

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ
YÖNTEMLERİYLE TÜRKİYE EMLAK
PİYASASINDA FİYAT TAHMİNİ

Recep Furkan KOÇYİĞİT

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Prof. Dr. Banu DİRİ

Eş-Danışman
Öğr. Gör. Dr. Ahmet ELBİR

Mayıs, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ
YÖNTEMLERİYLE TÜRKİYE EMLAK PİYASASINDA
FİYAT TAHMİNİ

Recep Furkan KOÇYİĞİT tarafından hazırlanan tez çalışması 22.05.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Banu DİRİ
Yıldız Teknik Üniversitesi
Danışman

Öğr. Gör. Dr. Ahmet ELBİR
Yıldız Teknik Üniversitesi
Eş-Danışman

Jüri Üyeleri

Prof. Dr. Banu DİRİ, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Ali Can KARACA, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi NİHAL ALTUNTAŞ, Üye
İstanbul Gelişim Üniversitesi

Danışmanım Prof. Dr. Banu DİRİ sorumluluğunda tarafımca hazırlanan DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE TÜRKİYE EMLAK PİYASASINDA FİYAT TAHMİNİ başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Recep Furkan KOÇYİĞİT

İmza

TEŞEKKÜR

Bu çalışmanın sonunda, bilgilerini benimle cömertçe paylaşan Prof. Dr. Banu DİRİ ve Öğr. Gör. Dr. Ahmet ELBİR'e, tüm zorluklarımda yanımda olan ve hayatım boyunca beni destekleyen aileme ve en yoğun anlarımda bile yanımda olan, sabrıyla ve sevgisiyle bana güç veren sevgili Beril BAYOĞLU'na sonsuz teşekkür ederim.

Recep Furkan KOÇYİĞİT

İÇİNDEKİLER

KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ	viii
TABLO LİSTESİ	ix
ÖZET	x
ABSTRACT	xii
1 GİRİŞ	1
1.1 LİTERATÜR ÖZETİ	2
1.2 TEZİN AMACI	6
1.3 HİPOTEZ	7
2 VERİ KÜMESİ	8
2.1 ÖN İŞLEME	8
2.2 ÖZNİTELİK ÇIKARIMI	9
2.3 VERİ ANALİZİ	10
2.4 ÖZELLİK SEÇİMİ	12
2.4.1 KORELASYON	13
2.4.2 ÖZYİNELEMELİ ÖZELLİK SEÇİMİ (RECURSIVE FEATURE ELIMINATION – RFE)	15
3 YÖNTEMLER	17
3.1 MAKİNE ÖĞRENMESİ MODELLERİ	17
3.1.1 XGBOOST	17
3.2 DERİN ÖĞRENME MODELLERİ	17
3.2.1 YAPAY SİNİR AĞLARI (ARTIFICAL NEURAL NETWORK - ANN)	17
3.2.2 EVRİŞİMLİ SİNİR AĞLARI (CONVOLUTIONAL NEURAL NETWORK - CNN)	19
3.2.3 UZUN KISA VADELİ BELLEK (LONG-SHORT TERM MEMORY -LSTM)	20

3.2.4	EVRIŞİMLİ SİNİR AĞLARI-UZUN KISA VADELİ BELLEK (CNN-LSTM)	21
3.2.5	KOLMOGOROV-ARNOLD AĞLARI (KOLMOGOROV-ARNOLD Network - KAN)	21
3.3	PERFORMANS METRİKLERİ	22
3.3.1	ORTALAMA MUTLAK HATA (MEAN ABSOLUTE ERROR - MAE)	23
3.3.2	ORTALAMA KARE HATASI (MEAN SQUARED ERROR - MSE)	23
3.3.3	KÖK ORTALAMA KARE HATASI (ROOT MEAN SQUARED ERROR - RMSE)	23
3.3.4	ORTALAMA MUTLAK YÜZDE HATA (MEAN ABSOLUTE PERCENTAGE ERROR - MAPE)	23
4	DENEYSEL SONUÇLAR	24
4.1	MAKİNE ÖĞRENMESİ MODELLERİ	24
4.1.1	XGBOOST DENEYLERİ	26
4.2	DERİN ÖĞRENME MODELLERİ	27
4.2.1	ANN SONUÇLARI	27
4.2.2	CNN SONUÇLARI	29
4.2.3	LSTM SONUÇLARI	31
4.2.4	CNN-LSTM SONUÇLARI	32
4.2.5	KAN SONUÇLARI	34
4.3	MODELLERİN KARŞILAŞTIRILMASI	35
5	SONUÇ	38
	KAYNAKÇA	40
A	ÖZNİTELİK AÇIKLAMALARI VE MODEL SONUÇLARI	42
	TEZDEN ÜRETİLMİŞ YAYINLAR	71

KISALTMA LİSTESİ

RFE	Recursive Feature Elimination
AVM	Automated Valuation Model
MAE	Mean Absolute Error
MSE	Mean Squared Error
SE	Squared Error
SPE	Squared Percentage Error
R ²	R-Squared
RMSE	Root Mean Squared Error
MAPE	Mean Absolute Percentage Error
ANN	Artificial Neural Network
CNN	Convolutional Neural Network
RNN	Recurrent Neural Network
LSTM	Long-Short Term Memory
KAN	Kolmogorov-Arnold Artificial Network
XGBoost	Extreme Gradient Boosting
FSTM	Flexible Spatio-Temporal Model
IQR	Interquartile Range
MLP	Multi-Layer Perceptron
HPI	House Price Index
GWR	Geographically Weighted Regression
CRISP-DM	Cross-Industry Standard Process for Data Mining

ŞEKİL LİSTESİ

Şekil 1.1	Proje Akışı	2
Şekil 2.1	Sayısal Özelliklerin Dağılımı	11
Şekil 2.2	Korelasyon Matrisi	13
Şekil 3.1	ANN Çalışma Prensibi [16]	18
Şekil 3.2	CNN Çalışma Prensibi [19]	19
Şekil 3.3	LSTM Çalışma Prensibi [21]	20
Şekil 3.4	KAN Mimarisi [22]	22
Şekil 4.1	ANN Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi	28
Şekil 4.2	CNN Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi	30
Şekil 4.3	LSTM Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi	31
Şekil 4.4	CNN-LSTM Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi	33
Şekil 4.5	KAN Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi	34

TABLO LİSTESİ

Tablo 2.1	En Önemli 10 Öznitelik	10
Tablo 2.2	Fiyat ile En Yüksek Korelasyona Sahip 20 Öznitelik	14
Tablo 2.3	En Önemli 50 Öznitelik	16
Tablo 4.1	Makine Öğrenmesi Modellerinin Performans Karşılaştırması	25
Tablo 4.2	Test Edilen XGBoost Hiperparametreleri	27
Tablo 4.3	Test Edilen ANN Hiperparametreleri	27
Tablo 4.4	Test Edilen CNN Hiperparametreleri	29
Tablo 4.5	Test Edilen LSTM Hiperparametreleri	31
Tablo 4.6	Test Edilen CNN-LSTM Hiperparametreleri	32
Tablo 4.7	Test Edilen KAN Modeli Hiperparametreleri	34
Tablo 4.8	Model Performans Sonuçları	35
Tablo A.1	İlan Öznitelikleri	42
Tablo A.2	ANN Hipermatre Sonuçları	47
Tablo A.3	CNN Hipermatre Sonuçları	53
Tablo A.4	LSTM Hipermatre Sonuçları	64
Tablo A.5	CNN-LSTM Hipermatre Sonuçları	65
Tablo A.6	KAN Hipermatre Sonuçları	69

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE TÜRKİYE EMLAK PIYASASINDA FİYAT TAHMİNİ

Recep Furkan KOÇYİĞİT

Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Prof. Dr. Banu DİRİ
Eş-Danışman: Öğr. Gör. Dr. Ahmet ELBİR

Türkiye’deki emlak piyasası, ekonomik büyümenin ve bireylerin yaşam kalitesinin önemli bir belirleyicisidir ve hem yatırımcılar hem de alıcılar için kritik bir rol oynamaktadır. Bu çalışma, Ocak 2025’te Türkiye’deki konut mülkleri için yayınlanan 128.670 emlak ilanından elde edilen verileri kullanarak emlak değerlendirme ve tavsiye sistemleri geliştirmektedir. Veri ön işleme aşamasında, yanlış kategorideki ilanlar, Kuzey Kıbrıs’tan ilanlar, eksik demografik ve fiyat bilgileri, inşaat halindeki mülkler için ilanlar ve koordinat verileri eksik olanlar gibi hatalı girişler kaldırılmıştır. Ek olarak, metinsel veriler sayısal değerlere dönüştürülmüş ve veri seti fiyat, brüt m² ve oda sayısı sınırlamaları uygulanarak 93.350 ilana indirgenmiş ve 207 farklı özellik elde edilmiştir. Özellikler arasında korelasyon analizi yapılarak fiyatla korelasyonu düşük olanlar çıkarılmıştır. Kategorik veriler Ki-Kare testi ve One-Hot Encoding kullanılarak işlenmiştir. RFE, özellik seçiminde en etkili yöntem olup, 50 ilgili özelliğin belirlenmesini sağlamıştır. Çeşitli makine öğrenimi modelleri arasında en iyi sonuçlar, 384 farklı parametre kombinasyonu üzerinden optimizasyon ile XGBRegressor kullanılarak elde edilmiştir. Modelin performansı yaklaşık %11’lik bir ortalama mutlak yüzde hata vermektedir ki bu da Türkiye’nin emlak piyasasındaki ortalama pazarlık oranının %9 olduğu düşünüldüğünde oldukça başarılı sayılmaktadır. ANN, CNN, CNN-LSTM, LSTM ve KAN dahil olmak üzere derin öğrenme modelleri de test edilmiştir, ancak hiçbirisi XGBRegressor’dan daha iyi performans göstermemiştir. Özellikle, ANN modeli

tanh aktivasyon fonksiyonu ve düşük bırakma oranları uygulandığında daha iyi sonuçlar göstermektedir. Genel olarak, XGBRegressor en düşük hata oranlarını vermektedir. Bu çalışma, modern veri işleme tekniklerinden yararlanarak emlak piyasasının analizine yönelik sağlam bir zemin oluşturmakta ve emlak fiyatlarının tahmini için etkili bir model ortaya koymaktadır.

