k-fold doğrulamadır.

Basit hold-out doğrulamada, verilerin bir kısmı test verisi olarak ayrılır, kalanıyla eğitim gerçekleştirilip, test verisi üzerinde değerlendirilir. Bilgi kaçaklarını engellemek için test verisinde model güncellenmemelidir. Dolayısıyla aynı zamanda doğrulama verisi de ayrılmalıdır. Bu yöntem en basit doğrulama protokolüdür ama bir zaafı vardır. Eğer eldeki veriler gösterimi sağlanamayacak kadar az ve sınırlı ise eğitim ve test verilerinin farklı karıştırma hallerinde sonuçlar birbirinden çok farklı performans gösteriyorsa bu duruma bir çözüm getirilmelidir. Çözüm k-fold doğrulama ve döngüsel k-fold doğrulama yöntemlerinden birinin kullanılmasıdır.

K-fold doğrulamada, veri kümesi K eşit parçaya bölünür ve her bir parça sırayla test verisi olarak kullanılırken, geri kalan $K - 1$ parça eğitim verisi olarak kullanılır. Bu işlem, her bir parçanın test verisi olarak kullanıldığı K farklı bölünme için tekrarlanır. Sonuç olarak, K farklı test hataları elde edilir ve bu hataların ortalaması genel model performansını temsil eder. Bu yöntem, eğer eğitim ve test veri setinin ayrılma şekli, modelin performansında belirli değişikliğe sebep oluyorsa, oldukça faydalıdır. Bu yöntem hold-out doğrulama gibi modelde ince ayar yapmak için doğrulama veri setinden muaf bırakmaz.

Karıştırılmış döngüsel k-fold doğrulama yöntemi, veri sayısı sınırlı olduğunda ve modelin yüksek hassasiyette değerlendirilmesi gerektiğinde kullanılır. K-fold doğrulama, veriyi K ayrı parçaya bölmek için önce tüm veri karıştırılır ve doğrulama birden fazla kez uygulanır. Son skor, k-fold doğrulama sonuçlarının ortalamasıdır. Ancak $K \times P$ (P döngü sayısı) kullanarak eğitme ve değerlendirme yapmak maliyetlidir.

3.3.6 Modeli test etme

Doğrulama aşamasını en yüksek başarı ile geçen model artık en son aşamaya gelmiştir. Burada model test verisi ile test edilir. Eğer başarısız olursa modelde iyileştirmeler yapılır. Eğer başarılı olursa model artık kullanıma hazırdır. Bazen test aşamasının yapılmadığı da olur. Yani test aşamasından önce model kullanıma hazırdır. Fakat doğru olan, modelin kullanıma çıkmadan önce test verisi üzerinde test edilmesidir. Kullanıma hazır model ile yeni veriler üzerine tahminler yapılabilir. Artık yeni verilerde etiket yoktur ve amaç da zaten budur. Eldeki veriler kullanılarak oluşturulan modelden etiketi bilinmeyen yeni verilerin değerlerinin bulunması istenir.


DÖ ile modelin oluşturulması, eğitilmesi ve test edilmesinden sonra eksik veya aşırı öğrenme sorunuyla karşılaşma olasılığı vardır. Eksik öğrenme (underfitting) modelinin veriyi öğrenememe durumudur. Yani veri ile etiket arasındaki ilişkiyi model yeterince anlayamaz. O yüzden model yanlış tahminlerde bulunur. Eksik öğrenme olup olmadığı modelin eğitim setindeki başarısına bakılarak anlaşılır. Eğer bu başarı oranı düşükse eksik öğrenme vardır. Aşırı öğrenme (overfitting) modeldeki genelleştirememe sorunudur. Yani model eğitim setinde başarılı iken yeni bir veri gördüğü zaman başarısız olmasıdır. Bu yüzden eğitim setindeki başarı ile test setindeki başarı arasında çok büyük fark oluşabilmektedir. Bu istenmeyen bir durumdur. Aşırı öğrenme ezberleme problemi olarak da bilinir. Yani model eğitim verisindeki başarısını artırmak için eğitim setinde olan ama aslında öğrenmemesi gereken özellikleri öğrenmeye başlar. Bu özellikler test setindeki verilerde olmayınca da test setinde başarısız olur. Bu durum şöyle bir örnekle açıklanabilir. Bir öğrenci sınava çalışırken konuları anlamak yerine defterindeki örnekleri inceleyip bunları ezberlerse ve sınavda o konu ile ilgili defterdeki örneklerden farklı sorular gelirse öğrenci sınavdan başarısız olur. Eksik öğrenme için daha büyük bir ağ, daha uzun eğitim ve transfer öğrenme önerilirken, aşırı öğrenme sorununun çözümü için ise regülerleştirme yani daha kısa eğitim ve daha fazla veri kullanılması önerilmektedir.

4. DERİN ÖĞRENME İLE KONUT DEĞERİ TESPİTİ

DÖ ile Kayseri ilinin 3 ilçe merkezini kapsayan bir alanda, toplu olarak konut değerlemesi için yapılan bu çalışmada; örneklem alan sınırı belirlenmiş, veri seti hazırlanmış, değişkenler analiz edilmiş, DÖ modeli oluşturulmuş ve DÖ uygulamasının sonuçları değerlendirilmiştir. Buna ek olarak, ÇDR ve CAR yöntemleri kullanılarak da konut değerleri tahmin edilmiş, geliştirilen DÖ mimarisi ile elde edilen konut değeri tahminleri ile karşılaştırılmıştır.

4.1 Örneklem Alanı


Örneklem alanı olarak Kayseri ilinin merkezindeki Kocasinan, Melikgazi ve Talas ilçeleri seçilmiştir. Çalışmanın başlarında Yahyalı, İncesu ve Yeşilhisar ilçelerinin de dâhil edilmesi planlanmış, ancak şehir merkezine oldukça uzak olan bu ilçelerde toplanacak olan verilerin bir DÖ mimarisi ile eğitimi hâlinde, mimarinin başarı oranını düşebileceği ihtimali göz önünde bulundurularak, bu ilçeler çalışma alanından çıkartılmıştır. Çalışma 74,60 km²'lik bir alanda yürütülmüştür. Şekil 4.1'de çalışma alanının konumu ve sınırları gösterilmektedir.



Şekil 4.1 Çalışma alanının konumu ve sınırları


Konumsal nitelikteki veriler, Universal Transverse Merkator (UTM) 3 derecelik projeksiyon, Turkish National Reference Frame (TUREF) datumu ve dilim numarası 36 olan koordinat sisteminde oluşturulmuştur.

Kocasinan, Melikgazi ve Talas ilçelerinde yer alan çalışma alanındaki konutlar, nokta sembolü ile Bing Maps altlığı kullanılarak gösterilmiştir (Şekil 4.2).




Şekil 4.2 Konutların konumsal gösterimi ve çalışma alan sınırı

Konutların konumsal gösterimine ek olarak, değer bilgisinin bir histogram grafiğinde gösterimi de yapılmıştır. Şekil 4.3’de 1365 adet konut değerlerinin normal dağılım histogramı görülmektedir.



Şekil 4.3 Değer normal dağılım histogramı

Buna ek olarak, konutların mevcut değerlerine bağlı olarak oluşturulmuş ısı haritası da Şekil 4.4'te gösterilmiştir. Değer ısı haritası, verilerin dağılımının yanı sıra değer ağırlığının bölgelere göre değişimini Kayseri haritası üzerinde gözlemleyebilme imkânı sunmaktadır.



Şekil 4.4 Konutların değer ısı haritası

4.2 Kullanılan Veri Seti

Çalışma alanındaki konut satışlarına ait detaylar, bütün ölçeklerdeki imar planları, kent rehberi verileri ve faydası olacağı düşünülen benzer veriler konut değerlerinin DÖ yöntemi ile tahmin edilmesinde girdi olarak kullanılmıştır. Çalışma alan sınırı, Kocasinan, Melikgazi ve Talas ilçelerinde konut yoğunluğunun ve alım-satım işlemlerinin fazla olduğu bir bölgede belirlenmiştir.

Konutlara ilişkin verilerin toplanmasında internette yayınlanan konut satış ilanlarından faydalanılmıştır. Her bir ilan yayını esnasında öznitelik bilgileri tespit edilip,

PostgreSQL veri tabanına kaydedilmiştir. İnternet ilanlarında bir konuta ilişkin öznitelik bilgilerinin neredeyse tamamı bulunmaktadır. Konutun gerçek satış değerini öğrenmek için ilan sahibine ulaşılmıştır. Konutun sahibi olsun olmasın, ilan veren kişiden satışın gerçekleşip gerçekleşmediği sorulmuş, satış gerçekleştiyse tapu vs. gibi masraflar hariç satış bedelinin ne olduğu sorulmuş, alınan cevap kayıtlara konutun değeri olarak geçirilmiştir. Kendisinden konutun satışına dair bilgi alınabilen emlakçı veya ev sahipleri olduğu gibi, konu hakkında bilgi vermekten kaçınanlar da olmuştur. Böyle durumlarda bu veri, veri tabanına eklenmemiştir.

Böylece 1535 adet konuta ilişkin verinin veri tabanına girişi sağlanmış, ancak verinin toplu değerlendirme çalışmasına temel teşkil etmeyeceği düşünülen ve istatistiki yöntemler açısından aykırı olarak kabul edilen; eksik veya doğruluğu şüpheli öznitelik bilgileri içeren veriler ayıklanmış, daha güvenilir nitelikte bir veri seti oluşturulmuştur. Son olarak geriye kalan 1365 adet veri 45 adet öznitelik bilgisiyle birlikte, Kayseri’de DÖ tabanlı konut değerlendirme çalışmasında en temel altlık olarak yer almıştır.

Hem mekâna ilişkin hem de sözel kayıtlardan oluşan veri, DÖ algoritmalarının çalıştığı plâtıformların gereksinimlerine uygun bir formata dönüştürülmüştür. Bunun için özellikle PostGIS yeteneklerine (extension) sahip bir PostgreSQL veri tabanı kullanılırken, masaüstü uygulaması olarak açık kaynak kodlu bir yazılım olan QGIS’in yanı sıra, NetCAD masaüstü programından da faydalanılmıştır. DÖ mimarilerinin geliştirilmesi için Python yazılım dili kullanılmıştır.

Konutun iç özelliklerinin yanı sıra, konumuyla ilgili öznitelik bilgileri de veri de yer almaktadır. Buna göre konutun çeşitli ölçeklerdeki imar planı fonksiyonlarının, en yakın alışveriş merkezine, kent merkezine, eğitim tesisine, dini tesise, taksi durağına, tramvay hattına olan mesafeleri gibi değişkenler de CBS araçları marifetiyle hesaplanarak veya manuel veri girişi yapılarak veriye eklenmiştir. Bu şekilde değişken sayısı artırılmış ve değer tahminlerinin daha çok değişken ile daha iyi sonuç vereceği beklentisi ile çalışma yürütülmüştür.

Konut deęerleme alıřmalarında konutun deęerini en fazla etkileyen faktörlerin tespit edilmesi, arařtırmanın önemli bir parasını oluřturmaktadır. Ayrıca konutun i özelliklerine ek olarak, kentsel donatı ve önemli merkezlere olan mesafelerin de deęeri etkileyebileceęi öngörölmüřtür.


Bu alıřma kapsamında konutun bulunduęu binaya iliřkin; bina görevlisinin olup olmadığı, binanın altında dükkân olup olmadığı, binanın yařı, binaya ait açık otopark olup olmadığı, deprem hasar durumu, güvenlik olup olmadığı, havuz olup olmadığı, ısıtma sisteminin ne olduęu, binaya ait kapalı otopark olup olmadığı, rezidans hizmetlerinin olup olmadığı, semt otoparkının yeterli olup olmadığı, sıcak su olup olmadığı, sığmaęın olup olmadığı, binanın site iinde olup olmadığı, yapı kalitesinin nasıl olduęu, yolcu asansörü olup olmadığı, yük asansörü olup olmadığı ve binanın kat adedi bilgileri veride yer almıřtır. Konutun i özelliklerine dair ise; balkon olup olmadığı, banyo sayısı, dairenin brüt alanı, dairenin bulunduęu kat, dairenin binadaki konumu, dairenin net alanı, ebeveyn banyosunun olup olmadığı, daire iinin tadilat gereksinimi, kiler olup olmadığı, manzara durumu, oda sayısı, salon sayısı ve dairenin stüdyo tipi olup olmadığı bilgileri veriye eklenmiřtir. Ayrıca binanın konumsal özelliklerine ait; AVM'ye yakınlık, İlkokula yakınlık, 1/1.000 ölekli imar planı fonksiyonu, 1/25.000 ölekli imar planı fonksiyonu, 1/5.000 ölekli imar planı fonksiyonu, 1/50.000 ölekli imar planı fonksiyonu, X koordinatı, Y koordinatı, Kayseri řehir merkezine (Cumhuriyet Meydanı) yakınlık, saęlık tesisine yakınlık, taksi duraęına yakınlık, ulařım imkânlarına yakınlık ve bulunduęu ile bilgileri veride yer almıřtır.

Verinin toplanmasında internette yayınlanan satılık konut ilanlarından faydalanılmıřtır. Deęerleme řirketlerinden deęerlemesi yapılmıř konutlara ait deęerleme raporlarından oluřan bir veri setinin oluřturulması da mümkün olabilirdi. Ancak deęerleme řirketlerinin amacı dıřında deęerleme raporlarını paylařması mümkün olmadığından ve verilerin iřlenmesine uygun bir veri tabanı formatında tutulmadığından bu yola başvurulamamıřtır.

Verinin toplanması belli bir süre zarfında gerekleřtirilebilmiřtir. Bu zaman aralıęının mümkün olduęunca dar olmasına, ok geniř bir zaman dilimine yayılı olmamasına dikkat

edilmiştir. Çünkü konut piyasasındaki eğilimlerin zamana göre sürekli değişmesi, enflasyon, kredi faiz oranları ve döviz fiyatları gibi göstergelerin çok hareketli olması, fiyatlarda olağan dışı düşme veya yükselme yaşanmasına neden olabilmektedir. O nedenle 2022 yılını ilk 4 ayı içerisinde veri toplama işi bitirilmiştir.

2022 yılının Ocak, Şubat, Mart ve Nisan aylarına ilişkin toplanan verilerin oran ve adetleri Şekil 4.5’de gösterilmiştir. Buna göre en çoğu 2022 yılının mart ayında 838 adet olmak üzere, toplam 1365 adet veri toplanmıştır.



Şekil 4.5 Verinin ay ve yıllara göre toplanma miktarı ve oranları

Paranın zaman değeri ilkesinden yola çıkıldığında, farklı aylarda gerçekleşen konut değerinin normalleştirilmesi, belirlenen bir tarihe indirgenmesi gerekmektedir. O nedenle bütün konutlara ilişkin değer değişkeni 271,8 endeks değeri olan 2022 yılı Ocak ayına indirgenmiştir (Çizelge 4.1). İndirgeme için Türkiye Cumhuriyet Merkez Bankası (TCMB) konut fiyat endeksi kullanılmıştır (Anonim 2023h). Örneğin 2022 yılının nisan ayında 350,4 birim değerinde olan bir konut eğer Ocak ayında satılmış olsaydı 271,8 birim değer edecektir.

Çizelge 4.1 Verinin toplandığı aylara ait konut fiyat endeksleri

Tarih	Konut fiyat endeksi
2022-01	271.8
2022-02	302.8
2022-03	324.6
2022-04	350.4

4.3 Kullanılan Değişkenler

1365 adet kayıttan oluşan veri setinde konutlara ait 45, veri işleme gereksinimleri için ise 4 tane olmak üzere toplam 49 adet öznitelik bilgisi bulunmaktadır. Bu bilgilerin edinilmesi için internet ilanlarından, yerel yönetimlere ait kent rehberi ve imar planı verilerinden faydalanılmıştır. Ayrıca geliştirilmek istenen DÖ mimarisine faydası olacağı düşünülen belli yerlere yakınlık gibi öznitelik bilgileri de veriye eklenmiştir. Değişkenlere ait detay bilgiler Çizelge 4.2’de gösterilmiştir.