Anahtar Kelimeler: Emlak Piyasası Tahmini, Makine Öğrenimi, Derin Öğrenme, Fiyat Tahminleri



ABSTRACT

PRICE PREDICTION IN THE TURKISH REAL ESTATE MARKET USING DEEP LEARNING AND MACHINE LEARNING METHODS

Recep Furkan KOÇYİĞİT

Department of Computer Engineering
Master of Science Thesis

Supervisor: Prof. Dr. Banu DIRİ
Co-supervisor: Lect. PhD Ahmet ELBİR

The real estate market in Turkey is a key determinant of economic growth and individuals' quality of life, playing a critical role for both investors and buyers. This study develops property valuation and recommendation systems using data from 128,670 property listings published in January 2025 for residential properties in Turkey. During the data preprocessing phase, erroneous entries, such as listings in the wrong category, those from Northern Cyprus, missing demographic and price information, listings for properties under construction, and those lacking coordinate data, are removed. Additionally, textual data is converted into numerical values, and the dataset is reduced to 93,350 listings by applying limitations on price, gross m², and number of rooms, resulting in 207 distinct features. Correlation analysis is performed among the features, leading to the removal of those with low correlation to the price. Categorical data are processed using the Chi-Square test and One-Hot Encoding. RFE proves most effective in feature selection, leading to the identification of 50 relevant features. Among various machine learning models, the best results are achieved using XGBRegressor, with optimization through 384 different parameter combinations. The model's performance yields a mean absolute percentage error of approximately 11%, which is considered highly successful, given that the average bargaining rate in Turkey's real estate market is 9%. Deep learning models, including ANN, CNN, CNN-LSTM, LSTM, and KAN, are also tested, but none outperform XGBRegressor. Notably, the ANN model shows better

results when the tanh activation function and low dropout rates are applied. Overall, XGBRegressor delivers the lowest error rates. This study provides a solid basis for the analysis of the real estate market by utilizing modern data processing techniques and presents an effective model for the prediction of real estate prices.

Keywords: Real Estate Market Prediction, Machine Learning, Deep Learning, Price Predictions




1 GİRİŞ

Pandeminin ardından Türkiye’deki emlak piyasası, yalnızca ekonomik büyümeyi değil, aynı zamanda bireysel refahı da doğrudan etkileyerek ülkenin ekonomik çerçevesinin ayrılmaz bir parçası haline gelmiştir. Bu süreçte, emlak sektörünün büyümesi, birçok sektördeki yeniden yapılanma ve değişimle paralel ilerlemiş, piyasada meydana gelen dalgalanmalar, hem yerel hem de ulusal düzeyde önemli ekonomik sonuçlar doğurmuştur. Konum, ekonomik koşullar, arz-talep dengesizliği, bölgesel gelişim ve piyasa dinamikleri gibi faktörler, gayrimenkul değerlerini belirlerken daha da karmaşık hale gelen bir etkileşim yaratmaktadır. Özellikle büyük şehirlerdeki yüksek talep, kırsal bölgelere yönelik artan ilgi ve yerel kalkınma projeleri gibi unsurlar, fiyat tahminlerinin doğruluğunu zorlaştırmaktadır.

Bu karmaşık ortamda, güvenilir gayrimenkul değerlendirme sistemleri, yalnızca yatırımcılar ve alıcılar için değil, aynı zamanda politika yapıcılar ve şehir planlamacıları için de kritik öneme sahiptir. Bu sistemler, tüm paydaşların bilinçli ve doğru kararlar almalarına olanak tanıırken, etkin ve sürdürülebilir uzun vadeli stratejilerin geliştirilmesine de katkı sağlamaktadır. Ancak, Türkiye gayrimenkul piyasasında bu değerlendirme süreçlerinin doğruluğunu etkileyen çeşitli zorluklar mevcuttur. Geleneksel değerlendirme yöntemleri, özellikle dalgalı piyasa koşulları, bölgesel farklılıklar ve veri kalitesindeki tutarsızlıklar nedeniyle büyük ölçüde yetersiz kalmaktadır. Bunun yanında, hızlı teknolojik gelişmeler ve dijitalleşme süreci, piyasada daha şeffaf ve erişilebilir veri kaynaklarının ortaya çıkmasını sağlasa da, bu yeniliklerin etkin bir şekilde entegre edilmesi ve güvenilir değerlendirme modellerine dönüştürülmesi büyük bir zorluk teşkil etmektedir.

Bu çalışmada, Türkiye emlak piyasasında karşılaşılan zorluklar detaylı bir şekilde incelenerek, güncel emlak verilerinin toplanması ve işlenmesi, ardından öznitelik çıkarımı ve özellik seçimi süreçleri gerçekleştirilmiştir. Bu doğrultuda Şekil 1.1’deki akış üzerinden ilerlenmiş, makine öğrenmesi ve derin öğrenme modelleri geliştirilip eğitilerek, bir gayrimenkulün fiyatının yüksek doğrulukla tahmin

edilmesi amaçlanmıştır.



Şekil 1.1 Proje Akışı

1.1 LİTERATÜR ÖZETİ

Wang ve diğerleri tarafından geliştirilen Esnek Zamansal-Mekânsal Model (FSTM), Shunde gibi orta-küçük şehirlerdeki ev fiyatlarının zamansal ve mekânsal dinamiklerini anlamak amacıyla 1498 örnek kullanılarak oluşturulmuştur [1]. Bu model, uzun vadeli eğilimleri ampirik ortogonal temel fonksiyonlar ile mekânsal olarak ilişkili rastgele katsayı alanlarını birleştirerek analiz etmiş ve performansı $RMSPE=0,568$, $MAPE=0,410$ ve $R^2=0,275$ gibi metriklerle değerlendirilmiştir. Modelin orta düzeyde başarı gösterdiği belirtilmiş, hükümet politikaları ile çevresel faktörlerin ev fiyatlarına etkisini kapsamlı bir şekilde açıkladığı vurgulanmıştır. Ancak, tahmin hatalarının yıllık örnek değerlerinin yüksek varyasyon katsayılarından kaynaklandığı ifade edilmiş ve gelecekte coğrafi ağırlıklı regresyonla entegrasyonunun tahmin doğruluğunu artırabileceği

önerilmiştir.

Hjort ve diğerleri, AVM'lerin gerçek performans ölçütüne uygun özel bir kayıp fonksiyonu tasarlayarak XGBoost modelinin performansını artırmayı hedeflemiştir [2]. Norveç konut piyasasından 126.719 işlem verisiyle model, SE ve SPE kayıp fonksiyonları altında eğitilmiştir. SPE kayıp fonksiyonu ile $\pm\%20$ aralığında doğruluk $\%89,4$ 'ten $\%90,0$ 'a, hibrit modelle $\%90,4$ 'e yükselmiş, özellikle düşük fiyat segmentlerinde belirgin iyileşme sağlanırken yüksek fiyat segmentlerinde performans düşüşü gözlenmiştir. Çalışma, finansal kurumlar ve konut piyasası için daha güvenilir tahminler sunmuş, gelecekte hibrit modelde veri odaklı bireysel ağırlıklar ile farklı kayıp fonksiyonu ailelerinin test edilmesiyle doğruluğun artırılabilceği önerilmiştir.

Adetunji ve diğerleri, ev fiyatlarını spesifik bir değer yerine fiyat varyansı olarak tahmin etmenin daha gerçekçi olduğunu savunarak bu problemi bir sınıflandırma meselesi olarak ele almıştır [3]. UCI Boston konut veri seti (506 giriş, 14 özellik) üzerinde Rassal Orman makine öğrenimi tekniği uygulanarak özgün bir yaklaşım geliştirilmiştir [4]. Model, gerçek fiyatlarla karşılaştırıldığında $R^2=0,9$ hata payı ile kabul edilebilir bir tahmin başarısı göstermiş, ev sahipleri, emlak değerlendirme uzmanları ve politikacılar için satış ile satın alma kararlarını destekleyen pratik bir araç sunmuştur. Ancak, HPI gibi genel göstergelerin bireysel fiyat tahmininde yetersiz kaldığı ve modelin yalnızca Boston veri setine dayandığı için genellenebilirliğinin kısıtlandığı belirtilmiş, gelecekte farklı bölgelerdeki spesifik değişkenleri dikkate alan kapsamlı modeller ile derin öğrenme tekniklerinin keşfedilmesi önerilmiştir.

Kopczewska ve Cwiakowski, emlak alt pazarlarının mekânsal-zamansal istikrarını test ederek literatürdeki boşluğu doldurmuştur [5]. Standart Coğrafi Ağırlıklı Regresyon (GWR) modeli kullanılarak hedonik tahminler yapılmış, katsayılar kümeleyerek alt pazarlar belirlenmiş ve Rand Index ile Jaccard Benzerliği ile stabilitesi incelenmiştir. 2006-2015 yılları arasında Varşova'daki apartman işlemleri üzerine yapılan vaka çalışması, görece yüksek mekânsal-zamansal istikrar göstermiş, GWR ve OLS modelleri $\%28-38 R^2$ aralığında benzer uyum başarısı elde etmiştir. Yöntem, fiyat belirleyicilerinin stabilitesini kantitatif olarak değerlendirme imkânı sunmuş, ancak 2006'daki düşük uyum ve stabilite gözlemlenemeyen dış faktörlerin etkisini işaret etmiş, bu anomalilerin araştırılması ve modelin farklı pazarlarda test edilmesi önerilmiştir.

Özoğur Akyüz ve diğerleri, hızla değişen emlak sektöründe doğru fiyatlandırma ihtiyacını karşılamak için ev özelliklerini kullanan dinamik bir tahmin prosedürü

sunmuştur [6]. Doğrusal regresyon, kümeleme analizi, en yakın komşu sınıflandırması ve Destek Vektör Regresyonu'nu (SVR) birleştiren hibrit bir algoritma geliştirilmiş, İstanbul Kadıköy ve Kaggle veri setlerinde test edilmiştir. Hibrit model, Kadıköy'de 0,791 ve Kaggle'da 0,937 maksimum R^2 ile RMSE ve MAPE ölçütlerinde nu-SVR, Ridge ve Lasso gibi standart tekniklere üstünlük sağlamış, heteroskedastik veri yapısını ele alarak paydaşlar için güvenilir bir karar destek aracı sunmuştur. Ancak, Kaggle veri setindeki eksik veriler ve yüksek özellik sayısı RMSE gibi ölçümlerde performansı sınırlamış, eksik veriler için imputation tekniklerinin geliştirilmesi ve farklı bölgelerden çeşitli veri setleriyle modelin test edilmesi önerilmiştir.

Ahlfeldt ve diğerleri, tekrarlanan kesit verilerden herhangi bir mekânsal birim için dengeli bir panel ev fiyatı endeksi tahmin eden bir programlama algoritması geliştirmiştir [7]. Mikro verilerin bol olduğu alanlarda hassas uyum ve seyrek olduğu yerlerde güvenilir tahminler sunan bu algoritma, Almanya'daki emlak fiyatları ve kiralari için 2007'den beri parametrik ve parametrik olmayan tekniklerle uygulanmıştır. Algoritma, Almanya'nın 8255 posta kodu bölgesinde satın alma fiyatlarının yıllık $-1,1\%$ ile $11,0\%$, kira fiyatlarının ise $-2,6\%$ ile $7,6\%$ arasında değiştiğini göstermiş, fiyat-kira oranlarının yoğunlukla pozitif korelasyonunu ortaya koyarak kentsel ekonomi teorisine dayalı sağlam bir temel sunmuştur. Başarı, mikro verilerin kalitesine ve yoğunluğuna bağlı bulunmuş, veri eksikliği olan bölgelerde ekstrapolasyonların sınırlı kalabileceği belirtilmiş, fiyat-kira oranlarındaki farklılıkların nedenlerinin araştırılması ve algoritmanın diğer ülkelerde test edilmesi önerilmiştir.

Gupta ve diğerleri, ABD eyaletlerindeki konut fiyatı senkronizasyonunu analiz ederek makroekonomik belirsizliğin bu hareketleri tahmin etmedeki rolünü araştırmıştır [8]. Bayesian dinamik faktör modeli ile fiyat hareketleri ulusal, bölgesel ve eyalete özgü faktörlere ayrılmış, Rassal Ormanlar makine öğrenimiyle belirsizliğin tahmin gücü test edilmiştir. Ulusal faktör, eyaletlerin reel konut fiyatı büyüme oranlarının 35% 'ini açıklamış, makroekonomik belirsizlik ulusal faktör ve toplam ABD konut fiyatı volatilitelerini anlamlı bir şekilde tahmin ederek yatırımcılar ve politika yapıcılar için portföy optimizasyonu ile balon öngörüsü imkânı sunmuştur. Analiz yalnızca ABD verilerine dayandığından genellenebilirliği sınırlı bulunmuş, bölgesel veri erişimine bağlı olarak diğer gelişmiş ve gelişmekte olan ülkelere genişletilmesi önerilmiştir.

Xu ve Zhang, Çin'de son on yılda hızla büyüyen konut piyasasında fiyat tahmini için 100 büyük şehirden aylık verilerle tek değişkenli bir sinir ağı modeli geliştirmiştir [9]. Levenberg-Marquardt, ölçeklendirilmiş eşlenik gradyan

ve Bayesian düzenleme algoritmaları test edilmiş, dört gecikme ve üç gizli nöronlu bir yapı ile ilk geniş kapsamlı çalışma sunulmuştur. Model, 99 şehirde eğitim, doğrulama ve test aşamalarında ortalama %1 RMSE ile istikrarlı bir performans sergileyerek trend analizi ve politika yapımı için basit ve uygulanabilir bir araç sağlamıştır. Tek parametre setine odaklanması şehirler arası farklılıkları yansıtamazken, tek değişkenli yaklaşım ekonomik faktörleri dışarda bırakmış, gelecekte hibrit modeller, farklı parametre setleri ve belirsizlik analizleri önerilmiştir.

Rico-Juan ve de La Paz, Alicante, İspanya'daki 1996-2012 dönemi mikro konut verileriyle makine öğrenimi (rassal orman) ve hedonik regresyon yöntemlerini karşılaştırmıştır [10]. Rassal ormanın doğrusal olmayan ilişkileri üç boyutta tespit etme kapasitesi ilk kez incelenerek tahmin doğruluğu değerlendirilmiştir. Rassal orman %2'den az hata ile üstün performans gösterirken konum ve zaman gibi özellikleri görselleştirmede başarılı olmuş, hedonik regresyon ise fiyat seviyesine göre doğrusal olmayan etkileri kantil bazında robust bir şekilde tespit etmiştir. Rassal orman doğrusal olmayan ilişkileri nicel olarak açıklamakta yetersiz kalmış, kantil regresyon ise üç boyutlu gizli nedensel bağlantıları yakalayamamış, derin yapay sinir ağları gibi gelişmiş tekniklerin açıklanabilirlik zorlukları aşarak denenmesi önerilmiştir.

Nouriani ve Lemke, mevcut emlak fiyat tahmin yöntemlerinin iç, dış ve mahalle görsel bilgilerini ihmal ettiğini fark ederek, bu görsel özellikleri derin evrişimli sinir ağlarıyla (CNN) analiz eden ve ev attributes ile birleştiren yenilikçi bir yöntem geliştirmiştir [11]. İç, dış ve uydu görüntülerinden lüks seviyesini sınıflandırarak fiyat tahmini yapılmış, CNN tabanlı model %4,98 medyan hata oranı ile Zestimate (%7,3), Poursaeed (%5,6) ve LSTM (%10,94) gibi yöntemlerden üstün performans göstermiştir. Bessinger veri setinde RMSE'yi 28.281\$'dan 24.137\$'a düşürerek daha doğru tahminler sunmuş, ancak model yalnızca Midwest (Minnesota) verileriyle eğitildiğinden genellenebilirliği sınırlı kalmış ve görsel veri eksikliğinde performansın düşebileceği belirtilmiş, daha büyük ve farklı pazarlardan veri setleriyle geliştirilmesi önerilmiştir.

Çılgın ve Gökçen, Ankara'daki Haziran-Temmuz 2021 emlak satış verileriyle (16.578 kayıt) makine öğrenimi yöntemlerini kullanarak konut fiyatlarını tahmin etmiştir [12]. Doğrusal, Lasso, Ridge Regresyon, XGBoost ve Yapay Sinir Ağları karşılaştırılmış, XGBoost MAPE olarak 0,0198 ile en iyi performansı göstermiş ve ANN ile benzer sonuçlar verirken Doğrusal, Lasso ve Ridge regresyonlardan belirgin şekilde üstün olduğu gözlemlenmiştir. Büyük veri seti ve çok sayıda değişkenle Türkiye emlak piyasasına kapsamlı bir analiz sunulmuş, ancak şehirlerin

özgün dokusu nedeniyle genellenebilirlik sınırlı kalmış, farklı yaklaşımların, hiper-parametrelerin ve kolektif modellerin test edilmesi önerilmiştir.

Kuru Erdem ve diğerleri, İzmir'in Bayraklı ilçesindeki 138 emlağın Nisan-Haziran 2019 verileriyle satış fiyatlarını etkileyen 17 parametreyi istatistiksel olarak analiz etmiştir [13]. 13 etkili parametreyle ayırt edici analiz uygulanarak fiyat aralıklarını tahmin eden yenilikçi fonksiyonlar geliştirilmiş, bu fonksiyonlar emlakların %78,3'ünü (50-100, 100-150, 150-200 bin dolar aralıklarında) doğru sınıflandırmıştır. Emlak alanı, yaşı, mobilya durumu gibi parametrelerin fiyat üzerindeki etkisi ortaya koyularak emlak değerlendirme uzmanlarına pratik bir araç sunulmuş, ancak balkon ve banyo sayısı gibi parametrelerin etkisi anlamlı bulunmamış ve analiz yalnızca Bayraklı ile sınırlı kalarak genellenebilirliği kısıtlanmış, farklı emlak türleri ve daha geniş bölgeler için modeller geliştirilmesi önerilmiştir.

Tekin ve Sarı, Türkiye konut piyasasındaki fiyat artışlarını dikkate alarak İstanbul emlak piyasası için 36.000 satırlık veriyi web kazıma ile toplayıp CRISP-DM çerçevesinde işlemiştir [14]. Doğrusal regresyon, polinomal regresyon, karar ağaçları, rassal ormanlar ve XGBoost algoritmaları test edilmiş, rassal ormanlar ve XGBoost yaklaşık %20 MAPE ile diğer algoritmalarından (doğrusal regresyon %34,42, polinomal %30,15, karar ağaçları %25,42) üstün performans göstermiştir. Parametre optimizasyonu ile %4-6 iyileşme sağlanarak anahtar değişkenlerle doğruluk artırılmış, ancak veriler yalnızca Aralık 2020'den toplandığından güncellik sınırlı kalmış ve eksik özellikler model doğruluğunu etkilemiş, aylık güncellenen dinamik bir model ve daha fazla özellik eklenmesi önerilmiştir.