Çizelge 4.2 Değişken listesi

Değişken Numarası	Değişken Kategorisi	Değişken Adı	Değişken Kodu	Değişken Veri Tipi
1	Bağımlı değişken	Değer	d70_deger_kfe	Numerik (sıralı değil)
2	Konutun bulunduğu binaya ait özellikler	Bina görevlisi	d12_binagorevlisi	Kategorik
3		Dükkan var mı	d46_dukkanvarmi	Kategorik
4		Binanın yaşı	d14_binayasi	Numerik
5		Açık otopark	d15_otoparkacik	Kategorik
6		Deprem hasar durumu	d16_depremmasardurumu	Kategorik
7		Güvenlik	d17_guvenlik	Kategorik
8		Havuz	d18_havuz	Kategorik
9		Isıtma sistemi	d19_isitma	Kategorik
10		Kapalı otopark	d65_otoparkkapali	Kategorik
11		Rezidans	d20_rezidans	Kategorik
12		Semt otoparkı	d21_otoparksemt	Kategorik
13		Sıcak su	d22_sicaksu	Kategorik
14		Sığınak	d23_siginak	Kategorik
15		Site içinde mi	d24_site	Kategorik
16		Yapı kalitesi	d25_yapikalitesi	Kategorik
17		Yolcu asansörü	d10_asansoryolcu	Kategorik
18		Yük asansörü	d11_asansoryuk	Kategorik
19		Binanın kat adedi	d13_katbina	Numerik
20	Konutun iç özellikleri	Balkon	d29_balkon	Kategorik
21		Banyo sayısı	d31_banyosayi	Numerik
22		Dairenin brüt alanı	d28_alanbrut	Numerik
23		Dairenin bulunduğu kat	d26_katdaire	Numerik
24		Dairenin konumu	d71_dairekonum	Kategorik
25		Dairenin net alanı	d64_alannet	Numerik
26		Ebeveyn banyosu	d30_banyoebeveyn	Kategorik
27		Daire içi yapılı mı	d51_iciyapilimi	Kategorik
28		Kiler	d32_kiler	Kategorik
29		Manzara	d27_manzara	Kategorik
30		Oda sayısı	d33_odasayi	Numerik
31		Salon sayısı	d34_salonsayi	Numerik
32		Stüdyo tipi daire mi	d35_studyo	Kategorik

Çizelge 4.2 Değişken listesi (devam)

Değişken Numarası	Değişken Kategorisi	Değişken Adı	Değişken Kodu	Değişken Veri Tipi
33	Konutun bulunduğu binanın konumsal özellikleri	AVM'ye yakınlık	d38_avm	Numerik
34		İlkokul'a yakınlık	d39_ilkokul	Numerik
35		1/1.000 ölçekli imar planı fonksiyonu	d4_plan1bin	Kategorik
36		1/25.000 ölçekli imar planı fonksiyonu	d6_plan25bin	Kategorik
37		1/5.000 ölçekli imar planı fonksiyonu	d5_plan5bin	Kategorik
38		1/50.000 ölçekli imar planı fonksiyonu	d7_plan50bin	Kategorik
39		Koordinat X	d47_koordx	Numerik (sıralı değil)
40		Koordinat Y	d48_koordy	Numerik (sıralı değil)
41		Merkeze yakınlık	d42_merkez	Numerik
42		Sağlık tesisine yakınlık	d41_saglik	Numerik
43		Taksi durağına yakınlık	d40_taksi	Numerik
44		Ulaşım	d9_ulasim	Numerik
45		İlçe	d2_ilce	Kategorik
46	Veriye ait işlem kolonları	Bölge	d8_bolge	Numerik (sıralı değil)
47		Geometri	poly	Geometri
48		Veri kategorisi	d43_verikategori	Kategorik
49		Veri numarası (id'si)	vid	Numerik (sıralı değil)

DÖ mimarisi geliştirme amacıyla geliştirilen yazılıma, girdi olarak verilen değişkenler ve işlem amaçlı kolonların açıklamaları aşağıda listelenmiştir.

1. Değer: Konutun gerçekleşen satış tutarıdır.
2. Bina görevlisi: Bina görevlisinin olup olmadığı bilgisidir.
3. Dükkân var mı: Binanın altında dükkân olup olmadığı bilgisidir.
4. Binanın yaşı: Binanın yapıldığı tarihten itibaren verinin elde edildiği tarihe kadar olan zamandır.
5. Açık otopark: Binaya ait açık otoparkın olup olmadığı bilgisidir.
6. Deprem hasar durumu: Binanın herhangi bir depremde bilinen bir hasarının olup olmadığı bilgisidir.
7. Güvenlik: Daireye erişimde bir güvenlik görevlisinin görev yapıp yapmadığı bilgisidir.
8. Havuz: Binanın ister yüzme amaçlı ister süs amaçlı en az bir adet havuzunun olup olmadığı bilgisidir.
9. Isıtma sistemi: Dairenin kış aylarında ne tür bir ısıtma sistemi ile ısıtıldığı bilgisidir.
10. Kapalı otopark: Binaya ait kapalı otoparkın olup olmadığı bilgisidir.
11. Rezidans: Dairenin rezidans hizmetlerinden faydalanıp faydalanmadığı bilgisidir.
12. Semt otoparkı: Semtteki kamuya ait ücretsiz açık otopark alanlarının yeterli olup olmadığı bilgisidir.
13. Sıcak su: Gerek merkezi sistem ısıtma ile gerekse dairede yer alan kombi ve benzeri cihazlarla banyo ve mutfığa sıcak su temin edilip edilmediği bilgisidir.
14. Sığınak: Binada sığınak olup olmadığı bilgisidir.
15. Site içinde mi: Binanın bir site içerisinde olup olmadığı bilgisidir.
16. Yapı kalitesi: Binanın yapı kalitesi hakkındaki göreceli bilgidir.
17. Yolcu asansörü: Binada yolcu asansörünün olup olmadığı bilgisidir.
18. Yük asansörü: Binada yük asansörünün olup olmadığı bilgisidir.
19. Binanın kat adedi: Binanın kaç katlı olduğu bilgisidir.
20. Balkon: Dairenin en az 1 tane balkona sahip olup olmadığı bilgisidir.
21. Banyo sayısı: Dairede ebeveyn banyosundan başka var olan banyo sayısıdır.
22. Dairenin brüt alanı: Dairenin brüt alanıdır.

23. Dairenin bulunduğu kat: Dairenin kaçınıcı katta olduđu bilgisidir.
24. Dairenin konumu: Dairenin dikey olarak binada nasıl konumlandıđı bilgisidir.
25. Dairenin net alanı: Dairenin net kullanım alanıdır.
26. Ebeveyn banyosu: Dairede ebeveyn banyosunun olup olmadığı bilgisidir.
27. Daire içi yapılı mı: Dairenin satın alındıktan sonra içinde tadilat yapılmasının gerekli olup olmadığı hakkındaki bilgisidir.
28. Kiler: Dairede kiler bulunup bulunmadıđı bilgisidir.
29. Manzara: Dairenin önünün açık olup olmadığı, günüşığından istifade edip etmediđi bilgisidir.
30. Oda sayısı: Salon haricindeki oda sayısıdır.
31. Salon sayısı: Dairenin salon olarak kullanılan oda sayısıdır.
32. Stüdyo: Dairenin mutfadı ile odalarından birinin arada bölme olmaksızın aynı mekânda bulunup bulunmadıđıdır.
33. AVM'ye yakınlık: Binanın en yakın AVM'ye uzaklıđıdır.
34. İlkokul: Binanın en yakın ilkokula olan kuş uçuşu mesafesidir.
35. 1/1.000 ölçekli imar planı fonksiyonu: Binanın 1/1.000 ölçekli imar planındaki fonksiyonudur.
36. 1/25.000 ölçekli imar planı fonksiyonu: Binanın 1/25.000 ölçekte nazım imar planındaki fonksiyonudur.
37. 1/5.000 ölçekli imar planı fonksiyonu: Binanın 1/5.000 ölçekli imar planındaki fonksiyonudur.
38. 1/50.000 ölçekli imar planı fonksiyonu: Binanın 1/50.000 ölçekli çevre düzeni planındaki fonksiyonudur.
39. X koordinatı: ITRF koordinat sistemindeki X değeriştir.
40. Y koordinatı: Konumu işaretlenen binanın ITRF koordinat sistemindeki Y değeriştir.
41. Merkeze yakınlık: Örnekleme kümesindeki bütün konutların şehir merkezi olarak bilinen Cumhuriyet Meydanı'na olan mesafeleridir.
42. Sağlık tesisine yakınlık: Binanın en yakın sağlık tesisine olan mesafesidir.
43. Taksi durağına yakınlık: Veride yer alan konutların en yakın taksi durağına olan mesafesidir.

44. Ulaşım: Konuta ilişkin ulaşım verisi olarak en yakın tramvay veya ana arter yola olan uzaklığıdır.
45. İlçe: Konutun hangi idari ilçe sınırlarında yer aldığı bilgisidir.
46. Geometri: Verileri konum özelliklerinin tutulduğu işlem kolonudur.
47. Veri kategorisi: Verinin eğitim ya da test bölümünde olduğunu belirtir.
48. Veri numarası: Her bir veri için verilen benzersiz (unique) sıra numarasıdır.
49. Bölge: Verinin eğitim ve test olarak ikiye bölünmesi amacıyla kullanmak üzere homojen özellik gösteren yerleşim alanları tek bir bölge olarak belirlenmiştir. Bir nevi bölgeleme (zoning) işlemi gerçekleştirilmiştir. Her binaya bölge bilgisi olarak benzersiz (unique), sıralı olmayan bir numara verilmiştir.

Konutun içinde bulunduğu binanın özellikleri, konutun iç özellikleri ve konutun içinde yer aldığı binanın konumsal özellikleri Ek-5 te özetlenmiştir. Kategorik değişkenlerin sıklık ve oran bilgileri gösterilirken, numerik olan değişkenlerin değerleri doğal eşik olarak belirlenen aralıklara bölünerek gruplanmak suretiyle özetlenmiştir. Ancak koordinat, bölge kodu, geometri ve veri numarası bilgileri, sıralı olmadığı için, çizelge halinde gösterilmemiştir. Veri kategorisine ait sıklık ve oran bilgileri ise detaylı olarak Şekil 4.8’de gösterilmiştir.

4.4 Uygulama ve Sonuçları

DÖ yöntemlerinin uygulanabilmesi için verinin bazı ön işlemlerden geçmesi gerekmektedir. Aykırı (outlier) verilerin temizlenmesi, değere etki eden değişkenlerin etki miktarlarının tespit edilmesi, gerekiyorsa değişken sayısının artırılması veya azaltılması ve verinin belirli oranlarda üçe bölünmesi, DÖ modelinin başarısını belirleyen işlemlerdir.

4.4.1 Verinin ön işlenmesi

Veri setinde 45 adet değişken bulunmaktadır. Değişkenler numerik, kategorik ve boolean (var/yok) niteliktedir. Numerik ve boolean değişkenler ile yazılım scripti çalıştırılabilirken, kategorik nitelikteki değişkenler scriptin yorumlayabileceği şekilde

değildir. Bu halde script çalıştırılabilse bile yanıltıcı sonuçlar üretebilmektedir. O nedenle kategorik değişkenlerin kodlama yöntemi ile numerik bir şekle dönüştürülerek yazılıma girdi olarak verilmesi gerekmektedir. Kategorik değişkenlerin numerik bir şekilde kodlanması ile kukla değişkenler ortaya çıkmaktadır. Örneğin Çizelge 4.3’de görüldüğü üzere; ısıtma sistemi için soba, merkezi sistem, ısı pay ölçer ve kombi seçenekleri normal durumda bir kolon ile kategorik seçenek olarak ile ifade edilirken, kukla değişkene dönüştürülmesi hâlinde her bir ısıtma sistemi için bir kolon oluşturulur. Verideki her kayıt için ısıtma sistemi ne ise o kolon 1 (bir) değerini alırken, diğer kolonlar 0 (sıfır) değerini almaktadır (Çizelge 4.4).

Çizelge 4.3 Kategorik veri yapısı

	Isıtma sistemi
Kayıt 1	Isı pay ölçer
Kayıt 2	Soba
Kayıt 3	Kombi
Kayıt 4	Merkezi sistem

Dolayısı ile ısıtma sistemi normalde 1 (bir) kolon ile ifade edilirken, kukla değişkenli yapı ile 4 (dört) kolon ile ifade edilmiş olur (Çizelge 4.4).

Çizelge 4.4 Kukla değişkenli veri yapısı

	Soba	Merkezi sistem	Isı pay ölçer	Kombi
Kayıt 1	0	0	1	0
Kayıt 2	1	0	0	0
Kayıt 3	0	0	0	1
Kayıt 4	0	1	0	0

Sonuç olarak 45 değişkenden oluşan veri, 91 kukla değişkenli bir yapıya dönüştürülmüştür (Çizelge 4.5).

Çizelge 4.5 Kukla değişkenler

No	Değişken kategorisi	Değişken adı	Değişken cevap seçenekleri	Değişken kodu	Kukla değişken kodu
1	Bina özellikleri	Bina görevlisi	var/yok	d12_binagorevlisi	d12_binagorevlisivaryok
2	Bina özellikleri	Dükkan var mı	var/yok	d46_dukkanvarmi	d46_dukkanvarmivaryok
3	Bina özellikleri	Binanın yaşı	yıl	d14_binayasi	d14_binayasi
4	Bina özellikleri	Açık otopark	var/yok	d15_otoparkacik	d15_otoparkacikvaryok
5	Bina özellikleri	Deprem hasar durumu	var/yok	d16_depremmasardurumu	d16_depremmasardurumuvaryok
6	Bina özellikleri	Güvenlik	var/yok	d17_guvenlik	d17_guvenlikvaryok
7	Bina özellikleri	Havuz	var/yok	d18_havuz	d18_havuzvaryok
8	Bina özellikleri	Isıtma sistemi	ısıpay	d19_isitma	d19_isitmaisipay
9	Bina özellikleri	Isıtma sistemi	kombi	d19_isitma	d19_isitmakombi
10	Bina özellikleri	Isıtma sistemi	merkezi sistem	d19_isitma	d19_isitmamerkezi
11	Bina özellikleri	Isıtma sistemi	soba	d19_isitma	d19_isitmasoba
12	Bina özellikleri	Kapalı otopark	var/yok	d65_otoparkkapali	d65_otoparkkapalivaryok
13	Bina özellikleri	Rezidans	evet/hayır	d20_rezidans	d20_rezidansevethayir
14	Bina özellikleri	Semt otoparkı	yeterli / yeterli değil	d21_otoparksemt	d21_otoparksemtiyeterliyetridegil
15	Bina özellikleri	Sıcak su	var/yok	d22_sicaksu	d22_sicaksuvaryok
16	Bina özellikleri	Sığınak	var/yok	d23_siginak	d23_siginakvaryok
17	Bina özellikleri	Site içinde mi	evet/hayır	d24_site	d24_siteevethayir
18	Bina özellikleri	Yapı kalitesi	iyi	d25_yapikalitesi	d25_yapikalitesiiyi
19	Bina özellikleri	Yapı kalitesi	kötü	d25_yapikalitesi	d25_yapikalitesikotu
20	Bina özellikleri	Yapı kalitesi	lüks	d25_yapikalitesi	d25_yapikalitesiluks
21	Bina özellikleri	Yapı kalitesi	orta	d25_yapikalitesi	d25_yapikalitesiorta
22	Bina özellikleri	Yolcu asansörü	var/yok	d10_asansoryolcu	d10_asansoryolcuvaryok
23	Bina özellikleri	Yük asansörü	var/yok	d11_asansoryuk	d11_asansoryukvaryok
24	Bina özellikleri	Binanın kat adedi	binanın kat adedi	d13_katbina	d13_katbina
25	Daire özellikleri	Balkon sayısı	var/yok	d29_balkon	d29_balkonvaryok
26	Daire özellikleri	Banyo sayısı	adet	d31_banyosayi	d31_banyosayi
27	Daire özellikleri	Dairenin brüt alanı	brüt alan	d28_alanbrut	d28_alanbrut
28	Daire özellikleri	Dairenin bulunduğu kat	dairenin bulunduğu kat	d26_katdaire	d26_katdaire
29	Daire özellikleri	Dairenin konumu	ara kat	d71_dairekonum	d71_dairekonumarakat

Çizelge 4.5 Kukla değişkenler (devam)

No	Değişken kategorisi	Değişken adı	Değişken cevap seçenekleri	Değişken kodu	Kukla değişken kodu
30	Daire özellikleri	Dairenin konumu	bodrum kat	d71_dairekonum	d71_dairekonumbodrum
31	Daire özellikleri	Dairenin konumu	dükkan üstü	d71_dairekonum	d71_dairekonumdukkannustu
32	Daire özellikleri	Dairenin konumu	son kat	d71_dairekonum	d71_dairekonumsonkat
33	Daire özellikleri	Dairenin konumu	zemin kat	d71_dairekonum	d71_dairekonumzeminkat
34	Daire özellikleri	Dairenin net alanı	net alan	d64_alannet	d64_alannet
35	Daire özellikleri	Ebeveyn banyosu	var/yok	d30_banyoebeveyn	d30_banyoebeveynvaryok
36	Daire özellikleri	İçi yapılı mı	evet	d51_iciyapili	d51_iciyapiliev
37	Daire özellikleri	İçi yapılı mı	hayır	d51_iciyapili	d51_iciyapilihayir
38	Daire özellikleri	İçi yapılı mı	istenirse	d51_iciyapili	d51_iciyapiliistenirse
39	Daire özellikleri	İçi yapılı mı	lüks	d51_iciyapili	d51_iciyapililuks
40	Daire özellikleri	Kiler	var/yok	d32_kiler	d32_kilervaryok
41	Daire özellikleri	Manzara	normal	d27_manzara	d27_manzaranormal
42	Daire özellikleri	Manzara	önü açık	d27_manzara	d27_manzaraocak
43	Daire özellikleri	Manzara	önü kapalı	d27_manzara	d27_manzaraokapali
44	Daire özellikleri	Oda sayısı	oda sayısı	d33_odasayi	d33_odasayi
45	Daire özellikleri	Salon sayısı	adet	d34_salonsayi	d34_salonsayi
46	Daire özellikleri	Stüdyo tipi daire mi	evet/hayır	d35_studio	d35_studioevethayir
47	Konum özellikleri	1/1.000 ölçekli imar planı fonksiyonu	bilinmiyor	d4_plan1bin	d4_plan1binbilinmiyor
48	Konum özellikleri	1/1.000 ölçekli imar planı fonksiyonu	gelişme konut	d4_plan1bin	d4_plan1bingelismekonut
49	Konum özellikleri	1/1.000 ölçekli imar planı fonksiyonu	iptal	d4_plan1bin	d4_plan1biniptal
50	Konum özellikleri	1/1.000 ölçekli imar planı fonksiyonu	konut	d4_plan1bin	d4_plan1binkonut
51	Konum özellikleri	1/1.000 ölçekli imar planı fonksiyonu	konut dışı kentsel çalışma alanı	d4_plan1bin	d4_plan1binkonutdisi
52	Konum özellikleri	1/1.000 ölçekli imar planı fonksiyonu	konut ticaret	d4_plan1bin	d4_plan1binkonutticaret
53	Konum özellikleri	1/1.000 ölçekli imar planı fonksiyonu	kütle	d4_plan1bin	d4_plan1binkutle
54	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	bilinmiyor	d6_plan25bin	d6_plan25binb
55	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	gelişme konut çok yüksek	d6_plan25bin	d6_plan25bingkcy
56	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	gelişme konut düşük	d6_plan25bin	d6_plan25bingkd
57	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	gelişme konut orta	d6_plan25bin	d6_plan25bingko
58	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	gelişme konut seyrek	d6_plan25bin	d6_plan25bingks
59	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	gelişme konut yüksek	d6_plan25bin	d6_plan25bingky
60	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	kentsel sit	d6_plan25bin	d6_plan25binks
61	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	mevcut konut çok yüksek	d6_plan25bin	d6_plan25binmkcy