1.2 TEZİN AMACI

Türkiye'deki emlak piyasası, ekonomik büyüme ve bireysel refah için kritik bir rol oynamaktadır. Emlak değerlemeleri, yatırımcılar, alıcılar ve politika yapıcılar için önemli kararlar alırken, doğru tahminlerin yapılabilmesi için güvenilir verilere ihtiyaç duyulmaktadır. Bu çalışmanın amacı, Türkiye'deki konut piyasasına ait emlak verilerini kullanarak, doğru fiyat tahminleri yapılabilmesi için makine öğrenmesi ve derin öğrenme modelleri geliştirmektir.

Bu çalışmada, Türkiye'deki 128.670 emlak ilanı verisi üzerinden, konut fiyatlarının doğru bir şekilde tahmin edilebilmesi için veri ön işleme, özellik çıkarımı, özellik seçimi ve model eğitimi gibi adımlar uygulanmıştır. Emlak verilerinin kalitesiz girişlerden arındırılması, metinsel verilerin sayısal verilere dönüştürülmesi ve gereksiz özelliklerin elimine edilmesi sağlanmıştır. Özelliklerin korelasyon analizi

yapılmış ve daha sonrasında özyinelemeli öznitelik seçimi yöntemiyle fiyatla ilişkilendirilebilecek en anlamlı 50 özellik belirlenmiş ve bu özellikler üzerinden tahminleme modelleri eğitilmiştir.

Makine öğrenmesi ve derin öğrenme modelleri de test edilerek, modellerin başarısı karşılaştırılmıştır. Çalışmanın nihai hedefi, emlak verileriyle geliştirilen güçlü bir fiyat tahmin modeli oluşturarak, Türkiye’deki emlak piyasasının analizine katkı sağlamaktır.

1.3 HİPOTEZ

1. Emlak fiyat tahmininde kullanılan veri setlerinde, makine öğrenmesi ve derin öğrenme modellerinin küçük, daha az etiketli veriyle eğitilen modellerin, büyük veri setlerine dayalı modellerden daha başarılı sonuçlar verebileceği hipotezi test edilecektir.
2. Türkçe dilindeki emlak verileriyle eğitilmiş makine öğrenmesi ve derin öğrenme modellerinin, çok dilli versiyonlarına kıyasla Türkçe verilerle daha iyi performans sergileyebileceği öngörülmektedir.
3. Emlak fiyat tahmini yapılırken, fiyatları etkileyen özelliklerin metindeki önemli faktörleri yakalayabilen özellik çıkarım modelleri kullanarak daha anlamlı tahminlerin elde edilebileceği ve bu yöntemle elde edilen özelliklerin model başarısını artıracak hipotezi ortaya konacaktır.

2 VERİ KÜMESİ

Bu çalışmada kullanılan veriler, Ocak 2025 tarihinde Türkiye genelinde yayımlanan satılık dairelere ilişkin emlak ilanlarından oluşmaktadır. Veriler, internet üzerindeki çeşitli kaynaklardan geliştirilen bir yazılım aracılığıyla toplanmış olup, belirtilen dönemde toplamda 128.670 ilan verisi elde edilmiştir. Ham verilerde, her bir ilana ait 17 farklı özellik yer almaktadır. Elde edilen veriler, ön işleme aşamasına tabi tutulmuş ve bu süreçte öznitelik çıkarımı yöntemleriyle yeni özellikler eklenmiştir. Sonuç olarak, verilerdeki ilan sayısı 93.350 adete düşerken, her ilana ait 207 özellik ortaya çıkmıştır. Ardından, fiyat tahminine ilişkin en önemli özelliklerin belirlenmesi amacıyla özellik seçimi yapılmıştır.

2.1 ÖN İŞLEME

Ham veri internet üzerinden toplandıktan sonra veriyi işlemek için aşağıdaki adımlar uygulanmıştır:

- Satılık daire verisi olmasına rağmen kiralık ya da dükkan gibi yanlış kategoriye eklenen ilan verileri silinmiştir.
- KKTC'deki ilanlar silinmiştir.
- Demografik ve fiyat bilgisi olmayan ilanlar silinmiştir.
- İlan açıklamalarındaki HTML formatlı içeriklerden metin verisi çıkarılmış, ardından bu metinlerden emoji ve etiketler (hashtag'ler) temizlenmiştir.
- Yapım aşamasındaki ev ilanları silinmiştir.
- Koordinat bilgileri girilmeyen ev ilanları silinmiştir.
- Net ve brüt m² fiyatları metin formatından sayısal veriye çevrilmiştir.
- Dairenin yıl bilgisi hem kategorik hem nümerik olarak tutulmuştur.

- Hangi katta olduđu bilgisi metin formatından sayısal veriye çevrilmiştir.
- Banyo sayısı metin formatından sayısal veriye çevrilmiştir..
- Fiyatı 500.000'den düşük ve 10.000.000'dan yüksek ev ilanları silinmiştir.
- Net m² değeri 30 m²'den küçük ve 200'den büyük ev ilanları silinmiştir.
- Oda sayısı 7'den büyük olan ev ilanları silinmiştir.
- Kat sayısı 20'den fazla olan ev ilanları silinmiştir.
- Banyo ve tuvalet sayıları 0 olan ve 4'ten büyük olan ev ilanları silinmiştir.
- Balkon sayısı metin formatından sayısal veriye çevrilmiştir.
- Eğer veride o özellik için %80 oranında eksik veri varsa o özellikler silinmiştir.
- Dairenin iç, dış ve konum özellik bilgileri ham veriden elde edilmiştir.
- Toplam popülasyon yoğunluğu, medeni durum, eğitim durumu, sosyo-ekonomik durum, ortalama yaş ve ortalama gelir ham veriden elde edilmiştir.
- Amortisman süresi, brüt m² fiyatı ve net m² fiyatı için IQR analizi yapıp aykırı değerler silinmiştir.

2.2 ÖZNİTELİK ÇIKARIMI

Ön işleme aşamasının ardından, verileri zenginleştirmek amacıyla aşağıdaki işlemlerle mevcut verilerden yeni öznitelikler oluşturulmuştur:

- Toplam oda sayısı hesaplanmış ve ortalama oda m²'si hesaplanmıştır.
- Ortalama kiralık ücreti ve amortisman süresi hesaplanmıştır.
- Hangi katta olduđu ve kaç katlı olduđu bilgisi kullanılarak ara kat olup olmadığı bilgisi hesaplanmıştır.
- İlanın eklenme ve son güncelleme tarihinden itibaren kaç gün geçtiği bilgisi hesaplanmıştır.
- Brüt m² fiyatı için dairenin bulunduđu il, ilçe ve mahalle bölgesindeki ortalama fiyatlar bulunmuştur.

- Brüt m² fiyatı için dairenin bulunduğu il, ilçe ve mahalle bölgesindeki daire yıl bilgisindeki ortalama fiyatlar bulunmuştur.
- Brüt m² fiyatı için dairenin bulunduğu il, ilçe ve mahalle bölgesindeki daire oda sayısındaki ortalama fiyatlar bulunmuştur.
- Brüt m² fiyatı için dairenin bulunduğu il, ilçe ve mahalle bölgesindeki daire ısıtma tipindeki ortalama fiyatlar bulunmuştur.
- Brüt m² fiyatı için dairenin bulunduğu il, ilçe ve mahalle bölgesindeki dairenin ara kat bilgisine göre ortalama fiyatlar bulunmuştur.
- Bulunan bu ortalama brüt m² fiyatları ile brüt m² çarpılarak ortalama o daire için fiyatlar bulunmuştur.


2.3 VERİ ANALİZİ

Veri ön işleme ve öznitelik çıkarımı adımlarının ardından, en etkili ilk 10 öznitelik Tablo 2.1’de verilmiştir. Özniteliklerin tamamı Tablo A.1’de verilmiştir.

Tablo 2.1 En Önemli 10 Öznitelik

No	Özellik	Açıklama
1	avg_town_id_build_age_categorical_gross_price	İlgili mahalledeki tüm emlakların, bina yaşına göre gruplandırılmış brüt fiyatlarının ortalaması
2	avg_town_id_heating_type_gross_price	İlgili mahalledeki tüm emlakların, ısıtma tipine göre gruplandırılmış brüt fiyatlarının ortalaması
3	avg_town_id_room_count_gross_price	İlgili mahalledeki tüm emlakların oda sayısına göre gruplandırılmış brüt fiyatlarının ortalaması
4	bath_count	Emlakta bulunan banyo sayısı
5	bosphorus_view	Boğaz manzarası var mı bilgisi
6	avg_town_id_build_age_categorical_gross_m2_price	İlgili mahalledeki tüm emlakların, bina yaşına göre gruplandırılmış brüt m ² fiyatlarının ortalaması
7	avg_town_id_room_count_gross_m2_price	İlgili mahalledeki tüm emlakların oda sayısına göre gruplandırılmış brüt m ² fiyatlarının ortalaması
8	is_mezzanine_floor	Emlak ara kat mı bilgisi
9	room_count	Emlak içindeki toplam oda sayısı
10	heating_type	Emlakta kullanılan ısınma tipi

Veri kümesindeki sayısal özelliklerin dağılımlarını gösteren histogram, Şekil 2.1’de yer almaktadır. Veri kümesindeki sayısal özelliklerin dağılımına baktığımızda, farklı özelliklerin dağılımlarının belirgin farklılıklar gösterdiği görülmektedir.