Çizelge 4.5 Kukla değişkenler (devam)

No	Değişken kategorisi	Değişken adı	Değişken cevap seçenekleri	Değişken kodu	Kukla değişken kodu
62	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	mevcut konut orta	d6_plan25bin	d6_plan25binmko
63	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	mevcut konut seyrek	d6_plan25bin	d6_plan25binmks
64	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	mevcut konut yüksek	d6_plan25bin	d6_plan25binmky
65	Konum özellikleri	1/25.000 ölçekli imar planı fonksiyonu	tarihi sit	d6_plan25bin	d6_plan25bints
66	Konum özellikleri	İmar planı fonksiyonu (1/25.000)	ticaret	d6_plan25bin	d6_plan25bint
67	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	bilinmiyor	d5_plan5bin	d5_plan5binbilinmiyor
68	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	gelişme konut çok yüksek	d5_plan5bin	d5_plan5bingkcyuksek
69	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	gelişme konut düşük	d5_plan5bin	d5_plan5bingkdusuk
70	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	gelişme konut orta	d5_plan5bin	d5_plan5bingkorta
71	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	gelişme konut seyrek yoğunluklu	d5_plan5bin	d5_plan5bingkseyrek
72	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	gelişme konut yüksek yoğunluklu	d5_plan5bin	d5_plan5bingkyuksek
73	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	konut ticaret	d5_plan5bin	d5_plan5binkt
74	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	yerleşik konut çok yüksek	d5_plan5bin	d5_plan5binykcyuksek
75	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	yerleşik konut orta	d5_plan5bin	d5_plan5binykorta
76	Konum özellikleri	1/5.000 ölçekli imar planı fonksiyonu	yerleşik konut yüksek	d5_plan5bin	d5_plan5binykyuksek
77	Konum özellikleri	1/50.000 ölçekli imar planı fonksiyonu	bilinmiyor	d7_plan50bin	d7_plan50binbilinmiyor
78	Konum özellikleri	1/50.000 ölçekli imar planı fonksiyonu	kentsel gelişme	d7_plan50bin	d7_plan50binkgelisme
79	Konum özellikleri	1/50.000 ölçekli imar planı fonksiyonu	kentsel meskun	d7_plan50bin	d7_plan50binkmeskun
80	Konum özellikleri	1/50.000 ölçekli imar planı fonksiyonu	mia	d7_plan50bin	d7_plan50binmia
81	Konum özellikleri	AVM'ye yakınlık	mesafe	d38_avm	d38_avm
82	Konum özellikleri	İlçe adı	Kocasinan	d2_ilce	d2_ilcekocasinan
83	Konum özellikleri	İlçe adı	Melikgazi	d2_ilce	d2_ilcemelikgazi
84	Konum özellikleri	İlçe adı	Talas	d2_ilce	d2_ilcetalas
85	Konum özellikleri	İlkokul	mesafe	d39_ilkokul	d39_ilkokul
86	Konum özellikleri	Koordinat X	X koordinatı	d47_koordx	d47_koordx
87	Konum özellikleri	Koordinat Y	Y koordinatı	d48_koordy	d48_koordy
88	Konum özellikleri	Merkeze yakınlık	mesafe	d42_merkez	d42_merkez
89	Konum özellikleri	Sağlık tesisine yakınlık	mesafe	d41_saglik	d41_saglik
90	Konum özellikleri	Taksi durağına yakınlık	mesafe	d40_taksi	d40_taksi
91	Konum özellikleri	Ulaşım	mesafe	d9_ulasim	d9_ulasim

Örneğin 593 veri numaralı (vid) kaydın kukla değişkene dönüştürülmüş hali ile öznitelik bilgileri Şekil 4.6’da gösterilmektedir.


vid	593	d4_plan1biniptal	0
deger	959589	d4_plan1binbilinmiyor	0
d43_verikategori	egitim	d4_plan1binkutle	0
longx	35.5542	d4_plan1bingelismekonut	0
laty	38.7528	d4_plan1binkonut	1
d47_koordx	461247.353	d4_plan1binkonutticaret	0
d48_koordy	4291153.254	d4_plan1binkonutdisi	0
d9_ulasim	34	d5_plan5bingkyuksek	0
d38_avm	1760	d5_plan5binykyuksek	0
d39_ilkokul	1246	d5_plan5bingkdusuk	0
d40_taksi	726	d5_plan5bingkseyrek	0
d41_saglik	662	d5_plan5binbilinmiyor	1
d42_merkez	6709	d5_plan5bingkcyuksek	0
d13_katbina	9	d5_plan5bingkorta	0
d14_binayasi	0	d5_plan5binykcyuksek	0
d28_alanbrut	170	d5_plan5binkt	0
d64_alannet	130	d6_plan25bingky	1
d31_banyosayi	1	d6_plan25binmko	0
d33_odasayi	3.0	d6_plan25bint	0
d34_salonsayi	1	d6_plan25bingkd	0
d2_ilcetalas	0	d6_plan25binmky	0
d2_ilcemelikgazi	0	d6_plan25binks	0
d2_ilcekocasinan	1	d6_plan25bingks	0
d4_plan1biniptal	0	d6_plan25binb	0
d25_yapikalitesiluks	1	d6_plan25binmks	0
d25_yapikalitesiyi	0	d6_plan25binmkcy	0
d25_yapikalitesiota	0	d6_plan25bints	0
d25_yapikalitesikotu	0	d6_plan25bingkcy	0
d27_manzaranormal	1	d6_plan25bingko	0
d27_manzaraokapali	0	d7_plan50binkgelisme	0
d27_manzaraocak	0	d7_plan50binkmeskun	1
d29_balkonvaryok	1	d7_plan50binmia	0
d30_banyoebeveynvaryok	1	d7_plan50binbilinmiyor	0
d32_kilervaryok	1	d10_asansoryolcuvar yok	1
d35_studyoevethayir	0	d11_asansoryukvar yok	0
d46_dukkanvarmivaryok	0	d12_binagorevliisvar yok	1
d51_jciyapilihayir	0	d15_otoparkacikvar yok	1
d51_jciyapililuks	1	d16_depremhasardurumuvar yok	0
d51_jciyapiliistenirse	0	d17_guvenlikvar yok	0
d51_jciyapilievat	0	d18_havuzvar yok	0
d65_otoparkkapalivaryok	0	d19_isitmaisipay	0
d71_dairekonumarakat	1	d19_isitmakombi	0
d71_dairekonumsonkat	0	d19_isitmamerkezi	1
d71_dairekonumbodrum	0	d19_isitmasoba	0
d71_dairekonumzeminkat	0	d20_rezidansevevethayir	0
d71_dairekonumdukkannustu	0	d21_otoparksemtiyeterliyetridegil	1
d26_katdaire	7	d22_sicaksuvaryok	1
		d23_siginakvar yok	1
		d24_siteevethayir	0

Şekil 4.6 Örnek bir kaydın kukla değişkene dönüştürülmüş halinin sorgu ekranındaki görünümü

4.4.2 Değere etki eden numerik değişkenler

Sadece numerik değişkenler içerisinde hangilerinin değere ne kadar etki ettiği Python yazılım dilinde yazılan script ile tespit edilmiş, korelasyon hesabı yapılmıştır (Ek-2). Script sonucunda ise ısı haritasının oluşturulması için kodlama da yapılmıştır.

“Değer” bağımsız değişkenine etki eden numerik değişkenlerin korelasyon ısı haritası ile değere en azdan en çok etki edene doğru sıralanmış hali Şekil 4.7’de gösterilmiştir. Değere pozitif yönde en çok etki eden numerik değişkenler sırayla brüt alan, net alan, binanın kat adedi, oda sayısı, dairenin bulunduğu kat, ilkokula yakınlık, salon sayısı, ulaşım, banyo sayısı ve AVM’ye yakınlık olmuştur. Buna karşın değere negatif yönde etki eden değişkenler ise en çok etki edenden başlamak üzere binanın yaşı, merkeze yakınlık, Y koordinatı, X koordinatı, taksi durağına yakınlık ve sağlık tesisine yakınlık olmuştur.



Şekil 4.7 Numerik değişkenlerin konut değerine etkisinin korelasyon ısı haritasında gösterimi

Çalışma alanındaki çok katlı binalarda yer alan konutların değerini, numerik değişkenlerden hangilerinin ne kadar etkilediği tespit edilmiştir. Buna göre en çok dairenin alan ve oda sayısının artmasının değerini olumlu yönde etkilemesi ve bina yaşının artmasının değeri olumsuz yönde etkilemesi beklenebilir bir durumdur. Ancak merkeze, taksi durağına ve sağlık tesisine yaklaştıkça konutların değerinin azalma eğilimi göstermesi şaşırtıcı olmuştur. Demek ki, değere olumsuz katkısı olan konuta ait bu özellikler, Kayseri’de konut satın alma istekliliğinde daha az para ödemeyi gerektirmektedir.

4.4.3 Değişken sayısının azaltılması

Bağımlı değişkene bağımsız değişkenlerin farklı ağırlıklarda etkisi olmaktadır. Bazı değişkenler daha çok etki ederken, bazı değişkenler daha az etki etmektedir. Değişken sayısının mümkün olduğunca fazla olması model başarısını elbette artıracaktır. Ancak belli bir değişken adedinden sonraki her değişken model başarısına önemli bir ölçüde katkı sunmayabilir. Ayrıca kaynak ihtiyacının çok fazla olduğu veri toplama aşamasında, modele katkısı azami olacak, optimum sayıda değişkenin belirlenmesi kaynakların etkili kullanımı açısından daha faydalı olacaktır.

Diğer yandan mümkün olduğunca az değişken ile geliştirilen model daha hızlı ve etkin olacaktır. Bir başka deyişle, DÖ modeli oluşturulurken, optimum düzeyde kaynak ayrılarak en etkili model geliştirmek esas olmalıdır. Bunun için Geriye Doğru Eleme (GDE) yöntemi kullanılarak modele katkısı önemsiz değişkenler modelden atılıp, değişken sayısı azaltılarak da alternatif mimariler geliştirilmiştir. Bunun için pythonda scikit learn paketi kullanılarak bir script yazılmış ve çalıştırılmıştır (Ek-3). Bu script gerekli kütüphanenin yüklenmesi, verinin yüklenmesi, değişkenlerin ayrılması, modelin oluşturulması ve GDE yöntemi ile değişken seçiminin yapılması aşamalarını içermektedir. Modele katkısı en çok olan değişkenler GDE yöntemi ile belirlenerek Çizelge 4.6’da gösterilmiştir.

Çizelge 4.6 GDE yöntemi ile belirlenen değişkenler

Değişken adı	Değişken kodu	Değişken türü	Kukla değişken kodu
Yolcu asansörü	d10_asansoryolcu	var/yok	d10_asansoryolcuvar/yok
Bina görevlisi	d12_binagorevlisi	var/yok	d12_binagorevlisivar/yok
Bina yaşı	d14_binayasi	numerik	d14_binayasi
Isıtma sistemi	d19_isitma	kategorik	d19_isitmaaisipay
			d19_isitmakombi
			d19_isitmamerkezi
			d19_isitmasoba
Rezidans	d20_rezidans	var/yok	d20_rezidanseventhayir
Semt otoparkı	d21_otoparksemt	var/yok	d21_otoparksemtiyeterliyetleridegil
Sıcak su	d22_sicaksu	var/yok	d22_sicaksuvar/yok
Sığınak	d23_siginak	var/yok	d23_siginakvar/yok
Site	d24_site	var/yok	d24_siteevethayir
Yapı kalitesi	d25_yapikalitesi	kategorik	d25_yapikalitesiiyi
			d25_yapikalitesikotu
			d25_yapikalitesiluks
			d25_yapikalitesiorta
	d29_balkon	var/yok	d29_balkonvar/yok
İlçe	d2_ilce	kategorik	d2_ilcekocasinan
			d2_ilcemelikgazi
			d2_ilcetalas
Ebeveyn banyosu	d30_banyoebeveyn	var/yok	d30_banyoebeveynvar/yok
Kiler	d32_kiler	var/yok	d32_kilervaryok
Oda sayısı	d33_odasayi	numerik	d33_odasayi
Stüdyo	d35_studio	var/yok	d35_studioevethayir
Koordinat X	d47_koordx	numerik	d47_koordx
Koordinat Y	d48_koordy	numerik	d48_koordy
Dairenin içinin yapıli olup olmadığı	d51_iciyapili	kategorik	d51_iciyapilihayir
			d51_iciyapiliistenirse
			d51_iciyapililuks
			d51_iciyapilievethayir
Net alan	d64_alannet	numerik	d64_alannet
Kapalı otopark	d65_otoparkkapali	var/yok	d65_otoparkkapalivaryok
1/25.000 ölçekli imar planı fonksiyonu	d6_plan25bin	kategorik	d6_plan25binb
			d6_plan25bingkcy
			d6_plan25bingkd
			d6_plan25bingko
			d6_plan25bingks
			d6_plan25bingky
			d6_plan25binks
			d6_plan25binmkcy
			d6_plan25binmko
			d6_plan25binmks
			d6_plan25binmky
			d6_plan25bint
			d6_plan25bints
Dairenin konumu	d71_dairekonum	kategorik	d71_dairekonumarakat
			d71_dairekonumbodrum
			d71_dairekonumdukkanustu
			d71_dairekonumsonkat
			d71_dairekonumzeminkat

Sonuç olarak optimum değişken sayısı 23 olarak belirlenmiştir. Yani değer değişkeni haricindeki 44 değişken yerine 23 değişken kullanılarak, istenen değer tahmin sonuçlarına oldukça yaklaşabilmek mümkündür. DÖ modelinin geliştirilmesi ve uygulanmasının gerekli olduğu durumlarda büyük veriye gereksinim duyulmaktadır. Bu çalışma kapsamında 44 tane değişken bilgisini elde etmeye çalışmak yerine, 23 tane değişken bilgisi ile çalışmanın yürütülmesiyle de hedeflenen sonuca ulaşmak mümkündür. Böylece veri toplama, depolama ve veri toplama için tahsis edilen iş gücü, sunucu (server) gibi kaynaklardan tasarruf edilmiş olacaktır.


4.4.4 Verinin bölünmesi

DÖ çalışmalarında verilerin bir kısmı oluşturulan modelin eğitimi için seçilirken, eğitim esnasında daha önce hiç kullanılmayan verinin kalan kısmı ise modelin test edilmesi için ayrılır. Verinin yaklaşık yüzde 80'i eğitim, yüzde 20'si ise test amacıyla kullanılmıştır. Belirlenen parametrelerin ilk bakışta olumlu denebilecek sonuçlar vermesi hâlinde, mimarının geliştirme aşamalarına devam etmek uygun olmaktadır. Parametrelerin ilk aşamada olumlu sonuçlar vermesi eğitim verisi ile model eğitilirken, yine eğitim verisinin bir kısmının doğrulama amacıyla kullanılması esasına dayanmaktadır. Bir başka deyişle; eğitilmiş modelin test edilmeden test edilmesi, doğrulama olarak nitelendirilmektedir. Dolayısı ile aslında veri eğitim, doğrulama ve test olmak üzere 3 bölüme ayrılmıştır. Doğrulama amacıyla eğitim verilerinin yaklaşık %10'una karşılık gelen 108 adet veri doğrulama verisi olarak kullanılmıştır (Şekil 4.8). Doğrulama verisinin seçimi “basit hold-out” tekniği ile gerçekleştirilmiştir.

1365 adet		
%80 eğitim		%20 test
978 adet eğitim	108 adet doğrulama	279 adet test


Şekil 4.8 Verinin eğitim, doğrulama ve test olarak bölünmesi

Veri seti test ve eğitim olarak ikiye ayrılırken homojen veri setinin tamamını temsil eden bir bölme işlemi gerçekleştirilmiştir. Örneğin her mahalleden eğitim amacıyla yaklaşık %80 oranında veri ayrılırken, kalan %20'si ise “tabakalı rastgele örnekleme” tekniğine uygun bir şekilde test amacıyla kullanılmak üzere seçilmiştir. Şekil 4.9’da görüldüğü gibi 122 adet bölge oluşturulmuş, bu bölgelerde tabakalı rastgele örnekleme tekniği ile veri bölünmesi gerçekleştirilmiştir.




Şekil 4.9 Çalışma alanındaki bölgeler

Şekil 4.10'da daha detaylı olarak görüldüğü üzere, her bir bölge içerisinde belirlenen oranlarda eğitim ve test verileri seçilmiştir.



Şekil 4.11 Eğitim verisinin eğitim kısmının gerçek ve tahmin edilen değerlerinin frekansı

Yine 18 numaralı çalışmanın parametrelerine bağlı olarak eğitim verisinin doğrulama kısmının gerçek değer ve tahmin edilen değerlerine ait grafik Şekil 4.12’de gösterilmektedir.



Şekil 4.12 Eğitim verisinin doğrulama kısmının tahminleri

Eđitim ve dođrulama iřlemlerine ait grafiklerin ikisinde de tahminlerin b y k  l  de tutarlı ve bařarılı olduđu kırmızı ve mavi  izgilerin birbiri ile  rt şmesinden anlaşılmaktadır.


4.4.6 Deđer tahmini

D  algoritmaları probleme y nelik ayarlamaların yapılmasını gerektiren, parametrelere sahiptir. Bařka bir deyiřle, modelin en bařarılı sonucu vermesi i in yazılıma iliřkin parametrelerin optimize edilmesi gereklidir.

Python yazılım dilinde keras k t phanesi kullanılarak D  modeli geliřtirme amacıyla farklı parametrelerin kullanımı yoluna gidilmiřtir. Aktivasyon fonksiyonu, optimizasyon algoritması, kayıp fonksiyonu, katman sayısı, epok sayısı ve deđiřken sayısı parametrelerinde deđiřikliđe gidilerek, konut deđerleme i in en uygun D  mimarisinin geliřtirilmesi ama lanmıřtır. Aktivasyon fonksiyonu olarak; relu ve softplus, optimizasyon algoritması olarak; adam, adamax ve rmsprop, kayıp fonksiyonu olarak; MeanAbsoluteError ve MeanAbsolutePercentageError, katman sayısı olarak; 3, 4 ve 5, epok sayısı olarak; 20 ve 50 kullanılırken, deđiřken sayısı olarak ise; deđiřkenlerin kukla deđiřkene d n řt r lm ř hali ile 91 ve 50 adet deđiřken kullanılmıřtır. Keras k t phanesinde olan ancak adı ge en parametreler dıřındaki parametreler de denenmiř, ancak kayda deđer sonu lar vermediđi i in bu  alıřma kapsamında deđerlendirmeye alınmamıřtır.


Konut deđerlerinin tahmin edilmesi amacıyla Kayseri'deki  alıřma alanı i in geliřtirilen D  modellerinde tensorflow'un keras k t phanesi kullanılmıřtır. Ek-4'te bir tensorflow keras sıralı model kodu g r lmektedir. İlk katman 91  zellikten oluřan bir giriř katmanıdır. Ardından, 3 adet 512 n ronlu tam bađlantılı katman (dense layer) gelmekte ve her biri relu aktivasyon fonksiyonu ile aktive edilmektedir. Son katman ise bir adet  ıkıř katmanıdır.

Buna ek olarak, Kayseri'deki çalışma alanında konut değerlerinin tahmin edilmesine yönelik olarak denenen 1 giriş, 3 gizli ve 1 de çıktı katmanından oluşan DÖ mimarisinin şematik olarak ifadesi Şekil 4.13'de gösterilmiştir. Konutun özelliklerini ifade eden 91 değişken, modelin giriş katmanında yer alır. İlk gizli katmanda bulunan 512 nöronun her birisine 91 giriş değeri iletilir. Her nöron içinde, ağırlıklandırılan, sapma değeri eklenen ve ardından aktivasyon fonksiyonuna tabi tutulan girdilerden bir çıktı üretilir. İlk gizli katmandaki her bir nöronun çıktısı, ikinci gizli katmandaki 512 nöronun tamamında birden giriş olarak kullanılır. Birinci gizli katmandaki işlemlerin aynısı ikinci ve üçüncü gizli katmanlarda da gerçekleşir ve her bir nörondan çıkan değerler çıktı katmanındaki nihai nörona girdi olarak gönderilir. Son nöronda da ağırlıklandırılan, sapma değeri eklenen ve aktivasyon fonksiyonuna tabi tutulan sonuçlarla nihai çıktı değeri elde edilir. Nihai çıktı değeri gerçek değer ile karşılaştırılır. Aradaki fark kayıp değeridir. Ardından, kayıp fonksiyonu ile kayıp miktarının azaltılması için nöronlarda yeniden ağırlıklandırma yapılır. Nöronlardaki ağırlıklar, çıktı katmanından giriş katmanına doğru, yani geriye doğru düzeltilerek güncellenir. Baştan sona bütün bu işlemler belirtilen epok sayısı kadar tekrar edilerek öğrenme gerçekleşir. Son olarak çıktı katmanında nihai çıktı değeri üretilir. Bu çıktı, 91 adetten oluşan değişken bilgilerine dayanarak eğitilen DÖ mimarisi sayesinde, konutun tahmin edilen piyasa değerini ifade etmektedir.



Şekil 4.13 Konut değerlendirme DÖ mimarisi

Konut değerinin tahmin edilmesine yönelik olarak geliştirilen scriptte değişken sayısı, aktivasyon fonksiyonu, optimizasyon algoritması, kayıp fonksiyonu, katman sayısı ve epok sayısı parametrelerinin (Şekil 4.14) farklılaştırılarak denenmesi ile başka bir deyişle en iyi sonuca ulaşmak için iterasyon yaparak, birbirinden farklı DÖ mimarileri (Çizelge 4.7) geliştirilmiştir.



Şekil 4.14 DÖ model parametreleri ve farklı kombinasyonları

Şekil 4.14'deki alternatif parametrelerin olası bütün ihtimallerinin sayısı 144 etmektedir. O nedenle 144 farklı kombinasyon ile yazılım çalıştırılmış, 144 farklı sonuç elde edilmiştir. Yani 144 farklı mimari oluşturulmuş ve ölçüt sonuçları hesaplanmıştır.

91 ve 50 değişkenle yapılan çalışmaların sonuçları ayrı ayrı en iyi sıralamasına tabi tutulmuş, her bir ölçüte göre en iyi sonucu veren mimariler belirlenmiştir. Herhangi bir ölçütte en iyi sonuç veren ilk 3 çalışmadan birisi olabilen çalışmalar, en iyi mimariye sahip çalışmalar olarak kabul edilmiştir. Yani bir çalışma her bir ölçütün başarı sıralamasında 1. 2. veya 3. olabilmiş ise başarılı olarak kabul edilmiştir. Bu kriterle uygunluk 91 ve 50 değişkenli çalışmalar için ayrı ayrı yapılmıştır. Buna göre 91 değişken ile 6 ölçütte birden en iyi sonucu veren mimariler 18 ve 12 numaralı mimariler olurken, 50 değişken ile 6 ölçütte birden en iyi sonucu veren mimariler 102 ve 84 numaralı çalışmalar olmuştur. Öne çıkan 4 mimari içerisinden ise, 91 değişkenli çalışmalar arasında OMYH ölçütü bakımından en iyi sonucu vermesi nedeniyle 18 numaralı çalışma en iyi mimari olarak seçilmiştir. 50 değişkenli çalışmalar içerisinden ise 102 ve 84 numaralı çalışmalar arasında OMYH bakımından en iyi sonucu veren 102 numaralı mimari en iyi mimari olarak kabul edilmiştir. Yani 18 (91 değişkenli) ve 102 (50 değişkenli) numaralı çalışmalar, Kayseri'deki çalışma alanında konut değerlemesinde kullanılabilecek en iyi DÖ mimarileri olarak ortaya çıkmıştır. Ayrıca, denenen farklı mimarilerin eğitim, doğrulama, kayıp fonksiyonu ve değer tahmin dağılımı grafiklerinden bazıları Ek-1'de liste halinde gösterilmiştir.

Çizelge 4.7 Kayseri için 144 farklı parametre kombinasyonu ile elde edilen mimarilere ait sonuçlar

Çalışma numarası	Değişken sayısı	Aktivasyon fonksiyonu	Optimizasyon algoritması	Kayıp fonksiyonu	Katman sayısı	Epok sayısı	R ²	OMH (/100.000)	OKH (/100.000.000.000)	OMYH	OKHK (/1.000.000)	Hataların standart sapması
1	91	relu	adam	MeanAbsoluteError	3	20	0,8265	0,6311	0,0841	0,1277	0,0917	0,21
2	91	relu	adam	MeanAbsoluteError	3	50	0,8382	0,5526	0,0784	0,1127	0,0885	0,20
3	91	relu	adam	MeanAbsoluteError	4	20	0,8740	0,5108	0,0610	0,1036	0,0781	0,18
4	91	relu	adam	MeanAbsoluteError	4	50	0,9449	0,3190	0,0267	0,0633	0,0517	0,10
5	91	relu	adam	MeanAbsoluteError	5	20	0,9152	0,4428	0,0411	0,0850	0,0641	0,13
6	91	relu	adam	MeanAbsoluteError	5	50	0,9498	0,3288	0,0243	0,0639	0,0493	0,09
7	91	relu	adam	MeanAbsolutePercentageError	3	20	0,7634	0,7016	0,1147	0,1430	0,1071	0,24
8	91	relu	adam	MeanAbsolutePercentageError	3	50	0,8451	0,5569	0,0751	0,1123	0,0866	0,19
9	91	relu	adam	MeanAbsolutePercentageError	4	20	0,8501	0,5401	0,0727	0,1080	0,0852	0,17
10	91	relu	adam	MeanAbsolutePercentageError	4	50	0,9443	0,3300	0,0270	0,0661	0,0520	0,11
11	91	relu	adam	MeanAbsolutePercentageError	5	20	0,9107	0,4460	0,0433	0,0901	0,0658	0,14
12	91	relu	adam	MeanAbsolutePercentageError	5	50	0,9542	0,3042	0,0222	0,0601	0,0471	0,10
13	91	relu	adamax	MeanAbsoluteError	3	20	0,7681	0,7363	0,1124	0,1504	0,1060	0,25
14	91	relu	adamax	MeanAbsoluteError	3	50	0,8401	0,6128	0,0775	0,1224	0,0880	0,19
15	91	relu	adamax	MeanAbsoluteError	4	20	0,8771	0,5074	0,0596	0,1001	0,0772	0,16
16	91	relu	adamax	MeanAbsoluteError	4	50	0,9194	0,3776	0,0390	0,0762	0,0625	0,14
17	91	relu	adamax	MeanAbsoluteError	5	20	0,9287	0,3961	0,0345	0,0790	0,0588	0,12
18	91	relu	adamax	MeanAbsoluteError	5	50	0,9472	0,3023	0,0256	0,0566	0,0506	0,09
19	91	relu	adamax	MeanAbsolutePercentageError	3	20	0,4986	1,0358	0,2430	0,2056	0,1559	0,33
20	91	relu	adamax	MeanAbsolutePercentageError	3	50	0,8034	0,6785	0,0953	0,1358	0,0976	0,21
21	91	relu	adamax	MeanAbsolutePercentageError	4	20	0,8359	0,6127	0,0795	0,1212	0,0892	0,19
22	91	relu	adamax	MeanAbsolutePercentageError	4	50	0,9090	0,4178	0,0441	0,0823	0,0664	0,14

Çizelge 4.7 Kayseri için 144 farklı parametre kombinasyonu ile elde edilen mimarilere ait sonuçlar (devam)

Çalışma numarası	Değişken sayısı	Aktivasyon fonksiyonu	Optimizasyon algoritması	Kayıp fonksiyonu	Katman sayısı	Epok sayısı	R ²	OMH (/100.000)	OKH (/100.000.000)	OMYH	OKHK (/1.000.000)	Hataların standart sapması
23	91	relu	adamax	MeanAbsolutePercentageError	5	20	0,9095	0,4441	0,0439	0,0869	0,0662	0,14
24	91	relu	adamax	MeanAbsolutePercentageError	5	50	0,9393	0,3296	0,0294	0,0666	0,0543	0,11
25	91	relu	rmsprop	MeanAbsoluteError	3	20	0,4996	0,9222	0,2425	0,1910	0,1557	0,36
26	91	relu	rmsprop	MeanAbsoluteError	3	50	0,6596	0,7257	0,1650	0,1490	0,1284	0,30
27	91	relu	rmsprop	MeanAbsoluteError	4	20	0,8896	0,4861	0,0535	0,0937	0,0731	0,15
28	91	relu	rmsprop	MeanAbsoluteError	4	50	0,9396	0,3526	0,0292	0,0681	0,0541	0,10
29	91	relu	rmsprop	MeanAbsoluteError	5	20	0,9266	0,4190	0,0356	0,0810	0,0596	0,11
30	91	relu	rmsprop	MeanAbsoluteError	5	50	0,9415	0,3472	0,0283	0,0692	0,0532	0,11
31	91	relu	rmsprop	MeanAbsolutePercentageError	3	20	0,4518	0,9609	0,2657	0,1961	0,1630	0,37
32	91	relu	rmsprop	MeanAbsolutePercentageError	3	50	0,6020	0,7550	0,1929	0,1546	0,1389	0,32
33	91	relu	rmsprop	MeanAbsolutePercentageError	4	20	0,7587	0,6115	0,1169	0,1277	0,1081	0,27
34	91	relu	rmsprop	MeanAbsolutePercentageError	4	50	0,9113	0,3845	0,0430	0,0758	0,0655	0,13
35	91	relu	rmsprop	MeanAbsolutePercentageError	5	20	0,8633	0,5855	0,0663	0,1177	0,0814	0,15
36	91	relu	rmsprop	MeanAbsolutePercentageError	5	50	0,9462	0,3500	0,0261	0,0691	0,0511	0,11
37	91	softplus	adam	MeanAbsoluteError	3	20	0,8195	0,6266	0,0875	0,1243	0,0935	0,20
38	91	softplus	adam	MeanAbsoluteError	3	50	0,8697	0,5223	0,0631	0,1022	0,0795	0,16
39	91	softplus	adam	MeanAbsoluteError	4	20	0,8842	0,5248	0,0561	0,1028	0,0749	0,15
40	91	softplus	adam	MeanAbsoluteError	4	50	0,9122	0,4406	0,0425	0,0889	0,0652	0,14
41	91	softplus	adam	MeanAbsoluteError	5	20	0,8474	0,6347	0,0740	0,1252	0,0860	0,16
42	91	softplus	adam	MeanAbsoluteError	5	50	0,9117	0,4711	0,0428	0,0897	0,0654	0,12
43	91	softplus	adam	MeanAbsolutePercentageError	3	20	0,6533	0,7564	0,1680	0,1578	0,1296	0,31
44	91	softplus	adam	MeanAbsolutePercentageError	3	50	0,8586	0,5380	0,0685	0,1085	0,0828	0,19
45	91	softplus	adam	MeanAbsolutePercentageError	4	20	0,8780	0,5390	0,0591	0,1069	0,0769	0,16
46	91	softplus	adam	MeanAbsolutePercentageError	4	50	0,9151	0,4345	0,0411	0,0867	0,0641	0,13
47	91	softplus	adam	MeanAbsolutePercentageError	5	20	0,8035	0,7646	0,0952	0,1500	0,0976	0,17

Çizelge 4.7 Kayseri için 144 farklı parametre kombinasyonu ile elde edilen mimarilere ait sonuçlar (devam)

Çalışma numarası	Değişken sayısı	Aktivasyon fonksiyonu	Optimizasyon algoritması	Kayıp fonksiyonu	Katman sayısı	Epok sayısı	R2	OMH (/100.000)	OKH (/100.000.000.000)	OMYH	OKHK (/1.000.000)	Hataların standart sapması
48	91	softplus	adam	MeanAbsolutePercentageError	5	50	0,9146	0,4511	0,0414	0,0894	0,0643	0,13
49	91	softplus	adamax	MeanAbsoluteError	3	20	0,8369	0,6508	0,0790	0,1312	0,0889	0,20
50	91	softplus	adamax	MeanAbsoluteError	3	50	0,8546	0,5973	0,0705	0,1183	0,0840	0,18
51	91	softplus	adamax	MeanAbsoluteError	4	20	0,8606	0,5909	0,0676	0,1183	0,0822	0,18
52	91	softplus	adamax	MeanAbsoluteError	4	50	0,8846	0,5149	0,0559	0,1034	0,0748	0,16
53	91	softplus	adamax	MeanAbsoluteError	5	20	0,8688	0,5815	0,0636	0,1144	0,0797	0,17
54	91	softplus	adamax	MeanAbsoluteError	5	50	0,8868	0,5159	0,0549	0,1005	0,0741	0,15
55	91	softplus	adamax	MeanAbsolutePercentageError	3	20	-0,094	1,3335	0,5303	0,2660	0,2303	0,47
56	91	softplus	adamax	MeanAbsolutePercentageError	3	50	0,5411	0,9021	0,2224	0,1799	0,1491	0,31
57	91	softplus	adamax	MeanAbsolutePercentageError	4	20	0,8598	0,6000	0,0679	0,1194	0,0824	0,18
58	91	softplus	adamax	MeanAbsolutePercentageError	4	50	0,8607	0,5537	0,0675	0,1110	0,0822	0,17
59	91	softplus	adamax	MeanAbsolutePercentageError	5	20	0,8523	0,6072	0,0716	0,1211	0,0846	0,17
60	91	softplus	adamax	MeanAbsolutePercentageError	5	50	0,8607	0,5974	0,0675	0,1177	0,0822	0,17
61	91	softplus	rmsprop	MeanAbsoluteError	3	20	0,5993	0,8141	0,1942	0,1680	0,1394	0,33
62	91	softplus	rmsprop	MeanAbsoluteError	3	50	0,6597	0,6878	0,1649	0,1422	0,1284	0,31
63	91	softplus	rmsprop	MeanAbsoluteError	4	20	0,8610	0,5844	0,0674	0,1141	0,0821	0,17
64	91	softplus	rmsprop	MeanAbsoluteError	4	50	0,9087	0,4602	0,0443	0,0890	0,0665	0,13
65	91	softplus	rmsprop	MeanAbsoluteError	5	20	0,8731	0,5436	0,0615	0,1077	0,0784	0,16
66	91	softplus	rmsprop	MeanAbsoluteError	5	50	0,8670	0,6139	0,0645	0,1210	0,0803	0,14
67	91	softplus	rmsprop	MeanAbsolutePercentageError	3	20	0,3565	1,0005	0,3119	0,2059	0,1766	0,40
68	91	softplus	rmsprop	MeanAbsolutePercentageError	3	50	0,5832	0,7320	0,2020	0,1477	0,1421	0,32
69	91	softplus	rmsprop	MeanAbsolutePercentageError	4	20	0,8528	0,5891	0,0713	0,1152	0,0845	0,17
70	91	softplus	rmsprop	MeanAbsolutePercentageError	4	50	0,8802	0,5340	0,0580	0,1040	0,0762	0,15
71	91	softplus	rmsprop	MeanAbsolutePercentageError	5	20	0,8299	0,6664	0,0824	0,1329	0,0908	0,18