Şekil 2.1 Sayısal Özelliklerin Dağılımı

Histogramlar, normal, sağa çarpık ve çok modlu dağılımlar sergilemektedir. Bazı özellikler, aşırı yüksek değerler göstererek sağa çarpık bir dağılım sergilerken, diğerleri daha düz veya seyrek dağılımlar göstermektedir. Ayrıca, aykırı ve ekstrem değerler dikkat çekmektedir. Veri kümesinin geniş bir özellik çeşitliliğine sahip olduğu ve bu durumun, model geliştirilirken özellik seçimi ve boyut indirgeme gereksinimlerini gündeme getirebileceği anlaşılmaktadır. Bu gözlemler, konut fiyat tahmini için veri hazırlığı ve model seçiminin önemini vurgulamaktadır.

Fiyat verisine bakıldığında, fiyatların sağa çarpık bir dağılım sergilediği görülmektedir. Veride bazı aşırı yüksek fiyat değerleri bulunmaktadır. Dupleks olmayan emlakların sayısının dupleks olanlardan fazla olduğu gözlemlenmiştir. Brüt ve net metrekarelerin dağılımı normal bir dağılım sergilemektedir. Bina yaşına ait dağılımda, verinin büyük bir kısmının 10 yaşından küçük binalara ait olduğu anlaşılmaktadır. Emlakların bulunduğu katın dağılımına bakıldığında, çoğunluğun ilk 5 kat içerisinde yer aldığı çıkarılabilir. Toplam kat sayısına bakıldığında ise

emlakların çoğunluğunun 5 kat civarında olduđu gör÷lmektedir. Site içerisinde olmayan ve eşyasız satılan emlakların, site içerisinde ve eşyalı satılanlardan daha fazla olduđu tespit edilmiştir. Ayrıca, çođu emlağın bir banyo ve tualete sahip olduđu gözlemlenmiştir. Balkonsuz emlakların, balkonlu emaklardan daha fazla olduđu da dikkat çekicidir. Net ve brüt metrekare fiyatlarının dağılımı normal bir dağılım göstermektedir. Ara kat olan emlak sayısı, ara kat olmayanlardan daha fazladır. Toplam oda sayısının dağılımına baktığımızda ise genellikle 4 odalı emlakların ön planda olduđu gör÷lmektedir. Ortalama oda metrekare fiyatları, aykırı değerler olsa da normal bir dağılıma yakın bir seyir izlemektedir. Semtlerdeki toplam nüfus dağılımı, genellikle düşük yoğunluklu bir yapıyı göstermektedir. Semtlerdeki ortalama yaş dağılımı ise genellikle 35 yaş civarındadır. Ortalama hane halkı gelirinin dağılımı sağa çarpık bir görünüm arz etmektedir. Ortalama satılık ve ortalama kiralık fiyatlarında aykırı değerler bulunduđu gözlemlenmiştir. Amortisman süresi dağılımına bakıldığında ise çođu emlak için bu sürenin 14 yıl olduđu çıkarılabilir. Ortalama illerdeki brüt metrekare fiyatlarının dağılımında, bazı illerdeki metrekare fiyatlarının diğer illerden daha yüksek olduđu anlaşılmaktadır. İllerdeki bina yaşına göre ortalama emlak fiyatları sola çarpık bir dağılım göstermektedir. İllerdeki ara kat bilgisi ve ısıtma tipine göre ortalama emlak fiyatları incelendiğinde ise uç değerlerin var olduđu gözlemlenmiştir. İlçe bazındaki ortalama fiyatlar incelendiğinde ise uç değerlerin azaldığı gör÷lmektedir. Semt bazlı dağılımlar ise daha düzgün bir dağılım sergilemektedir. Semtlere, semtlerdeki bina yaşına, oda sayısına, ısıtma tipine ve ara kat bilgisine göre ortalama brüt metrekare fiyatları normal dağılım gösterirken, aynı özelliklere göre ortalama fiyatlar sağa çarpık bir dağılım sergilemektedir.

2.4 ÖZELLİK SEÇİMİ

Özellik seçimi, modelin daha sade, yorumlanabilir ve hızlı bir hale gelmesini sağlar. Aşırı sayıda değişkenin varlığı, modelin yorumlanmasını karmaşıktırabilir. Gereksiz değişkenlerin çıkarılması, overfitting (aşırı öğrenme) riskini azaltarak modelin genelleme yeteneğini ve gerçek doğruluğunu artırabilir. Ayrıca, değişkenler arasında yüksek korelasyon (multicollinearity) mevcutsa, bir değişkenin elenmesi model performansını iyileştirebilir. Bunun yanı sıra, eğitim süresini kısaltarak özellikle büyük veri setlerinde önemli bir zaman tasarrufu sağlayabilir.

Pearson Korelasyon Katsayısı yöntemi, özellik seçiminde kullanılan yöntemlerden biridir. Bu yöntem, iki sürekli değişken arasındaki doğrusal ilişkiyi ölçen bir istatistiksel yaklaşımdır ve katsayı değeri -1 ile +1 arasında değişir. +1, değişkenler arasında mükemmel pozitif doğrusal ilişkiyi temsil ederken, -1 mükemmel negatif doğrusal ilişkiyi ifade eder; 0 ise değişkenler arasında herhangi bir doğrusal ilişkinin bulunmadığını gösterir. Ev fiyat tahmini gibi uygulamalarda, özellikler arasındaki yüksek korelasyonlar modelin tahmin gücünü artırabilir; ancak bu durum, aynı zamanda aşırı öğrenme (overfitting) riskini de beraberinde getirebilir. Bu nedenle, birbirleriyle yüksek korelasyon gösteren özelliklerden yalnızca birinin seçilmesi, modelin performansını iyileştirebilir ve gereksiz hesaplama yükünü azaltabilir. Pearson Korelasyon Katsayısı, veri setindeki lineer bağımlılıkları tespit etmek için etkili bir araçtır ve bu sayede modelin doğruluğu artırılabilir. Fiyatla olan korelasyonu en yüksek 40 özneliğin birbiriyle olan ilişkilerini gösteren korelasyon matrisi Şekil 2.2’de verilmiştir.



Korelasyon matrisinin incelenmesi sonucunda, emlakların net ve brüt metrekare büyüklükleri ile fiyatları arasında güçlü bir pozitif korelasyon olduğu gözlemlenmiştir. Bu durum, daha büyük metrekareye sahip emlakların genellikle daha yüksek fiyatlarla ilişkilendirildiği şeklinde yorumlanabilir. Benzer şekilde, banyo sayısı ile fiyat arasında da belirgin bir pozitif korelasyon tespit edilmiştir; bu, banyo sayısının artmasının emlak değerini yükseltebileceği yönünde bir çıkarımı desteklemektedir. Toplam oda sayısı ile fiyat arasındaki yüksek pozitif korelasyon ise, oda sayısının artmasıyla emlak fiyatlarının da artma eğiliminde olduğunu göstermektedir. Bununla birlikte, emlak yaşı ile fiyat arasında negatif bir korelasyon bulunmuştur. Bu, bir emlağın yaşı ilerledikçe değerinin düşme eğiliminde olduğu şeklinde yorumlanabilir. Ayrıca, bir bölgedeki ortalama emlak fiyatları ile bireysel emlak fiyatları arasında güçlü bir pozitif korelasyon ortaya çıkmıştır; bu, bir emlağın değerinin büyük ölçüde bulunduğu bölgenin ortalama fiyat düzeyine bağlı olduğunu düşündürmektedir. Son olarak, bölgedeki eğitim düzeyi ile emlak değeri arasında pozitif bir korelasyon gözlemlenmiştir. Bu bulgu, eğitim seviyesinin yükseldiği bölgelerde emlak değerlerinin de artış gösterdiği yönünde bir çıkarımı mümkün kılmaktadır.

Tablo 2.2 Fiyat ile En Yüksek Korelasyona Sahip 20 Öznitelik

Satır	Öznitelik	Korelasyon
1	avg_town_id_build_age_categorical_gross_price	0,90
2	avg_town_id_room_count_gross_price	0,86
3	avg_town_id_heating_type_gross_price	0,86
4	avg_town_id_is_mezzanine_floor_gross_price	0,84
5	avg_town_id_gross_price	0,82
6	averagePriceForSale	0,78
7	averagePriceForRent	0,73
8	avg_town_id_build_age_categorical_gross_m2_price	0,60
9	avg_town_id_heating_type_gross_m2_price	0,57
10	avg_town_id_is_mezzanine_floor_gross_m2_price	0,54
11	avg_town_id_gross_m2_price	0,53
12	gross_square	0,51
13	net_square	0,50
14	total_room_count	0,50
15	avg_town_id_room_count_gross_m2_price	0,50
16	avg_district_id_build_age_categorical_gross_m2_price	0,50
17	bath_count	0,48
18	avg_district_id_heating_type_gross_m2_price	0,47
19	avg_district_id_is_mezzanine_floor_gross_m2_price	0,41
20	avg_district_id_gross_m2_price	0,40

Tablo 2.2’de sunulan veriler incelendiğinde, fiyat ile en güçlü korelasyona sahip öz niteliğin, ilgili mahalledeki tüm emlakların bina yaşına göre gruplandırılmış

brüt metrekare fiyatlarının ortalaması olduğu ortaya çıkmaktadır. Bu bulgu, aynı mahallede ve aynı yaş grubuna ait evlerin değerlerinin genellikle birbirine yakın fiyatlarla ilişkilendirilebileceği şeklinde yorumlanabilir. İlk beş öznitelik değerlendirildiğinde, bunların tamamının mahalle düzeyindeki öznitelikler olduğu dikkati çekmektedir. Buna karşılık, son beş öznitelik ise ilçe düzeyindeki özniteliklerden oluşmaktadır. Bu durum, bir emlağın fiyatının öncelikle bulunduğu mahalledeki fiyatlarla güçlü bir ilişki içinde olduğu, ardından ise ilçe genelindeki fiyatlarla bağlantılı olduğu çıkarımını desteklemektedir. Bu çalışma kapsamında, fiyat ile korelasyon katsayısı 0,015'ten düşük olan öznitelikler, modelin doğruluğunu ve yorumlanabilirliğini artırmak hedefiyle, özellik seçimi sürecinde analizden kaldırılmıştır. Bu özniteliklerin fiyatla olan ilişkisinin son derece zayıf ve ihmal edilebilir düzeyde olduğu saptanmıştır.