Çizelge 4.7 Kayseri için 144 farklı parametre kombinasyonu ile elde edilen mimarilere ait sonuçlar (devam)

Çalışma numarası	Değişken sayısı	Aktivasyon fonksiyonu	Optimizasyon algoritması	Kayıp fonksiyonu	Katman sayısı	Epok sayısı	R2	OMH (/100.000)	OKH (/100.000.000.000)	OMYH	OKHK (/1.000.000)	Hataların standart sapması
72	91	softplus	rmsprop	MeanAbsolutePercentageError	5	50	0,8831	0,5256	0,0566	0,1055	0,0753	0,15
73	50	relu	adam	MeanAbsoluteError	3	20	0,8222	0,6744	0,0862	0,1332	0,0928	0,19
74	50	relu	adam	MeanAbsoluteError	3	50	0,8425	0,6116	0,0763	0,1200	0,0874	0,18
75	50	relu	adam	MeanAbsoluteError	4	20	0,8830	0,5520	0,0567	0,1101	0,0753	0,16
76	50	relu	adam	MeanAbsoluteError	4	50	0,9021	0,4728	0,0474	0,0924	0,0689	0,14
77	50	relu	adam	MeanAbsoluteError	5	20	0,9038	0,4863	0,0466	0,0960	0,0683	0,15
78	50	relu	adam	MeanAbsoluteError	5	50	0,9121	0,4459	0,0426	0,0869	0,0653	0,13
79	50	relu	adam	MeanAbsolutePercentageError	3	20	0,7977	0,7029	0,0981	0,1423	0,0990	0,22
80	50	relu	adam	MeanAbsolutePercentageError	3	50	0,8297	0,6330	0,0825	0,1251	0,0908	0,19
81	50	relu	adam	MeanAbsolutePercentageError	4	20	0,8541	0,5717	0,0707	0,1116	0,0841	0,17
82	50	relu	adam	MeanAbsolutePercentageError	4	50	0,8998	0,4802	0,0486	0,0932	0,0697	0,14
83	50	relu	adam	MeanAbsolutePercentageError	5	20	0,8758	0,5871	0,0602	0,1144	0,0776	0,15
84	50	relu	adam	MeanAbsolutePercentageError	5	50	0,9165	0,4190	0,0405	0,0840	0,0636	0,13
85	50	relu	adamax	MeanAbsoluteError	3	20	0,7941	0,7474	0,0998	0,1503	0,0999	0,22
86	50	relu	adamax	MeanAbsoluteError	3	50	0,8426	0,6475	0,0763	0,1281	0,0873	0,18
87	50	relu	adamax	MeanAbsoluteError	4	20	0,8637	0,5921	0,0661	0,1174	0,0813	0,17
88	50	relu	adamax	MeanAbsoluteError	4	50	0,8776	0,5036	0,0593	0,0980	0,0770	0,16
89	50	relu	adamax	MeanAbsoluteError	5	20	0,8970	0,4913	0,0499	0,0966	0,0707	0,15
90	50	relu	adamax	MeanAbsoluteError	5	50	0,9107	0,4648	0,0433	0,0894	0,0658	0,13
91	50	relu	adamax	MeanAbsolutePercentageError	3	20	0,4963	1,0758	0,2441	0,2112	0,1562	0,32
92	50	relu	adamax	MeanAbsolutePercentageError	3	50	0,8200	0,7034	0,0872	0,1395	0,0934	0,20
93	50	relu	adamax	MeanAbsolutePercentageError	4	20	0,8481	0,6144	0,0736	0,1205	0,0858	0,18
94	50	relu	adamax	MeanAbsolutePercentageError	4	50	0,8675	0,5474	0,0642	0,1090	0,0801	0,17
95	50	relu	adamax	MeanAbsolutePercentageError	5	20	0,8695	0,5551	0,0633	0,1115	0,0795	0,17

Çizelge 4.7 Kayseri için 144 farklı parametre kombinasyonu ile elde edilen mimarilere ait sonuçlar (devam)


Çalışma numarası	Değişken sayısı	Aktivasyon fonksiyonu	Optimizasyon algoritması	Kayıp fonksiyonu	Katman sayısı	Epok sayısı	R2	OMH (/100.000)	OKH (/100.000.000.000)	OMYH	OKHK (/1.000.000)	Hataların standart sapması
96	50	relu	adamax	MeanAbsolutePercentageError	5	50	0,9071	0,4454	0,0450	0,0883	0,0671	0,14
97	50	relu	rmsprop	MeanAbsoluteError	3	20	0,7177	0,7851	0,1368	0,1640	0,1170	0,30
98	50	relu	rmsprop	MeanAbsoluteError	3	50	0,7230	0,7262	0,1342	0,1515	0,1159	0,30
99	50	relu	rmsprop	MeanAbsoluteError	4	20	0,8692	0,5731	0,0634	0,1131	0,0796	0,16
100	50	relu	rmsprop	MeanAbsoluteError	4	50	0,8826	0,5427	0,0569	0,1074	0,0754	0,15
101	50	relu	rmsprop	MeanAbsoluteError	5	20	0,9057	0,4859	0,0457	0,0957	0,0676	0,15
102	50	relu	rmsprop	MeanAbsoluteError	5	50	0,9274	0,4118	0,0352	0,0812	0,0593	0,12
103	50	relu	rmsprop	MeanAbsolutePercentageError	3	20	0,6311	0,8714	0,1788	0,1794	0,1337	0,32
104	50	relu	rmsprop	MeanAbsolutePercentageError	3	50	0,7264	0,7155	0,1326	0,1479	0,1152	0,30
105	50	relu	rmsprop	MeanAbsolutePercentageError	4	20	0,8194	0,6397	0,0875	0,1284	0,0935	0,20
106	50	relu	rmsprop	MeanAbsolutePercentageError	4	50	0,8837	0,5051	0,0563	0,0998	0,0751	0,15
107	50	relu	rmsprop	MeanAbsolutePercentageError	5	20	0,8722	0,5550	0,0620	0,1111	0,0787	0,16
108	50	relu	rmsprop	MeanAbsolutePercentageError	5	50	0,9135	0,4805	0,0419	0,0934	0,0648	0,12
109	50	softplus	adam	MeanAbsoluteError	3	20	0,8482	0,6392	0,0736	0,1274	0,0858	0,18
110	50	softplus	adam	MeanAbsoluteError	3	50	0,8446	0,6055	0,0753	0,1188	0,0868	0,18
111	50	softplus	adam	MeanAbsoluteError	4	20	0,8497	0,6185	0,0729	0,1211	0,0854	0,18
112	50	softplus	adam	MeanAbsoluteError	4	50	0,8684	0,5830	0,0638	0,1168	0,0799	0,17
113	50	softplus	adam	MeanAbsoluteError	5	20	0,8343	0,6896	0,0803	0,1359	0,0896	0,18
114	50	softplus	adam	MeanAbsoluteError	5	50	0,8548	0,6335	0,0704	0,1252	0,0839	0,17
115	50	softplus	adam	MeanAbsolutePercentageError	3	20	0,5396	0,8774	0,2231	0,1798	0,1494	0,35
116	50	softplus	adam	MeanAbsolutePercentageError	3	50	0,7799	0,6648	0,1066	0,1364	0,1033	0,25
117	50	softplus	adam	MeanAbsolutePercentageError	4	20	0,8519	0,6262	0,0718	0,1228	0,0847	0,17
118	50	softplus	adam	MeanAbsolutePercentageError	4	50	0,8671	0,5602	0,0644	0,1121	0,0802	0,17
119	50	softplus	adam	MeanAbsolutePercentageError	5	20	0,8424	0,6770	0,0764	0,1340	0,0874	0,18

Çizelge 4.7 Kayseri için 144 farklı parametre kombinasyonu ile elde edilen mimarilere ait sonuçlar (devam)

Çalışma numarası	Değişken sayısı	Aktivasyon fonksiyonu	Optimizasyon algoritması	Kayıp fonksiyonu	Katman sayısı	Epok sayısı	R2	OMH (/100.000)	OKH (/100.000.000.000)	OMYH	OKHK (/1.000.000)	Hataların standart sapması
120	50	softplus	adam	MeanAbsolutePercentageError	5	50	0,8769	0,5530	0,0597	0,1107	0,0772	0,17
121	50	softplus	adamax	MeanAbsoluteError	3	20	0,8140	0,7113	0,0902	0,1406	0,0950	0,20
122	50	softplus	adamax	MeanAbsoluteError	3	50	0,8345	0,6827	0,0802	0,1343	0,0896	0,19
123	50	softplus	adamax	MeanAbsoluteError	4	20	0,8377	0,6600	0,0786	0,1301	0,0887	0,19
124	50	softplus	adamax	MeanAbsoluteError	4	50	0,8438	0,6390	0,0757	0,1266	0,0870	0,18
125	50	softplus	adamax	MeanAbsoluteError	5	20	0,8397	0,6665	0,0777	0,1315	0,0881	0,19
126	50	softplus	adamax	MeanAbsoluteError	5	50	0,8542	0,6298	0,0707	0,1243	0,0841	0,17
127	50	softplus	adamax	MeanAbsolutePercentageError	3	20	-0,004	1,2239	0,4868	0,2396	0,2206	0,43
128	50	softplus	adamax	MeanAbsolutePercentageError	3	50	0,4695	0,9583	0,2571	0,1872	0,1603	0,31
129	50	softplus	adamax	MeanAbsolutePercentageError	4	20	0,8258	0,6626	0,0844	0,1311	0,0919	0,19
130	50	softplus	adamax	MeanAbsolutePercentageError	4	50	0,8496	0,6253	0,0729	0,1232	0,0854	0,18
131	50	softplus	adamax	MeanAbsolutePercentageError	5	20	0,8338	0,6677	0,0806	0,1337	0,0898	0,19
132	50	softplus	adamax	MeanAbsolutePercentageError	5	50	0,8467	0,6253	0,0743	0,1252	0,0862	0,18
133	50	softplus	rmsprop	MeanAbsoluteError	3	20	0,7211	0,7533	0,1352	0,1570	0,1163	0,30
134	50	softplus	rmsprop	MeanAbsoluteError	3	50	0,7764	0,7030	0,1084	0,1448	0,1041	0,25
135	50	softplus	rmsprop	MeanAbsoluteError	4	20	0,8292	0,6804	0,0828	0,1322	0,0910	0,18
136	50	softplus	rmsprop	MeanAbsoluteError	4	50	0,8673	0,5756	0,0643	0,1156	0,0802	0,17
137	50	softplus	rmsprop	MeanAbsoluteError	5	20	0,8504	0,6420	0,0725	0,1283	0,0851	0,18
138	50	softplus	rmsprop	MeanAbsoluteError	5	50	0,8602	0,5973	0,0677	0,1197	0,0823	0,18
139	50	softplus	rmsprop	MeanAbsolutePercentageError	3	20	0,4162	0,9751	0,2829	0,1969	0,1682	0,39
140	50	softplus	rmsprop	MeanAbsolutePercentageError	3	50	0,7254	0,7103	0,1331	0,1480	0,1154	0,30
141	50	softplus	rmsprop	MeanAbsolutePercentageError	4	20	0,8349	0,6494	0,0800	0,1291	0,0894	0,19
142	50	softplus	rmsprop	MeanAbsolutePercentageError	4	50	0,8591	0,6099	0,0683	0,1214	0,0826	0,18
143	50	softplus	rmsprop	MeanAbsolutePercentageError	5	20	0,8524	0,6376	0,0715	0,1263	0,0846	0,18
144	50	softplus	rmsprop	MeanAbsolutePercentageError	5	50	0,8671	0,5807	0,0644	0,1146	0,0802	0,17


Sonuç olarak, DÖ ile konut değerlemesinde, 91 değişken ile 18 numaralı mimaride; aktivasyon fonksiyonu relu, optimizasyon algoritması adamax, kayıp fonksiyonu MeanAbsoluteError, katman sayısı 5 ve epok sayısı olarak ise 50 olan parametreler en iyi sonucu vermiştir. Değerleme çalışmalarında hata tutarı yerine hata yüzdesi kullanımı daha makul görülmektedir. Buna göre kayıp fonksiyonu olarak MeanAbsoluteError'un en iyi sonucu vermesi tersine bir durumun gerçekleştiği kanaatini oluşturabilmektedir. Ancak zaten 91 değişken ile en iyi ikinci sonucu veren modelin kayıp fonksiyonu parametresinin MeanAbsolutePercentageError olması, her iki kayıp fonksiyonu parametresinin de Kayseri'deki çalışma alanı özelinde kullanılabilir olduğunu göstermiştir. Kayseri'de DÖ tabanlı konut değerlerinin tahminine yönelik olarak değişken sayısının optimize edilmesi ile 50 değişken sayısına ulaşılmış ve buna göre en iyi tahmin sonucunu veren parametrelerin aktivasyon fonksiyonunda relu, optimizasyon algoritmasında adam, kayıp fonksiyonunda MeanAbsolutePercentageError, katman sayısında 5 ve epok sayısında ise 50 olduğu bulunmuştur.

Son olarak verinin %20'sini teşkil eden 279 adet verinin test edilmesi ile en iyi kayıp fonksiyonuna 50 epok ile ulaşıldığı Şekil 4.15'de gösterilmektedir.



Şekil 4.15 Eğitim verisinin kayıp fonksiyonu grafiği

Gerçek değerler ile tahmin edilen değerlerin dağılım grafiği ise Şekil 4.16'da gösterilmektedir.



Şekil 4.16 18 numaralı DÖ modelinin değer-tahmin dağılım grafiği

Belirlenen ölçütlere göre en iyi ve optimum sonucu 18 numaralı mimari; normalize edilmiş hali ile r^2 0,9472, OMH 0,30230, OKH 0,0256, OMYH 0,0566, OKHK 0,0506 ve hataların standart sapmasında 0,09 sonuçlarını vermiştir.

4.5 Derin Öğrenme ile Değer Tahmin Sonuçlarının Değerlendirilmesi

Kayseri'deki çalışma sınırları dâhilinde çok katlı bir binada yer alan bir konutun piyasa değerinin toplu değerlendirme usullerinden biri olan DÖ ile tespit edilebilmesi amacına yönelik olarak DÖ mimarileri geliştirilmiştir. Bu mimariler içerisinde en iyi sonuç veren mimariler değerlendirilmiştir. DÖ mimarilerinin başarısı r^2 , OMH, OKH, OMYH, OKHK

ve hataların standart sapması olmak üzere 6 adet ölçütün sonuçlarına göre belirlenmiştir. Buna göre en iyi sonucu veren 4 adet mimari belirlenmiştir (Çizelge 4.8).

Çizelge 4.8 Kayseri için belirlenen en iyi 4 DÖ mimarisinin sonuçları

Mimari Numarası	Değişken sayısı	R2	OMH (x100.000)	OKH (x100.000.000.000)	OMYH	OKHK (x1.000.000)	Hataların standart sapması
18	91	0,9472	0,3023	0,0256	0,0566	0,0506	0,09
12	91	0,9542	0,3042	0,0222	0,0601	0,0471	0,10
102	50	0,9274	0,4118	0,0352	0,0812	0,0593	0,12
84	50	0,9165	0,4190	0,0405	0,0840	0,0636	0,13

OMYH ölçütünün en iyi mimariler içerisinde 1. mimariyi belirleme bakımından önemi bulunmaktadır. Konut değerlendirme çalışmaları sonucunda kesin bir değerden bahsedilememektedir. Amaca göre yapılan değerlendirme işlemlerinde kullanılan yöntemle göre sonuçlar raporlanmaktadır. Toplu değerlendirme metodu geliştirmek için yapılan DÖ çalışmasında elde edilen sonuçların, OMYH ölçütüne göre değerlendirmeyi ön planda tutmak daha mantıklıdır. Çünkü değerlemede amaç en yakın değeri tespit etmek olduğu için ve toplu değerlendirme işlemlerinde oransal bakımdan en yakın sonucu elde etmek önem taşımaktadır.

Bulgulara göre, 91 ve 50 değişkenli mimarilerin her bir ölçüte göre en iyi sonuçları veren mimariler ayrı ayrı belirlenmiştir. 91 değişkenli mimarilerde, 6 ölçütte birden en iyi sonucu veren 18 ve 12 numaralı mimarilerdir. 50 değişkenli mimarilerde ise, 6 ölçütte birden en iyi sonucu veren 102 ve 84 numaralı mimarilerdir. OMYH ölçütü bakımından ise, 18 numaralı çalışma (91 değişkenli) ve 102 numaralı çalışma (50 değişkenli) en iyi sonuçları vermiştir. Bu nedenle, 18 numaralı çalışma Kayseri'deki çalışma alanında geçerli olmak üzere, konut değerlemede en iyi DÖ mimarisi olarak seçilmiştir. Buna ek olarak, 50 değişken bazında 102 numaralı mimari de kullanılabilir yeterlilikte iyi bir DÖ mimarisi olarak bulunmuştur.

Belirlenen en iyi 4 DÖ mimarisi için yazılım parametreleri Çizelge 4.9’da gösterilmiştir. Buna göre relu en uygun aktivasyon fonksiyonu olarak ortaya çıkmıştır. Adamax, adam ve rmsprop optimizasyon algoritması olarak en iyi sonuçları vermişlerdir. Kayıp fonksiyonu olarak; MeanAbsoluteError ve MeanAbsolutePercentageError olumlu sonuç verirken, katman sayısı olarak; 5, epok sayısı olarak ise; 50 değeri beklenen başarıyı sağlayan parametreler olarak bulunmuştur.

Çizelge 4.9 Kayseri için belirlenen en iyi 4 DÖ mimarisinin parametreleri

Mimari Numarası	Değişken sayısı	Aktivasyon fonksiyonu	Optimizasyon algoritması	Kayıp fonksiyonu	Katman sayısı	Epok sayısı
18	91	relu	adamax	MeanAbsoluteError	5	50
12	91	relu	adam	MeanAbsolutePercentageError	5	50
102	50	relu	rmsprop	MeanAbsoluteError	5	50
84	50	relu	adam	MeanAbsolutePercentageError	5	50

Belirlenen en iyi 4 mimaride de relu aktivasyon fonksiyonu kullanılmıştır. Relu fonksiyonu, girdi olarak verilen değerin negatif olması durumunda 0 (sıfır), pozitif veya 0 (sıfır) olması durumunda ise verilen değerin aynısını çıktı olarak verir. Yani, fonksiyon girdi olarak aldığı değeri doğrudan geçirirken, negatif değerleri sıfıra eşitleyerek çıktı üretmektedir. Konut değeri tahmini konusunda relu’nun kullanılabilecek uygun bir aktivasyon fonksiyonu olduğu tespit edilmiştir.

Konut değeri tahminlerinde optimizasyon algoritmalarından adamax, adam ve rmsprop’un herhangi birinin kullanılabileceği görülmüştür.

Kayıp fonksiyonu olarak ise MeanAbsoluteError ve MeanAbsolutePercentageError’un DÖ mimarisinin eğitiminde iyi sonuç vermesi nedeniyle, miktar ve oransal olarak hataların azaltılması konusunda bu parametrelerin kullanılmasının uygun olduğu ortaya çıkmıştır.

Değer tahmini konusunda optimum katman sayısı 5 olarak belirlenmiştir. Katman sayısının 5'ten çok olması daha iyi sonuç vereceği anlamına gelmemektedir. 3 ve 4 katman sayısı da denenmiş, ancak 5 katman sayısı ile elde edilen sonuçlar kadar iyi sonuç vermemiştir.

Epok sayısının 5, 10, 20 gibi değerler alması DÖ mimarisinin eğitimi için yeterli olmamıştır. 50'nin üzerinde olan 100, 200, 500 gibi epok değerleri ise modelin aşırı öğrenmesine neden olmaktadır. O nedenle 50 epok sayısının daha uygun olduğuna karar verilmiştir.


4.6 Diğer MÖ Yöntemleriyle Değer Tahmini

Geleneksel yöntemlerden olan ÇDR ve CAR yöntemleriyle de değer tahmini yapılmış, DÖ'deki ölçütlerin aynısı bu yöntemler için de hesaplanarak sonuçlar karşılaştırılmıştır.

4.6.1 ÇDR yöntemi ile konut değerlendirme


ÇDR analizi bir bağımlı değişkeni birden fazla bağımsız değişkenin nasıl açıkladığının anlaşılması için yapılır. Bağımsız değişkenlerden yola çıkarak geliştirilen model vasıtası ile bağımlı değişken tahminleri yapılabilir. Bu yöntemle konut özelliklerinden, konut değerinin tahmininin yapılması da mümkündür. Bu çalışmada eğitim verisi ile ÇDR modeli oluşturulup, aynı model test verisine de tatbik edilerek değer tahmini yapılmıştır.

ÇDR modeli oluşturulmuş ve modelin eğitim verisine tatbik edilmesiyle r^2 0,85, OMH 0,69148, OKH 0,80562628, OMYH 0,1304, OKHK 0,89756 ve hataların standart sapması 0,16 olarak bulunmuştur. Değer ve tahmin edilen değerlerin dağılım grafiği Şekil 4.17'de gösterilmiştir.



Şekil 4.17 ÇDR yöntemi kullanılarak eğitim verisi kullanılarak değer tahmini dağılım grafiği

Eğitim verisi ile oluşturulan regresyon modelinin test verisine tatbik edilmesiyle ise r^2 0,7919 OMH 0,80067, OKH 0,10085393041, OMYH 0,1481, OKHK 0,100426 ve hataların standart sapması 0,20 bulunmuştur. Test verisiyle yapılan ÇDR çalışmasında değer ve tahmin edilen değerlerin dağılım grafiği Şekil 4.18’de gösterilmiştir.




Şekil 4.18 ÇDR yöntemi kullanılarak test verisi ile değer tahmini dağılım grafiği

Bu sonuçlardan konutların 80.067 TL'ye kadar ve oran olarak ise %14,81 ile değerinin tahmin edilebildiği anlaşılmaktadır. Konut değeri tahmininde 80.000 TL civarında yaklaşık sonuç tatminkâr sayılabilmektedir.


4.6.2 CAR yöntemi ile konut değerlendirme

CAR modeli oluşturulmuş ve modelin eğitim verisine tatbik edilmesiyle r^2 0,85, OMH 0,68899, OKH 0,078140332, OMYH 0,1300, OKHK 0,088397 ve hataların standart sapması 0,16 olarak bulunmuştur. Değer ve tahmin edilen değerlerin dağılım grafiği Şekil 4.19'da gösterilmiştir.



Şekil 4.19 CAR yöntemi kullanılarak eğitim verisi ile değer tahmini dağılım grafiği

Oluşturulan CAR modelinin test verisine tatbik edilmesiyle r^2 0,83, OMH 0,71384, OKH 0,081153329, OMYH 0,1300, OKHK 0,090085 ve hataların standart sapması 0,17 olarak bulunmuştur. Değer ve tahmin edilen değerlerin dağılım grafiği Şekil 4.20’de gösterilmiştir.



Şekil 4.20 CAR yöntemi kullanılarak test verisi ile değer tahmini dağılım grafiği

CAR yöntemi ile test verisi üzerinde yapılan tahminlerin ölçüt sonuçlarına bakıldığında 71.384 TL ortalama mutlak hata ve %12,98’lik bir yaklaşık oran sonucuna ulaşılmıştır. Dolayısı ile bir toplu değerlendirme yöntemine göre uygun denebilecek bir değer tahmini başarıları çıkmıştır.

4.6.3 ÇDR ve CAR yöntemleri ile konut değerlendirme sonuçları

DÖ ile konut değeri tahminleri sadece test verileri üzerinde yapıldığından, DÖ yönteminin diğer ÇDR ve CAR yöntemleriyle karşılaştırılabilir olması için diğer yöntemlerle de yapılan çalışmalarda da test verilerinin sonuçları kullanılmıştır. Diğer yöntemlerle geliştirilen modellerde eğitim verileri de tahmin edilmiş ve grafik halinde

gösterilmiştir. Böylelikle diğer yöntemlerin de kendi içinde eğitim verisi sonuç grafiğinin ardından test verisi sonuç grafiğindeki saçılmanın miktarı görsel olarak gözlemlenebilmektedir.

CAR ve ÇDR yöntemleri ile geliştirilen değer tahmin modelleri toplu değerlendirme çalışmalarında kullanılabilecek ölçüde etkili sonuç vermiştir. Bunların içerisinde CAR yöntemi ÇDR yöntemine göre daha iyi sonuç vermiştir. CAR yönteminde verilerin konumsal özellikleri de değeri belirleyen unsur olarak model kapsamında değerlendirildiği için ÇDR yönteminden daha iyi sonuç vermesi zaten beklenirdi.

Sonuç olarak toplu değerlendirme çalışmalarında ÇDR veya CAR yöntemlerinden biri kullanılacak olsa, imkânlar ölçüsünde CAR yönteminin ÇDR'ye tercih edilmesi gerektiği ortaya çıkmıştır.


4.7 DÖ ile Diğer MÖ Uygulama Sonuçlarının Karşılaştırılması

Kayseri'deki çalışma alanı için belirlenen DÖ mimarileri ile yine diğer MÖ yöntemleri ile geliştirilen ÇDR ve CAR modellerinin başarı sonuçları Çizelge 4.10'da listelenmiştir.

Çizelge 4.10 DÖ ile ÇDR ve CAR sonuçlarının karşılaştırılması


Yöntemin adı	R^2	OMH (x100.000)	OKH (x100.000.000.000)	OMYH	OKHK (x1.000.000)	Standart Sapma
Çoklu doğrusal regresyon	0,79	0,8007	0,1009	0,148	0,1004	0,20
Coğrafi ağırlıklı regresyon	0,83	0,7138	0,0812	0,130	0,0901	0,17
Derin öğrenme (50 değişkenli)	0,93	0,4118	0,0352	0,081	0,0593	0,12
Derin öğrenme (91 değişkenli)	0,95	0,3023	0,0256	0,057	0,0566	0,09

Öncelikle Şekil 4.21’de görüldüğü gibi r^2 ölçütüne göre durum değerlendirilmiştir. R^2 değerinin mümkün olduğunca 1’e yakın olması istenmektedir. R^2 değeri ne kadar yüksek ise modelin veri ile o denli uyum içerisinde olduğu anlamı ortaya çıkmaktadır. ÇDR’da 0,79, CAR’da 0,83 değeri elde edilmiştir. Buna karşın DÖ yönteminde 50 değişkenli mimaride r^2 0,93 hesaplanırken, 91 değişkenli DÖ mimarisinde r^2 0,95 bulunmuştur. Bu durumda DÖ modelinin veri uyumu açısından en etkili model olduğu ortaya çıkmıştır. DÖ’den sonra en etkili r^2 sonucunu CAR modeli vermiştir. ÇDR modelinin r^2 değeri DÖ modeline kıyasla çok daha düşük kalmaktadır.



Şekil 4.21 DÖ, ÇDR ve CAR yöntemlerinin r^2 karşılaştırması


OMYH ölçütüyle, konutlara ilişkin gerçek değer ile tahmin edilen değer arasındaki farkın mutlak hata oranlarının ortalaması hesaplanmıştır. OMYH’nin 0’a yakın olması istenmektedir. ÇDR ile 0,148 OMYH değerine ulaşılmış olup, bu değer CAR’da 0,13 olmuştur. Buna karşın DÖ modelinde 50 değişken kullanmak suretiyle OMYH 0,081 hesaplanmıştır. DÖ yönteminde 91 değişken kullanılarak ise 0,057 gibi çok daha başarılı bir sonuç elde edilmiştir (Şekil 4.22).



Şekil 4.22 DÖ, ÇDR ve CAR yöntemlerinin OMYH karşılaştırması

OMYH sonuçları göz önüne alındığında, konutların değerini %5,7 veya %8,1 ortalama mutlak hata oranı ile tahmin edebilen DÖ modellerinin belirlenebildiği, buna karşın diğer MÖ yöntemlerinden olan CAR ile %13 ve ÇDR ile ise %14,8 OMYH ile konut değerlerinin tahmin edilebildiği sonucuna varılmıştır.


OMH ölçüt sonuçları da DÖ yönteminin diğer ÇDR ve CAR yöntemlerine göre çok daha iyi sonuçların elde edilebileceği bir yöntem olduğunu göstermiştir (Şekil 4.23). Bu değerlerin düşük olması modelin başarılı olduğunun bir göstergesidir.




Şekil 4.23 DÖ, ÇDR ve CAR yöntemlerinin OMH karşılaştırması

DÖ yöntemleri ile ortalama 30.230 TL ve 41.180 TL hata tutarları ile değer tahminleri yapılabilmektedir. CAR ile 71.380 TL ve ÇDR ile ise 80.070 TL ortalama hata tutarı ile konut değerleri tahmin edilebilmiştir.

OKH ve OKHK ölçüt sonuçları da hesaplanmıştır. Bu ölçütlerin sonuçları ne kadar düşük ise, model o derece başarılı kabul edilir. Bu ölçütlere göre de yine DÖ yönteminin 91 değişkenli modeli en başarılı model olarak ortaya çıkmıştır (Şekil 4.24-4.25).




Şekil 4.24 DÖ, ÇDR ve CAR yöntemlerinin OKH karşılaştırması



Şekil 4.25 DÖ, ÇDR ve CAR yöntemlerinin OKHK karşılaştırması

Konut değerlerinin tahmin edilmesi ve tahmin edilen değerlerin gerçek değere olan yakınlık derecesi çalışmanın başarısını göstermektedir. Hata miktarlarının standart sapması da geliştirilen modellerin başarısı hakkında fikir vermektedir. Tahminlerin hata miktarlarının standart sapması mümkün olduğunca düşük olmalıdır. Buna göre DÖ yönteminin hem 91 hem de 51 değişkenle çalıştırılmasıyla belirlenen modellerin, ÇDR ve CAR modellerine ait hataların standart sapmasından daha düşük çıktığı Şekil 4.26’da görülmektedir.



Şekil 4.26 DÖ, ÇDR ve CAR yöntemlerinde hataların standart sapma karşılaştırması

Dolayısı ile hataların standart sapması ölçütüne göre de DÖ diğer MÖ yöntemlerine göre daha başarılı olmuştur.

5. SONUÇ VE DEĞERLENDİRME

Kayseri şehir merkezindeki Kocasinan, Melikgazi ve Talas ilçelerinde genellikle konut alım-satımının çok olduğu, çok katlı binalarda yer alan konut niteliğindeki gayrimenkullerin bulunduğu bölge çalışma alanı olarak belirlenmiştir. Bu bölge Kayseri'nin şehir merkezi olarak da tanımlanmaktadır. Çalışma alanı içerisinde, çok katlı binalarda yer alan konutların piyasa değerlerini tahmin edebilecek bir DÖ mimarisi geliştirilmeye çalışılmıştır. Bu kapsamda denenen farklı yazılım parametrelerinin hangisinin değer tahmininde tutarlı olduğu belirlenmeye çalışılmıştır.

Öncelikle DÖ mimarisinin geliştirilmesi için kullanılmak üzere 1365 adet veri toplanmıştır. 1365 adet verinin tamamı çalışma alanı içerisinde çok katlı binalarda yer alan, konut niteliğindeki bağımsız bölümleri ifade etmektedir. Alım-satım işlemi gerçekleştirilmiş olan konutların iç özellikleri, binanın özellikleri ve konumsal özellikleri tespit edilip veri tabanına kaydedilmiştir. Çok sayıdaki verilerin bir veri tabanında tutulması veri kalitesi açısından önem taşımaktadır. Ayrıca konutlar konumsal nitelikte bir veri olduğu için, geometrik verileri depolayabilecek türde bir veri tabanı seçilmiş ve veri tabanı bu ihtiyaca uygun şekilde tasarlanmıştır.

DÖ mimarisinin oluşturulabilmesi için geliştirilen scriptin girdi olarak kullanacağı verinin, yazılım gereksinimlerine uygun hâle dönüştürülmesi gerekmektedir. Bunun için veri manuel ve otomatik yöntemlerle düzenlenmiş, ayrıca kukla değişkenli bir yapıya dönüştürülmesi de sağlanmıştır.

Normalde 44 adet bağımsız değişkenden oluşan veri kukla değişkenli bir yapıya dönüştürüldüğünde 91 adet değişken oluşmaktadır. Bunun yanı sıra değişkenler içerisinden konut değerine en çok etkisi olan, optimum sayıdaki değişkenlerin hangileri olduğu belirlenmiştir. Konut değerine etki eden, kukla değişkenli yapıya dönüştürülmüş hâliyle optimum değişken sayısı 50 olmuştur. Aslında ilk hali ile 44 olan değişken sayısı 23'e düşürülmüştür. Böylece veri toplamak için daha az kaynak ayırarak da istenen hedefe çok yakın bir sonuca ulaşmak mümkün olmaktadır. Yani 44 değişken yerine, 23 bağımsız değişken ve değer bağımlı değişkeninin kullanılması ile de değer tahmini

konusunda başarılı bir sonuç elde edilebileceği bulgusuna varılmıştır. Başka bir deyişle, geriye kalan 21 değişkenin çalışma alanında konut değeri tahmininde kullanılması için toplanmasına gerek olmadığı bulgusuna ulaşılmıştır.