2.4.2 ÖZYİNELEMELİ ÖZELLİK SEÇİMİ (RECURSIVE FEATURE ELIMINATION – RFE)

Bu çalışma kapsamında, RFE yöntemi kullanılarak veri setindeki özniteliklerin fiyat ile ilişkisi değerlendirilmiştir. RFE, bir makine öğrenimi modelini temel alarak öznitelikleri özyinelemeli bir şekilde eleyen ve en önemli öznitelikleri seçen bir özellik seçimi yöntemidir. Bu yöntem, modelin performansını artırmak ve gereksiz veya düşük katkılı öznitelikleri ortadan kaldırmak için yaygın olarak kullanılmaktadır. Bu çalışmada, RFE, XGBRegressor algoritması ile uygulanmış ve 50 öznitelik seçilecek şekilde yapılandırılmıştır. RFE yöntemi ile yapılan seçim sonucunda, en önemli 50 öznitelik Tablo 2.3'te verilmiştir.

Tablo 2.3 En Önemli 50 Öz nitelik

No	Öz nitelik	No	Öz nitelik
1	is_duplex	26	camera_system
2	floor_number	27	cloakroom
3	floor_count	28	turkish_bath
4	in_site	29	avg_city_id_gross_m2_price
5	bath_count	30	avg_city_id_build_age_categorical_gross_m2_price
6	wc_count	31	avg_city_id_is_mezzanine_floor_gross_m2_price
7	total_room_count	32	avg_district_id_gross_m2_price
8	is_mezzanine_floor	33	avg_district_id_is_mezzanine_floor_gross_m2_price
9	room_per_m2	34	avg_town_id_gross_m2_price
10	city_popularity	35	avg_town_id_build_age_categorical_gross_m2_price
11	town_popularity	36	avg_town_id_room_count_gross_m2_price
12	air_conditioner	37	avg_town_id_is_mezzanine_floor_gross_m2_price
13	built_in_kitchen	38	avg_town_id_heating_type_gross_m2_price
14	video_intercom	39	avg_town_id_gross_price
15	elevator	40	avg_town_id_build_age_categorical_gross_price
16	dressing_room	41	avg_town_id_room_count_gross_price
17	wooden_frame	42	avg_town_id_is_mezzanine_floor_gross_price
18	jacuzzi	43	avg_town_id_heating_type_gross_price
19	fireplace	44	not_suitable_for_credit
20	siding	45	room_count_3+1
21	lake_view	46	heating_type_air_conditioner
22	sea_view	47	heating_type_floor_heating
23	outdoor_pool	48	usability_tenant_occupies
24	seafront	49	usability_owner_occupies
25	bosphorus_view	50	deed_status_land_title_deed

Bu bölümde, ev fiyat tahmini için kullanılan makine öğrenmesi ve derin öğrenme modelleri ve performans metrikleri açıklanacaktır.

3.1 MAKİNE ÖĞRENMESİ MODELLERİ

3.1.1 XGBOOST


XGBoost, Chen ve Guestrin tarafından 2016 yılında geliştirilmiş bir makine öğrenimi algoritmasıdır [15]. Bu algoritma, karar ağaçlarının oluşturulması için tasarlanmış güçlü ve ölçeklenebilir bir yaklaşımdır. XGBoost, ağaç tabanlı modeller arasında öne çıkar. Çünkü önceki ağaçlardan elde edilen bilgileri kullanır ve yaprak skorlarını bir araya getirerek hataları en aza indirmeye çalışır, böylece tahmin doğruluğunu artırır. Algoritma, her bir ağacın önceki ağaçların hatalarını düzeltecek şekilde sıralı bir biçimde inşa edilmesi prensibine dayanır. Ayrıca, paralel ve dağıtık hesaplama desteğine sahip olması, öğrenme sürecini hızlandırır ve tahmin performansını iyileştirir. Bu özellikler, XGBoost'u büyük veri setleriyle çalışırken ve yüksek doğruluk gerektiren problemlerde özellikle etkili bir araç haline getirir. Bu çalışmada, veri kümesiyle ev fiyatlarını tahmin etmek için XGBoost'un seçilmesi, algoritmanın yüksek doğruluk sunma kapasitesi ve büyük veri hacimlerini etkin bir şekilde işleyebilme yeteneğinden kaynaklanmaktadır.

3.2 DERİN ÖĞRENME MODELLERİ

3.2.1 YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORK - ANN)

Yapay Sinir Ağları, makine öğreniminin temel kavramlarından biri olarak, 20. yüzyılın ortalarında insan beyninden esinlenerek geliştirilmiş bir modeldir. ANN'ler, birbirine bağlı nöron katmanlarından oluşur ve genellikle bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanını içerir. Bu ağlar, son derece çok yönlü yapıları sayesinde sınıflandırma, regresyon ve örüntü tanıma gibi

geniş bir yelpazede görevlere uygulanabilir. Öğrenme süreci, nöronlar arasındaki bağlantıların ağırlıklarını ayarlamayı içerir ve bu işlem, ağırlık tahminleri ile gerçek sonuçlar arasındaki hatayı en aza indirmek için geri yayılım adı verilen bir yöntemle gerçekleştirilir. Geri yayılım, hataları ters yönde yayarak ağırlıkları iteratif bir şekilde günceller ve böylece modelin doğruluğunu artırır. Şekil 3.1’de ANN’lerin çalışma prensibi görülmektedir.



Şekil 3.1 ANN Çalışma Prensibi [16]

Yapay Sinir Ağları, verilerdeki karmaşık ve doğrusal olmayan ilişkileri modelleyebilme yeteneğine sahiptir. Bu da onları finans, sağlık hizmetleri ve doğal dil işleme gibi alanlarda karşılaşılan problemleri çözmek için güçlü bir araç haline getirir [17]. Bu esneklik ve kapasite, ANN’lerin büyük veri setlerinden anlamlı desenler çıkarmasını ve yüksek derecede genelleştirilebilir tahminler yapmasını sağlar. Bu çalışmada, ev fiyat tahmini gibi karmaşık bir regresyon problemi için ANN’lerin kullanımı, bu modellerin non-lineer ilişkileri etkili bir şekilde yakalayabilmesi ve veri kümesinde başarılı sonuçlar üretebilmesi nedeniyle tercih edilmiştir.

$$f(\mathbf{x}) \approx \sum_{i=1}^{N(\epsilon)} a_i \sigma(\mathbf{w}_i \cdot \mathbf{x} + b_i) \quad (3.1)$$


Formül 3.1, bir yapay sinir ağındaki bir nöronun çıkışını modellemektedir. Burada:

- $\mathbf{x}$ girdi vektörünü temsil eder.
- $\mathbf{w}_i$ her bir nöronun ağırlık vektörünü ifade eder.
- b_i her bir nöronun bias (önyargı) terimini temsil eder.

- σ aktivasyon fonksiyonunu ifade eder.
- a_i genellikle her bir nöronun çıktı katsayısı veya ağırlığıdır.
- $N(\epsilon)$ toplam nöron sayısını temsil eder.

3.2.2 EVRİŞİMLİ SINIR AĞLARI (CONVOLUTIONAL NEURAL NETWORK - CNN)

Evrışimli Sinir Ağları, LeCun ve diğerleri tarafından 1989 yılında tanıtılmış olup, görüntüler gibi yapılandırılmış verileri işlemek için tasarlanmış derin öğrenme algoritmalarıdır [18]. CNN'ler, evrişim katmanları ve filtreler kullanarak özelliklerin otomatik olarak algılanmasını sağlar. Bu özellikler, düşük seviyeli kenarlardan yüksek seviyeli nesnelere kadar uzanır. Ayrıca, havuzlama teknikleri uygulanarak verinin boyutları küçültülürken önemli bilgiler korunur, böylece hesaplama verimliliği artırılır. Bu yapılar, görüntü ve video tanıma gibi büyük ölçekli görevler için oldukça uygundur ve hesaplama açısından etkin bir çözüm sunar. CNN'lerin temel avantajı, elle özellik çıkarımı gerektirmeden veriden hiyerarşik desenleri öğrenebilmesidir. Bu, onları geleneksel yöntemlerden ayıran önemli bir özelliktir. Emlak fiyat tahmini gibi uygulamalarda, özellikle 1D CNN'ler, sıralı verilerin analizinde etkili bir rol oynar. 1D CNN'lerin çalışma prensibi Şekil 3.2'de görülmektedir.




Şekil 3.2 CNN Çalışma Prensibi [19]

Bu modeller, geçmiş fiyat trendlerinden örüntüleri yakalayıp gelecekteki değerleri tahmin etme yeteneğine sahiptir. Bu çalışmada, veri kümesinde ev fiyatlarını öngörmek için 1D CNN'lerin tercih edilmesi, algoritmanın zamansal bağımlılıkları modellemedeki başarısı ve büyük veri setlerinde sağlam tahminler üretebilme kapasitesinden kaynaklanmaktadır. Bu özellikler, CNN'leri emlak

piyasasındaki dinamik fiyat değişimlerini analiz etmek için güçlü bir araç haline getirmiştir.