Ayrıca, konut değerinin belirlenmesinde imar planı fonksiyonunun etkili olmadığı bulgusuna varılmıştır. Bunun nedeni her konutun imar planlarında zaten konut fonksiyonunu da içeren karma nitelikteki fonksiyonlardan birine sahip olmasıdır. Bu bulguya dayanarak, çalışma alanında imar planı verilerinin değer üzerinde etkisinin pek olmadığı sonucuna varılmıştır.

Değere pozitif yönde en çok etki eden numerik değişkenler sırayla; brüt alan, net alan, binanın kat adedi, oda sayısı, dairenin bulunduğu kat, ilkokula yakınlık, salon sayısı, ulaşım, banyo sayısı ve AVM'ye yakınlık olmuştur. Buna karşın, değere negatif yönde etki eden değişkenler ise; binanın yaşı, merkeze yakınlık, Y koordinatı, X koordinatı, taksi durağına yakınlık ve sağlık tesisine yakınlık olduğu bulgusu ortaya çıkmıştır.

Verinin mevcut hali ile ısı haritasında gösterimi de yapılarak, bir anlamda verinin değer değişkeninin mekânsal olarak harita üzerinde gösterimi yapılmıştır. Değer ısı haritası sayesinde Kayseri'deki çalışma alanında konut değerlerinin bölgesel olarak değişiminin izlenebilmesine olanak sağlanmıştır. Değerin histogram türünde normal dağılım grafiği de hazırlanmış, konumdan bağımsız olarak çalışma alanı içerisinde değer aralıklarının tespiti yapılmıştır.

DÖ mimarisinin geliştirilmesi aşamalar hâlinde gerçekleşmiştir. Verinin toplanması ve hazır hâle getirilmesinin ardından DÖ modeli oluşturulmuştur. DÖ modelinin oluşturulması için aktivasyon fonksiyonu, optimizasyon algoritması, kayıp fonksiyonu, katman sayısı ve epok sayısı parametrelerinden değer tahmini konusunda olumlu sonuç verenlerin, olası bütün kombinasyonları denenmiştir. DÖ ile değer tahmini için en uygun mimari arayışı, işin doğası gereği denemelere dayanmaktadır. 144 adet kombinasyon içerisinden en iyi sonucu veren mimariler belirlenmiştir. Bir mimarinin en iyi sonucu vermesi 6 farklı ölçütün hepsinde de en iyi sonucu vermesine dayanmaktadır. Sonuç olarak 91 değişkenle oluşturulan mimaride 2 tane ve 50 değişkenle oluşturulan

mimarilerde de 2 adet olmak üzere toplam 4 adet mimari bütün ölçütlerde başarılı bulunmuştur. Bunların içinden ise 91 değişkenle geliştirilen 1 tanesi ve 50 değişkenle geliştirilen mimariden de 1 tane seçmek adına OMYH ölçütünde en iyi sonucu veren mimariler en iyi DÖ mimarileri olarak saptanmıştır.

Sonuç olarak 91 adetten oluşan bütün değişkenlerle denenen en iyi mimari OMYH ölçütünde 0,0566 sonucunu vermiş, 50 adet değişkenden oluşan en iyi mimari ise yine OMYH ölçütünde 0,0593 olarak hesaplanmıştır. Bu hesaplamalar, Kayseri'deki çalışma alanında konut değerlemesinde kullanılmak üzere denenmiş en iyi DÖ mimarisinin %5 civarında bir hata payı ile doğru sonuç verdiği bulgusunu ortaya çıkarmıştır. Bu çalışma sonuçlarının sadece 3 ilçe merkezinde geçerli olduğu çalışmanın kısıtıdır.

Geliştirilmiş olan DÖ mimarisinin, Kayseri şehir merkezindeki çalışma alanında geçerli olmak kaydıyla, toplu değerlendirme çalışmalarında kullanılabilir olduğu görülmüştür. Piyasa değerinin esas alındığı bu çalışma, ihtiyaç doğrultusunda aynı çalışma alanında yapılmak şartıyla, güncel konut fiyat endeksi ile değer değişkeninin güncellenmesi ve en güncel yeni verilerin de eklenmesiyle mevcut bulgulardan daha iyi değerlere ulaşılabileceği de öngörülmektedir.

Elde edilen bulgulardan yola çıkarak, Kayseri'nin 3 merkez ilçesinde, konut alım-satımının yoğun olduğu bir alan için geliştirilmiş olan DÖ mimarisinin; yeni imar planlarının yapılması, toplu konut alanlarının planlanması, kentsel dönüşüm çalışmasının yapılması, toplu kamulaştırmaların yapılması, konutların vergi değerlerinin belirlenmesi ve güncellenmesi gibi işlerde, konut niteliğindeki çok katlı binalarda yer alan bağımsız bölümlerin değerlerinin toplu halde hesaplanmasında kullanılabileceği sonucuna varılmıştır.

ÇDR ve CAR analizi yöntemleri kullanılarak da aynı veriler üzerinde otomatik değerlendirme mimarisi geliştirilmiştir. Bunun için yine DÖ mimarisinin geliştirilmesinde kullanılan verilerin aynısı kullanılmıştır. Adı geçen 3 yöntemin birbiri ile karşılaştırılabilir olması için DÖ'de eğitim için kullanılan verilerle mimari geliştirildikten sonra, test verisi ile modelin uygunluğu kontrol edilirken, ÇDR ve CAR ile model oluşturabilmek için de aynı

usulle hareket edilmiştir. ÇDR ve CAR modellerinin geliştirilmesi için de DÖ'de olduğu gibi eğitim verisi kullanılırken, model başarılarının hesaplanması için yine DÖ'deki ile aynı test verileri kullanılmıştır. Böylece 279 adetten oluşan test verileri üzerinde hesaplanan ölçüt sonuçları karşılaştırılmıştır. Karşılaştırma neticesinde DÖ'nün CAR ve ÇDR yöntemlerinin her ikisine göre de başarı bakımından üstünlük sağladığı bulunmuştur. Buna ek olarak, DÖ, CAR ve ÇDR yöntemlerinin üçünün de çalışma alanı ile sınırlı kalmak kaydıyla, konutların toplu değerlemesinde kullanılabileceği sonucuna varılmıştır. ÇDR ve CAR analizi sonuçları birbirine yakın çıkmış olmakla birlikte, CAR yönteminin çok az bir farkla ÇDR yönteminden daha iyi sonuç verdiği de tespit edilmiştir.

DÖ yöntemi ile ortalama 30.230 TL ve 41.180 TL hata tutarları ile konut değerleri tahmin edilebilmiştir. CAR ile 71.380 TL ve ÇDR ile ise 80.070 TL ortalama hata tutarı ile konut değerlerinin tahmin edilebilmesi de bulgular arasında yer almaktadır. Bu bağlamda, DÖ yöntemi ile değer tahminlerinin başarılı olmasının yanı sıra, CAR ve ÇDR yöntemleri ile de yapılan değer tahminlerinin tatminkâr olması nedeniyle, adı geçen 3 modelin de çalışma alanı içerisindeki konutların toplu halde değerlemesinde kullanılabileceği sonucu ortaya çıkmaktadır.

Toplu olarak konut değerlendirme işlerinden olan;

- Yerel yönetimlere ait emlak vergi değeri veri tabanının oluşturulmasında,
- Belirlenen bölgeye ait şerefiye bedellerinin hesaplanmasında, geniş bir tabana hitap eden bir kentsel dönüşüm projesinde hak sahipliği puantajlarının hesaplanmasında,
- Bir kooperatifteki konutların şerefiye bedellerinin hesaplanmasında,
- Yeni imara açılacak konut alanlarında konut değerlerinin hesaplanmasında,
- Değer artış payı hesabını gerektiren imar planı tadilatlarında,
- Özniteliğe dayalı görsel değer haritalarının oluşturulmasında,
- Bir emlak ilanları web sitesinin geliştirilmesinde

DÖ yönteminin kullanılabileceği veya diğer MÖ yöntemleri ile birlikte hibrit mimarilerin oluşturulması yoluna da gidilebileceği de bu çalışmadan çıkarılan genel sonuçlar arasında yer almaktadır.

Kayseri’deki çalışma alanı için geliştirilen DÖ mimarisindeki aynı parametrelerin başka şehirlerde nasıl sonuç verdiği üzerinde durulmamıştır. Alan kayması prensibine göre, belirli bir alandaki verilerle yazılım eğitilip DÖ mimarisi geliştirildikten sonra, test verisi olarak başka bir alana ait verilerin kullanılmasıyla DÖ mimarisinin başarılı bir sonuç üretmesi zaten beklenemez. Ancak birden fazla şehir için geçerli olabilecek bir DÖ mimarisinin geliştirilebilmesi, buna ek başka çalışmaların yapılmasını gerektiren bir araştırma konusudur.

Kayseri için geliştirilmiş yazılıma dayalı matematiksel bir toplu değerlendirme yöntemi olan DÖ modelleri, çalışma alanı içerisindeki konut değerlerinin otomatik olarak hesaplanmasına olanak tanır. Bu yöntem, toplu değerlemelerde modelin başarı oranı dikkate alınarak kullanılabilir. Ancak, bu süreçte değerlendirme uzmanının gözetimi önemlidir. DÖ modellerinin kullanımı, çalışmalara daha fazla bilimsellik, hız, tutarlılık ve güvenilirlik katmaktadır.

KAYNAKLAR

- Abraham, M. (2016), “Determinants of Residential Property Value in New Zeland: A neural Network Approach”, Department of Applied Business, New Zeland Goverment Institue of Technology, Auckland, 1-24.
- Açlar, A., Çağdaş, V., Taşınmaz (Gayrimenkul) Değerlemesi, TMMOB Harita ve Kadastro Mühendisleri Odası, Ankara, Türkiye, 2008.
- Aktaş, A. (2020). Derin Öğrenme Yöntemleri İle Dokunsal Parke Yüzeyi Tespiti, Marmara Üniversitesi, Fen bilimleri Enstitüsü. Yüksek Lisans Tezi, İstanbul, 61s.
- Alpaslan H. İ., “TMS/TFRS Kapsamında Gayrimenkul Değerleme ve Gerçeğe Uygun Değerin Tespitinde Emsal Karşılaştırma ve Gelir İndirgeme Yöntemleri Üzerine Bir Uygulama”, Nevşehir Hacı Bektaş Veli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, Cilt 4, Sayı 2, Ocak-Haziran 2015, ss.17-35.
- Anonim, 2023a. Web Sitesi: [https://medium.com \(@Onurriilmaz/yapay-sinir-a%C4%9Flar%C4%B1-aktivasyon-fonksiyonlar%C4%B1-d964805b189b\)](https://medium.com/@Onurriilmaz/yapay-sinir-a%C4%9Flar%C4%B1-aktivasyon-fonksiyonlar%C4%B1-d964805b189b) Erişim Tarihi: 22.11.2023.
- Anonim, 2023b. Web Sitesi: [https://medium.com \(/machine-learning-t%C3%BCrkiye/makine-ogrenmesine-giris-62bcfa9b124a\)](https://medium.com (/machine-learning-t%C3%BCrkiye/makine-ogrenmesine-giris-62bcfa9b124a)) Erişim Tarihi: 22.11.2023.
- Anonim, 2023c. Web Sitesi: [https://medium.com \(@bsradogn/gradient-descent-dereceli%CC%87-azalma-nedi%CC%87r-49333e74c0f0\)](https://medium.com (@bsradogn/gradient-descent-dereceli%CC%87-azalma-nedi%CC%87r-49333e74c0f0)) Erişim Tarihi: 22.11.2023.
- Anonim, 2023d. Web Sitesi: [https://www.veribilimiokulu.com \(/yapay-sinir-aglari/\)](https://www.veribilimiokulu.com (/yapay-sinir-aglari/)) Erişim Tarihi: 22.11.2023.
- Anonim, 2023e. Web Sitesi: [http://www.sanko-shoko.net \(/note.php?id=p9mt\)](http://www.sanko-shoko.net (/note.php?id=p9mt)) Erişim Tarihi: 22.11.2023.
- Anonim, 2023f. Web Sitesi: [https://medium.com \(@yasinguzel/yapay-zeka-ders-notlar%C4%B1-03-biyolojik-sinir-sistemi-ve-yapay-sinir-a%C4%9F%C4%B1-h%C3%BCcresi-6555add68d80\)](https://medium.com (@yasinguzel/yapay-zeka-ders-notlar%C4%B1-03-biyolojik-sinir-sistemi-ve-yapay-sinir-a%C4%9F%C4%B1-h%C3%BCcresi-6555add68d80)) Erişim Tarihi: 23.11.2023.
- Anonim, 2023g. Web Sitesi: [https://developer.nvidia.com \(/deep-learning\)](https://developer.nvidia.com (/deep-learning)) Erişim Tarihi: 23.11.2023.
- Anonim, 2023h. Web Sitesi: [https://evds2.tcmb.gov.tr \(/index.php?/ evds/portlet/jHQqZSuUssg%3D/tr\)](https://evds2.tcmb.gov.tr (/index.php?/ evds/portlet/jHQqZSuUssg%3D/tr)) . Erişim tarihi 11.05.2022.
- Alpaslan, H. İ. “TMS/TFRS Kapsamında Gayrimenkul Değerleme Ve Gerçeğe Uygun Değerin Tespitinde Emsal Karşılaştırma ve Gelir İndirgeme Yöntemleri Üzerine Bir Uygulama”, Nevşehir Hacı Bektaş Veli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, Cilt 4, Sayı 2, Ocak-Haziran 2015, s.17-35.

- Akar, Ö., Güngör, O. (2013). Eş Dizimlilik Matrisi ve Rastgele Orman Sınıflandırıcısı ile Çay ve Fındık Alanlarını Sınıflandırılması. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu. 23-25 Mayıs, Trabzon, Türkiye.
- Arıkan Kargı, V.S. (2015), Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama, Ekin Basım Yayın Dağıtım: Bursa.
- Aydemir E, Aktürk C, Yalçınkaya M (2020). Yapay Zekâ ile Konut Fiyatlarının Tahmin Edilmesi. Turkish Studies - Information Technologies and Applied Sciences, 15(2), 183 - 194.
- Basheer I.A, Hajmeer M. (2000). “Artificial Neural Networks: Fundamentals, Computing, Design, and Application” , Journal of Microbiological Methods, 43(1), 3-31.
- Baydilli, Y. Y. 2020. Derin öğrenme yöntemleri ile periferik yayma görüntülerinin analizi ve sınıflandırılması. Doktora Tezi. Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Karabük.
- Borst, R.A. 1991. Artificial Neural Networks: The Next Modelling / Calibration Technology For The Assessment Community. Artificial Neural Networks, 69-94.
- Cechin, A., Antonio, S. and Gonzales, M. A. 2000. Real Estate Value at Porto Alegre City Using Artificial Neural Networks. Neural Networks, Proceedings, Sixth Brazilian Symposium on IEEE, November 2000. 237-242.
- Chiarazzo, V., Caggiani, L., Marinelli, M. and Ottomanelli, M. (2014), “Neural Network Based Model For Real Estate Price Estimation Considering Environmental Quality Of Property Pocation”, Transportation Research Procedia, 3 , 810-817.
- Chollet, F. 2021. Python İle Derin Öğrenme. Buzdağı Yayınevi, 374, Ankara.
- Demirel, Y. (2007). Toplu Konut İnşaat Maliyetlerinin Yapay Sinir Ağları İle Tahmini. Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi, 22(4), 53-60.
- Do, A. Q. And Grudnitski, G.1992. A Neural Network Approach To Residential Property Appraisal. The Real Estate Appraiser. 58 (3). 38-45.
- Ecer, F. (2014), “Türkiye’deki Konut Fiyatlarının Tahmininde Hedonik Regresyon ile Yapay Sinir Ağlarının Karşılaştırılması”, International Conference on Eurasian Economies,1-10.
- Ekşioğlu Çetintahra, G., & Çubukçu, E. (2011). Çevre Estetiğinin Konut Fiyatlarına Etkisi. İtü Dergisi/A, 10(1), 3-12.
- Erdem, A. E. (1996). Konut Projelerinde, Ön Tasarım Aşamasında, Fonksiyonel Elemanlara Dayalı Maliyet Tahmini İçin Bir Model Geliştirilmesi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.