3.2.3 UZUN KISA VADELİ BELLEK (LONG-SHORT TERM MEMORY -LSTM)

Uzun Kısa Vadeli Bellek ağları, Hochreiter tarafından 1997 yılında tanıtılmış olup, sıralı verileri işlemek ve uzun vadeli bağımlılıkları yakalamak için tasarlanmış bir Tür Yinelemeli Sinir Ağı (RNN) modelidir [20]. LSTM'ler, bellek hücreleri ve kapılar kullanarak bilgi akışını düzenler. Bu yapı, önemli detayları uzun diziler boyunca saklama yeteneği sağlar ve geleneksel RNN'lerde sıkça karşılaşılan kaybolan gradyan problemini önler. Bellek hücreleri, hangi bilgilerin tutulacağını veya unutulacağını belirleyen giriş, çıkış ve unutma kapılarıyla çalışır, böylece model hem kısa vadeli hem de uzun vadeli bağlamları etkili bir şekilde öğrenebilir. Şekil 3.3'te LSTM'lerin çalışma prensibi görülmektedir.



Şekil 3.3 LSTM Çalışma Prensibi [21]

Bu özellik, LSTM'leri zaman serisi analizleri için özellikle uygun hale getirir. Örneğin, hisse senedi fiyatları veya emlak trendleri gibi geçmiş değerlerin gelecekteki tahminleri etkilediği durumlarda üstün performans gösterir. LSTM'ler, zamansal örüntülerin anlaşılmasını gerektiren görevlerde başarılıdır ve bu nedenle geçmiş trendlere dayalı olarak gelecekteki emlak fiyatlarını tahmin etmek için son derece elverişlidir. Bu çalışmada, veri kümesiyle ev fiyatlarını öngörmek için LSTM'lerin seçilmesi, modelin uzun vadeli zamansal bağımlılıkları yakalama yetkinliği ve büyük veri setlerinde karmaşık ilişkileri modelleyerek güvenilir tahminler üretme kapasitesinden ileri gelmektedir. Bu, LSTM'leri emlak piyasasındaki fiyat dalgalanmalarını analiz etmek ve geleceğe yönelik doğru projeksiyonlar yapmak için güçlü bir araç haline getirmiştir.


3.2.4 EVRİŞİMLİ SİNİR AĞLARI-UZUN KISA VADELİ BELLEK (CNN-LSTM)

CNN-LSTM ağları, hem mekansal hem de zamansal verileri işlemek için tasarlanmış hibrit bir mimaridir. CNN'ler, görüntüler veya zaman serisi girdileri gibi yapılandırılmış verilerden mekansal özellikleri otomatik olarak çıkarmada etkilidir. Bu CNN katmanları, yerel desenleri ve yapısal ilişkileri algılayarak veriden anlamlı özetler üretir. LSTM ağlarıyla birleştirildiğinde ise, sıralı verilerdeki uzun vadeli bağımlılıkları yakalama yeteneği devreye girer. Bu hibrit yapı, önce CNN katmanlarıyla ilgili mekansal özellikleri çıkarmasına ve ardından LSTM katmanlarıyla zamansal örüntüleri öğrenmesine olanak tanır. Böylelikle model, verinin hem yerel hem de uzun vadeli dinamiklerini bir arada ele alabilir. Bu özellik, CNN-LSTM modellerini, emlak fiyat tahmini gibi hem mekansal hem de zamansal faktörlerin önemli olduğu görevler için son derece uygun hale getirir. Örneğin, piyasa koşulları gibi mekansal özellikler ve geçmiş trendler gibi zamansal veriler, gelecekteki fiyatların öngörülmesinde kritik bir rol oynar. CNN bileşeni, verideki yerel örüntüleri verimli bir şekilde işlerken, LSTM bileşeni uzun vadeli bağımlılıkları yakalayarak modelin karmaşık zaman serisi desenlerini tahmin etme doğruluğunu artırır. Bu çalışmada, veri kümesiyle ev fiyatlarını öngörmek için CNN-LSTM modelinin tercih edilmesi, bu mimarinin hem emlak piyasasındaki yerel özellikleri hem de uzun vadeli trendleri etkili bir şekilde modelleyebilme kapasitesinden kaynaklanmaktadır. Bu kombinasyon, modelin büyük ve karmaşık veri setlerinde sağlam ve güvenilir tahminler üretmesini sağlamıştır.

3.2.5 KOLMOGOROV-ARNOLD AĞLARI (KOLMOGOROV-ARNOLD Network - KAN)

Kolmogorov-Arnold Ağları, Kolmogorov-Arnold temsil teoreminden esinlenerek geliştirilmiş olup, Çok Katmanlı Algılayıcılar'a (MLP) umut vadeden bir alternatif olarak önerilmiştir. Geleneksel MLP'ler, düğümlerde sabit aktivasyon fonksiyonları kullanırken, KAN bu yaklaşımı değiştirerek kenarlarda öğrenilebilir aktivasyon fonksiyonlarına yer verir. Doğrusal ağırlıkların yerini, eğri parametreleriyle tanımlanmış tek değişkenli fonksiyonlar alır. Bu yenilik, KAN'ın hem doğruluk hem de yorumlanabilirlik açısından MLP'lerden üstün performans sergilemesini sağlar. Şekil 3.4'te KAN'ların genel mimarisi görülmektedir.

KAN, daha küçük boyutlarıyla bile veri uydurma ve kısmi diferansiyel denklem çözümü gibi görevlerde MLP'lere kıyasla benzer veya daha iyi sonuçlar elde edebilir. Ayrıca, bu ağlar daha hızlı sinirsel ölçeklendirme yasaları sergiler. Yani, model boyutu arttıkça performans artışı daha verimli bir şekilde gerçekleşir.



Şekil 3.4 KAN Mimarisi [22]

Bunun yanı sıra, KAN'ın yorumlanabilirliği yüksektir ve kullanıcılarla kolayca etkileşime girebilir, bu da onları pratik uygulamalarda avantajlı kılar. Özetle, KAN, MLP'lere kıyasla daha güçlü ve esnek bir alternatif sunar [22]. Bu çalışmada, veri kümesinde KAN'ın kullanımı, modelin yüksek doğrulukla karmaşık ilişkileri öğrenme kapasitesi ve yorumlanabilir sonuçlar üretme yeteneği nedeniyle tercih edilmiştir. Bu özellikler, KAN'ı büyük veri setlerinde etkili bir şekilde çalışabilen ve emlak piyasasındaki fiyat dinamiklerini anlamlı bir şekilde modelleyen bir araç haline getirmiştir.

$$f(\mathbf{x}) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_{p=1}^n \phi_{q,p}(x_p) \right) \quad (3.2)$$

Formül 3.2, Kolmogorov-Arnold Network (KAN) modelinin matematiksel tanımını ifade eder. Burada:

- $\mathbf{x}$ girdi vektörünü temsil eder.
- Φ_q genel aktivasyon fonksiyonlarını ifade eder.
- $\phi_{q,p}(x_p)$ her bir aktivasyon fonksiyonunun girdi öğeleri ile ilgili kısmını belirtir.
- n toplam giriş sayısını ifade eder.
- $2n + 1$ toplam aktivasyon fonksiyonu sayısını ifade eder.

3.3 PERFORMANS METRİKLERİ

Bu çalışmada, modellerinin performansını değerlendirmek için birkaç standart değerlendirme ölçütü kullanılmıştır.

3.3.1 ORTALAMA MUTLAK HATA (MEAN ABSOLUTE ERROR - MAE)

MAE, tahmin edilen ve gerçek fiyatlar arasındaki ortalama mutlak farkı hesaplar ve modelin doğruluğunu ham birimler cinsinden yansıtır. Daha düşük bir MAE, daha iyi bir performansı gösterir. Formül 3.3, MAE'nin hesaplanışını göstermektedir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (3.3)$$

3.3.2 ORTALAMA KARE HATASI (MEAN SQUARED ERROR - MSE)

MSE, tahmin edilen ve gerçek değerler arasındaki ortalama kare farkını nicelendirir ve modelin doğruluğunu genel bir ölçüde sağlar. Daha düşük MSE değerleri, daha iyi bir tahmin performansını gösterir. Formül 3.4, MSE'nin hesaplanışını göstermektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (3.4)$$

3.3.3 KÖK ORTALAMA KARE HATASI (ROOT MEAN SQUARED ERROR - RMSE)

RMSE, MSE'nin kareköküdür ve mülk fiyatlarıyla aynı birimlerde yorumlanabilir bir hata ölçütü sağlar, böylece tahmin hatalarının büyüklüğünü anlamayı kolaylaştırır. Formül 3.5, RMSE'nin hesaplanışını göstermektedir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (3.5)$$

3.3.4 ORTALAMA MUTLAK YÜZDE HATA (MEAN ABSOLUTE PERCENTAGE ERROR - MAPE)

MAPE, tahmin edilen ve gerçek değerler arasındaki yüzde farkını ölçer ve modelin doğruluğunu göreceli bir şekilde anlamamıza olanak tanır. Daha düşük bir MAPE, daha doğru bir modeli gösterir. Formül 3.6, MAPE'nin hesaplanışını göstermektedir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{x_i} \right| \quad (3.6)$$

4 DENEYSEL SONUÇLAR

Bu bölümde, emlak fiyat tahmini problemine yönelik gerçekleştirilen deneysel analizlerin sonuçları sunulmaktadır. Bu kapsamda, Tablo 2.3'te listelenen seçilmiş özellikler, çeşitli makine öğrenmesi ve derin öğrenme modellerinin eğitimi için kullanılmıştır. Deneyler, Apple M3 Pro işlemcili, 18 GB LPDDR5 RAM'li ve macOS işletim sistemli bir cihazda gerçekleştirilmiştir.