- Gallego, J. and Esperanza, M. (2004), Artificial Intelligence Applied to Real Estate Valuation, An Example for The Appraisal of Madrid, Catastro, 255-265.
- Gemici, M., 2007. Xml Tabanlı Uygulamaların Yapay Zeka Modeliyle Gerçek Zamanlı Analizi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Goodfellow, I., Bengio, Y., Courville, A., 2021. Derin Öğrenme: New York.
- Güneş, T. ve Yıldız, Ü. (2015), Mass Valuation Techniques Used in Land Registry and A Cadastre Modernization Project of Republic of Turkey, FIG Working Week, From the Wisdom of the Ages to the Challenges of the Modern World, Sofia, Bulgaria.
- İlhan, A. T., ve Öz, S. N., (2020). Yapay Sinir Ağlarının Gayrimenkullerin Toplu Değerlemesinde Uygulanabilirliği: Gölbaşı İlçesi Örneği. Hacettepe Üniversitesi Sosyal Bilimler Dergisi, Cilt 2/Sayı 2/2020.
- Karapınar, A., (2013). Gayrimenkul-Konut Değerleme Uzmanlığı Lisanslama Sınavına Hazırlık, Yenilenmiş 7.Basım, Ankara: Gazi Kitapevi. Tic. Ltd. Şti., s. 70.
- Keleş, A. 2007. Öğrenme - Öğretme Sürecinde Yapay Zeka Ve Web Tabanlı Zeki Öğretim Sistemi Tasarımı Ve “Matematik Öğretiminde Bir Uygulama”. Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Ortaöğretim Fen ve Matematik Alanları Eğitimi Anabilim Dalı, Doktora Tezi.
- Khamrabaeva, L., 2020. Gayrimenkul Değerleme Yöntemleri: Hedonik Fiyat Modeli Üzerine Bir Uygulama, Uludağ Üniversitesi, İşletme Anabilim Dalı, Sayısal Yöntemler Bilim Dalı, Yüksek Lisans Tezi.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. Nature, 521, 436-444.
- Lin, C., 1991. Neural Network Based Fuzzy Logic Control and Descision System, IEEE Trans. Comput. 40, 1320-1336.
- Marin, M. C., & Altıntaş, H. (2004). Konut Yer Seçimi-Ulaşım Etkileşim Teorileri: Kritik Bir Literatür İncelenmesi. Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 19(1),73-88.
- Mimis, A., Rovolis, A. and Stamou, M. (2013), “Property Valuation with Artificial Neural Network: The Case of Athens”, Journal of Property Research, 30 (2), 128-143.
- Nuhoğlu, B. A. 2007. Gayrimenkul Değerleme, 19 Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- Odabaşı, G., 2020. Türkiye’de Taşınmaz Değerleme Yöntemleri Ve Uygulama Alanlarının İrdelenmesi, Harita Mühendisliği Anabilim Dalı, Jeodezi ve Coğrafi Bilgi Teknolojileri Programı, Yüksek Lisans Tezi.

- Özkan, G., Yalpir, Ş. ve Uygunol, O. (2007), “An Investigation on The Price Estimation of Residable Real Estates by Using ANN and Regression Methods” The 12 th Applied Stochastic Models and Data Analysis International Conference (ASMDA), Chania, Crete, Greece.
- Rende, F. Ş, Bütün G., Karahan Ş. (2016). Derin Öğrenme Algoritmalarında Model Testleri: Derin Testler. 10. Ulusal yazılım Mühendisliği Sempozyumu, 24-26 Ekim, pp:54-59, Çanakkale.
- Rossini, P. (1997), “Artificial Neural Networks Versus Multiple Regression In The Valuation of Residential Property”, Australian Land Economics Review, 3 (1), 1-12.
- Selim, S. & Demirbilek, A. (2009). Türkiye’deki Konutların Kira Değerinin Analizi: Hedonik Model Ve Yapay Sınır Ağları Yaklaşımı. Aksaray Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 1 (1), 73-90. Retrieved from <http://aksarayiibd.aksaray.edu.tr/en/pub/issue/22558/241036>
- Selim, S. ve Demirbilek, A. Aksaray Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi (2016): 73-90.
- Sorias, S., 2005. Yapay Nöron Ağları Bilişsel İşlevleri Anlamamıza Yardım Edebilir Mi?, Journal of Internal Medical Sciences, 40, 8-16.
- Şeker, Ş. E., 2021. Şadi Evren ŞEKER, Python ile Makine Öğrenmesi. <https://www.btkakademi.gov.tr/portal/course/player/deliver/python-ile-makine-ogrenmesi-11800>. Erişim Tarihi: 16.07.2021.
- Tanrıvermiş, H., 2013. Gayrimenkul Değerleme İlkeleri ve Uygulamaları, Ders Notları. Ankara.
- Tanrıvermiş, H. (2018), Gayrimenkul Değerleme Esasları, Sermaye Piyasası Lisanslama, Sicil ve Eğitim Kurulu Yayınları: İstanbul.
- Topaloğlu, F., 2018. Bulanık Mantık ve Genetik Algoritma Yöntemleri Kullanılarak Parametre Belirleme Ve Ölçeklendirme: Rüzgar Türbini Kurulum Uygulaması, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Trabzon.
- Türel, A. (1976). Ankara’da Konut Fiyatlarının Mekânsal Farklılaşması. Geoforum, 7, 271-283.
- Worzala E., Lenk, M. and Silva, A. (1995), An Exploration of Neural Networks and Its Application to Real Estate Valuation”. Journal of Real Estate Research, 10 (2), 185-201.
- Yıldız, B. (2009). Finansal Analizlerde Yapay Zeka, Detay Yayıncılık, Ankara.
- Yılmaz, A. ve Kaya, U., 2021. Derin Öğrenme. Kodlab Yayın Dağıtım, İstanbul.

Yılmazel, Ö., Afşar, A., ve Yılmazel, S., 2018. Konut Fiyat Tahmininde Yapay Sinir Ağları Yönteminin Kullanılması, Eskişehir.

Yomralıoğlu, T. 1997. Taşınmazların Değerlendirilmesi ve Kat Mülkiyeti Mevzuatı, İmar Planı Uygulama Teknikleri, JEDOF-Kentsel Alan Düzenlemelerinde İmar Planı Uygulama Teknikleri, Trabzon, ss.153-169.



EKLER

EK 1 Denenen bazı DÖ mimarilerinin eğitim, doğrulama, kayıp fonksiyonu ve gerçek değer-tahmin edilen değer dağılım grafikleri

EK 2 Değere en çok etki eden numerik bağımsız değişkenlerin tespitine ilişkin script

EK 3 GDE yöntemi ile optimum değişkenleri belirleyen script


EK 4 DÖ mimarisinde katmanlı yapının kod görünümü


EK 5 Konutlara ait özelliklerin özeti





EK 1 Denenen bazı DÖ mimarilerinin eğitim, doğrulama, kayıp fonksiyonu ve gerçek değer-tahmin edilen değer dağılım grafikleri


OMYH başarı sıralaması	Çalışma numarası	Eğitim-eğitim doğrulama	Eğitim-test doğrulama	Kayıp fonksiyonu	Değer-tahmin dağılımı
1	18				
2	12				
3	4				


























EK 2 Değere en çok etki eden numerik bağımsız değişkenlerin tespitine ilişkin script

```
1 import numpy as np
2 import pandas as pd
3 import seaborn as sns
4 import matplotlib.pyplot as plt
5 df_train = pd.read_csv('D:/veri.csv', index_col=0)
6 df_train.drop('vid', inplace=True, axis=1)
7 df_train.drop('d8_semt', inplace=True, axis=1)
8 df_train.columns
9 df_train.head()
10 df_train['deger'].describe()
11 sns.distplot(df_train['deger']);
12 print("Skewness: %f" % df_train['deger'].skew())
13 print("Kurtosis: %f" % df_train['deger'].kurt())
14 corrmatrix = df_train.corr()
15 f, ax = plt.subplots(figsize=(60, 40))
16 sns.heatmap(corrmatrix, vmax=.8, square=True);
17 k = 100
18 cols = corrmatrix.nlargest(k, 'deger')['deger'].index
19 cm = np.corrcoef(df_train[cols].values.T)
20 sns.set(font_scale=0.75)
21 hm = sns.heatmap(cm, cbar=True, annot=True, square=True, fmt='.2f',
22 , annot_kws={'size': 42}, yticklabels=cols.values, xticklabels=cols.values)
23 plt.show()
```

EK 3 GDE yöntemi ile optimum değişkenleri belirleyen script

```
1 import pandas as pd
2 from sklearn.feature_selection import RFE
3 from sklearn.linear_model import LinearRegression
4
5 # Veri setini yükleme
6 data = pd.read_csv('/content/../../degisken_secimi_veri.csv')
7
8 data.columns
9
10 # Bağımsız değişkenleri ve hedef değişkeni ayırma
11 X = data.drop('deger_log', axis=1)
12 y = data['deger_log']
13
14 # Linear regresyon modeli oluşturma
15 lr = LinearRegression()
16
17 # RFE yöntemi ile özellik seçimi yapma
18 rfe = RFE(lr, step=1)
19 rfe.fit(X, y)
20
21 # Seçilen özelliklerin indekslerini alma
22 selected_features = rfe.get_support(indices=True)
23
24 # Seçilen özelliklerin adlarını alma
25 feature_names = list(X.columns)
26 selected_feature_names = [feature_names[i] for i in selected_features]
27
28 print(f'Selected features: {selected_feature_names}')
```

EK 4 DÖ mimarisinde katmanlı yapının kod görünümü

```
1 model = tf.keras.Sequential([  
2   keras.layers.Dense(512 , activation='relu' , input_shape=[91]),  
3   keras.layers.Dense(512 , activation='relu') ,  
4   keras.layers.Dense(512 , activation='relu') ,  
5   keras.layers.Dense(1) ])
```



EK 5 Konutlara ait özelliklerin özeti

Bina görevlisi	Var	Yok	Toplam
Sıklık (adet)	948	417	1365
Oran (%)	69,5	30,5	100

Binanın altında dükkân olup olmadığı	Var	Yok	Toplam
Sıklık (adet)	268	1097	1365
Oran (%)	19,6	80,4	100

Binanın yaşı	0-6	6-12	12-19	19-25	25-31	Toplam
Sıklık (adet)	861	4	319	86	95	1365
Oran (%)	63,1	0,3	23,4	6,3	7	100

Binaya ait açık otopark	Var	Yok	Toplam
Sıklık (adet)	777	588	1365
Oran (%)	56,9	43,1	100

Deprem hasar durumu	Var	Yok	Toplam
Sıklık (adet)	3	1362	1365
Oran (%)	0,2	99,8	100

Güvenlik	Var	Yok	Toplam
Sıklık (adet)	5	1360	1365
Oran (%)	0,4	99,6	100

Havuz	Var	Yok	Toplam
Sıklık (adet)	12	1353	1365
Oran (%)	0,9	99,1	100

Isıtma Sistemi	Isı Pay Ölçer	Kombi	Merkezi	Soba	Toplam
Sıklık (adet)	181	435	710	39	1365
Oran (%)	13,3	31,9	52	2,9	100

Kapalı otopark	Var	Yok	Toplam
Sıklık (adet)	27	1338	1365
Oran (%)	2	98	100

Rezidans hizmetleri var mı	Evet	Hayır	Toplam
Sıklık (adet)	2	1363	1365
Oran (%)	0,1	99,9	100

Semt otoparkı yeterli mi	Yeterli Değil	Yeterli	Toplam
Sıklık (adet)	118	1247	1365
Oran (%)	8,6	91,4	100

Sıcak su	Var	Yok	Toplam
Sıklık (adet)	1325	40	1365
Oran (%)	97,1	2,9	100

Sığınak	Var	Yok	Toplam
Sıklık (adet)	1021	344	1365
Oran (%)	74,8	25,2	100

Site içinde mi	Evet	Hayır	Toplam
Sıklık (adet)	73	1292	1365
Oran (%)	5,3	94,7	100

Yapı kalitesi	İyi	Kötü	Lüks	Orta	Toplam
Sıklık (adet)	929	83	64	289	1365
Oran (%)	68,1	6,1	4,7	21,2	100

Yolcu asansörü	Var	Yok	Toplam
Sıklık (adet)	1117	248	1365
Oran (%)	81,8	18,2	100

Yük asansörü	Var	Yok	Toplam
Sıklık (adet)	22	1343	1365
Oran (%)	1,6	98,4	100

Binanın kat adedi	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	Toplam
Sıklık (adet)	1	27	108	67	83	47	71	97	105	116	60	164	111	268	33	2	1	2	0	1	0	1	1365
Oran (%)	0,07	1,98	7,91	4,91	6,08	3,44	5,2	7,1	7,69	5,5	4,4	12	8,13	19,6	2,4	0,2	0,1	0,15	0	0,1	0	0,1	100

Balkon	Var	Yok	Toplam
Sıklık (adet)	1331	34	1365
Oran (%)	97,5	2,5	100

Banyo sayısı	1	2	3	4	Toplam
Sıklık (adet)	1360	4	0	1	1365
Oran (%)	99,6	0,3	0	0,1	100

Brüt alan	55-106	106-157	157-208	208-259	259-310	Toplam
Sıklık (adet)	69	412	804	71	9	1365
Oran (%)	5,1	30,2	58,9	5,2	0,7	100

Dairenin bulunduğu kat	-1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	Toplam
Sıklık (adet)	15	74	205	145	169	104	122	114	96	68	67	52	42	51	19	18	4	1365
Oran (%)	1,1	5,4	15	10,6	12,4	7,6	8,9	8,4	7	5	4,9	3,8	3,1	3,7	1,4	1,3	0,3	100

Dairenin konumu	Ara kat	Bodrum	Dükkân üstü	Son kat	Zemin kat	Toplam
Sıklık (adet)	856	15	48	215	231	1365
Oran (%)	62,7	1,1	3,5	15,8	16,9	100

Net alan	45-92	92-139	139-186	186-233	233-280	Toplam
Sıklık (adet)	116	716	489	37	7	1365
Oran (%)	8,5	52,5	35,8	2,7	0,5	100

Ebeveyn banyosu	Var	Yok	Toplam
Sıklık (adet)	686	679	1365
Oran (%)	50,3	49,7	100

Dairenin iinin yapılı olup olmadığı	Evet	Hayır	İstenirse	Lüks	Toplam
Sıklık (adet)	707	259	291	108	1365
Oran (%)	51,8	19	21,3	7,9	100

Kiler	Var	Yok	Toplam
Sıklık (adet)	160	1205	1365
Oran (%)	11,7	88,3	100

Manzara	Normal	Önü Açık	Önü Kapalı	Toplam
Sıklık (adet)	1230	101	34	1365
Oran (%)	90,1	7,4	2,5	100

Oda sayısı	1	1,5	2	2,5	3	3,5	4	4,5	5	Toplam
Sıklık (adet)	24	1	157	25	995	32	119	2	10	1365
Oran (%)	1,8	0,1	11,5	1,8	72,9	2,3	8,7	0,1	0,7	100

Salon sayısı	0	1	2	Toplam
Sıklık (adet)	2	1350	13	1365
Oran (%)	0,1	98,9	1	100

Dairenin stüdyo tipi olup olmadığı	Evet	Hayır	Toplam
Sıklık (adet)	44	1321	1365
Oran (%)	3,2	96,8	100

AVM'ye yakınlık	12-1867	1867-3721	3721-5576	5576-7430	7430-9285	Toplam
Sıklık (adet)	716	461	101	80	7	1365
Oran (%)	52,5	33,8	7,4	5,9	0,5	100

İlkokula yakınlık	12-472	472-931	931-1391	1391-1850	1850-2310	Toplam
Sıklık (adet)	908	398	55	2	2	1365
Oran (%)	66,5	29,2	4	0,1	0,1	100

1/1.000 ölçekli imar planındaki fonksiyonu	Bilinmiyor	Gelişme Konut	İptal	Konut	Konut Dışı Kentsel Çalışma Alanı	Konut Ticaret	Kütle	Toplam
Sıklık (adet)	140	249	82	764	1	49	80	1365
Oran (%)	10,3	18,2	6	56	0,1	3,6	5,9	100

1/25.000 ölçekli imar planındaki fonksiyonu	Bilinmiyor	Gelişme Konut Çok Yüksek	Gelişme Konut Düşük	Gelişme Konut Orta	Gelişme Konut Seyrek	Gelişme Konut Yüksek	Kentsel Sit	Mevcut Konut Çok Yüksek	Mevcut Konut Orta	Mevcut Konut Seyrek	Mevcut Konut Yüksek	Tarihi Sit	Ticaret	Toplam
Sıklık (adet)	24	36	3	59	3	133	1	104	115	7	829	1	50	1365
Oran (%)	1,8	2,6	0,2	4,3	0,2	9,7	0,1	7,6	8,4	0,5	60,7	0,1	3,7	100

1/5.000 ölçekli imar planındaki fonksiyonu	Bilinmiyor	Gelişme Konut Çok Yüksek	Gelişme Konut Düşük	Gelişme Konut Orta	Gelişme Konut Seyrek	Gelişme Konut Yüksek	Konut Ticaret	Yerleşik Konut Çok Yüksek	Yerleşik Konut Orta	Yerleşik Konut Yüksek	Toplam
Sıklık (adet)	289	50	5	79	9	113	79	77	61	603	1365
Oran (%)	21,2	3,7	0,4	5,8	0,7	8,3	5,8	5,6	4,5	44,2	100

1/50.000 ölçekli imar planındaki fonksiyonu	Bilinmiyor	Kentsel Gelişme	Kentsel Meskun	MİA	Toplam
Sıklık (adet)	25	117	1156	67	1365
Oran (%)	1,8	8,6	84,7	4,9	100

Şehir merkezine yakınlık	295-3055	3055-5815	5815-8575	8575-11335	11335-14095	Toplam
Sıklık (adet)	368	371	337	132	157	1365
Oran (%)	27	27,2	24,7	9,7	11,5	100

Sağlık tesisine yakınlık	0-691	691-1383	1383-2074	2074-2766	2766-3457	Toplam
Sıklık (adet)	939	348	76	0	2	1365
Oran (%)	68,8	25,5	5,6	0	0,1	100

Taksi durağına yakınlık	3-1031	1031-2059	2059-3087	3087-4115	4115-5143	Toplam
Sıklık (adet)	935	252	108	59	11	1365
Oran (%)	68,5	18,5	7,9	4,3	0,8	100

Ulaşım	0-1757	1757-3514	3514-5272	5272-7029	7029-8786	Toplam
Sıklık (adet)	897	323	63	61	21	1365
Oran (%)	65,7	23,7	4,6	4,5	1,5	100

İlçe adı	Kocasinan	Melikgazi	Talas	Toplam
Sıklık (adet)	563	587	215	1365
Oran (%)	41	43	16	100