4.1 MAKİNE ÖĞRENMESİ MODELLERİ

Bu çalışmada, emlak fiyat tahmini için çeşitli makine öğrenmesi algoritmaları, varsayılan hiperparametre ayarlarıyla eğitilmiş ve performansları test edilmiştir. Elde edilen sonuçlar, RMSE ve eğitim süresi metrikleri üzerinden değerlendirilmiş olup, detaylı karşılaştırma Tablo 4.1'de sunulmuştur.

Tablo 4.1 Makine Öğrenmesi Modellerinin Performans Karşılaştırması

Model	RMSE	Eğitim Süresi (s)
XGBRegressor	0,05	0,81
LGBMRegressor	0,05	1,35
HistGradientBoostingRegressor	0,05	2,50
RandomForestRegressor	0,05	145,59
ExtraTreesRegressor	0,05	61,73
MLPRegressor	0,05	16,68
LinearRegression	0,05	0,23
TransformedTargetRegressor	0,05	0,22
RidgeCV	0,05	0,44
Ridge	0,05	0,09
BayesianRidge	0,05	0,12
LassoLarsIC	0,05	0,36
LassoLarsCV	0,05	0,39
LassoCV	0,05	14,83
ElasticNetCV	0,05	12,90
HuberRegressor	0,05	3,77
GradientBoostingRegressor	0,05	32,28
SGDRegressor	0,05	0,18
LarsCV	0,05	0,79
BaggingRegressor	0,05	12,12
SVR	0,06	133,18
LinearSVR	0,06	33,67
OrthogonalMatchingPursuit	0,06	0,12
OrthogonalMatchingPursuitCV	0,06	0,25
Lars	0,06	0,13
KNeighborsRegressor	0,06	1,22
TheilSenRegressor	0,06	0,21
PassiveAggressiveRegressor	0,07	0,23
PoissonRegressor	0,07	0,30
DecisionTreeRegressor	0,07	2,15
AdaBoostRegressor	0,07	9,09
ExtraTreeRegressor	0,08	0,72
RANSACRegressor	0,09	0,74
ElasticNet	0,14	0,19
LassoLars	0,14	0,09
DummyRegressor	0,14	0,05
Lasso	0,14	0,09
QuantileRegressor	0,14	108,51

En düşük RMSE değerine sahip modeller arasında XGBRegressor, LGBMRegressor ve HistGradientBoostingRegressor yer almaktadır. Bu modeller, emlak fiyat tahmini için seçilen özelliklerle yüksek derecede uyum sağlamış ve tahmin hatalarını en aza indirmiştir. Eğitim süreleri açısından değerlendirildiğinde,

XGBRegressor 0,81 saniye ile en hızlı model olarak öne çıkarken, LGBMRegressor 1,35 saniye ve HistGradientBoostingRegressor 2,50 saniye ile biraz daha fazla hesaplama süresi gerektirmiştir. Bu sonuçlar, gradient boosting tabanlı modellerin emlak fiyat tahmini probleminde güçlü performans sergilediğini göstermektedir.

Kolektif öğrenme yöntemlerinden RandomForestRegressor ve ExtraTreesRegressor da 0,05'lik RMSE ile düşük hata oranları sunmuş, ancak sırasıyla 145,59 ve 61,73 saniyelik eğitim süreleriyle hesaplama maliyeti açısından dezavantajlı bir konumdadır. Bu durum, özellikle büyük veri setlerinde bu modellerin pratikliğini sınırlandırabilir. Benzer şekilde, destek vektör makinelerine dayalı SVR (RMSE: 0,06, 133,18 saniye) ve LinearSVR (RMSE: 0,06, 33,67 saniye) modelleri, daha yüksek RMSE ve uzun eğitim süreleriyle performans-hız dengesinde geride kalmaktadır.

Doğrusal regresyon tabanlı modeller (LinearRegression, Ridge, BayesianRidge vb.), 0,05'lik RMSE ile düşük hata oranları elde etmiş ve 0,09-0,44 saniye arasında değişen eğitim süreleriyle hızlı bir çözüm sunmuştur. Özellikle Ridge (0,09 saniye) ve LinearRegression (0,23 saniye), hesaplama verimliliği açısından dikkat çekicidir ve pratik uygulamalar için uygun bir alternatif oluşturmaktadır.

Buna karşılık, ElasticNet, Lasso, LassoLars ve QuantileRegressor gibi modeller, 0,14'lük RMSE ile diğer modellere kıyasla belirgin şekilde daha yüksek hata oranları sergilemiştir. Bu modeller, emlak fiyat tahmini için seçilen özelliklerle uyum sağlayamamış ve düşük performans göstermiştir. DummyRegressor'ın da 0,14'lük RMSE değeri, bu modelin veri setine herhangi bir öğrenme katkısı sunmadığını doğrulamaktadır.

Sonuç olarak, emlak fiyat tahmini için düşük hata oranı ve hesaplama verimliliği arasında bir denge arandığında, XGBRegressor 0,05'lik RMSE ve 0,81 saniyelik eğitim süresi ile öne çıkmaktadır. Daha hızlı bir çözüm tercih edildiğinde ise Ridge veya LinearRegression gibi doğrusal modeller önerilebilir. Büyük veri setlerinde hesaplama süresi önemli bir kısıt ise, RandomForestRegressor gibi yüksek eğitim süresi gerektiren modellerden kaçınılması uygun olacaktır. Bu bulgular, model seçiminin veri setinin büyüklüğüne, özelliklerin yapısına ve uygulama gereksinimlerine bağlı olarak değişkenlik gösterdiğini ortaya koymaktadır.

4.1.1 XGBOOST DENEYLERİ

XGBoost algoritması, çoklu hiperparametreleri ile esnek bir makine öğrenmesi modeli olup, bu parametrelerin farklı kombinasyonları model performansını önemli ölçüde etkilemektedir. Bu çalışmada, emlak fiyat tahmini için XGBoost modelinin optimal hiperparametre yapılandırmasını belirlemek amacıyla 5 katmanlı

çapraz doğrulama yöntemi uygulanmıştır. Analiz sürecinde, öğrenme oranı (*learning rate*), ağaç sayısı (*n_estimators*), maksimum derinlik (*max_depth*), alt örnekleme oranı (*subsample*) ve sütun örnekleme oranı (*colsample_bytree*) hiperparametreleri sistematik bir şekilde incelenmiştir. Toplamda 384 farklı hiperparametre kombinasyonu test edilmiş ve her bir kombinasyon 5 katmanlı çapraz doğrulama ile değerlendirildiğinden, 1920 ayrı eğitim gerçekleştirilmiştir. En yüksek performansı sağlayan hiperparametre seti belirlenmiş ve şu şekilde bulunmuştur: öğrenme oranı 0,01, ağaç sayısı 1000, maksimum derinlik 9, alt örnekleme oranı 0,8 ve sütun örnekleme oranı 0,8. Test edilen hiperparametrelerin detayları Tablo 4.2’de sunulmuştur.

Tablo 4.2 Test Edilen XGBoost Hiperparametreleri

Hiperparametre	Test Edilen Değerler
Öğrenme Oranı (<i>learning rate</i>)	0,001 - 0,01 - 0,1 - 0,2
Ağaç Sayısı (<i>n_estimators</i>)	100 - 200 - 500 - 1000
Maksimum Derinlik (<i>max_depth</i>)	3 - 6 - 9 - 12
Alt Örnekleme Oranı (<i>subsample</i>)	0,8 - 0,9 - 1,0
Sütun Örnekleme Oranı (<i>colsample_bytree</i>)	0,8 - 1,0

4.2 DERİN ÖĞRENME MODELLERİ

4.2.1 ANN SONUÇLARI


ANN modeli, birim sayısı, aktivasyon fonksiyonları ve bırakma oranları gibi çeşitli hiperparametrelere sahiptir ve bu parametreler modelin performansını farklı şekillerde etkiler. En uygun yapılandırmayı belirlemek amacıyla toplam 243 kombinasyon test edilmiştir. Test edilen hiperparametreler şunlardır: birim sayıları olarak 32, 64 ve 128; aktivasyon fonksiyonları olarak *relu*, *sigmoid* ve *tanh*; bırakma oranları olarak ise 0,1, 0,2 ve 0,5. Model, iki gizli katman, düzenleme için bir bırakma katmanı ve regresyon problemi için tek bir çıktı nöronu içermektedir. Eğitim sürecinde Adam optimize edici ve MSE kayıp fonksiyonu kullanılmıştır. Test edilen hiperparametreler Tablo 4.3’te özetlenmiştir:

Tablo 4.3 Test Edilen ANN Hiperparametreleri

Hiperparametre	Test Edilen Değerler
1,Gizli Katman Birim Sayısı (<i>Units</i>)	32 - 64 - 128
2,Gizli Katman Birim Sayısı (<i>Units</i>)	32 - 64 - 128
1,Gizli Katman Aktivasyonu	relu - sigmoid - tanh
2,Gizli Katman Aktivasyonu	relu - sigmoid - tanh
Bırakma Oranı (<i>Dropout</i>)	0,1 - 0,2 - 0,5

Yapılan testler sonucunda en iyi sonuçları elde eden parametreler Tablo A.2’de

görülebileceği gibi, ilk gizli katman için 128 birim ve ikinci gizli katman için yine 128 birim olarak belirlenmiştir. Her iki gizli katman için de $\tanh$ aktivasyon fonksiyonu kullanılmıştır. Ayrıca, dropout oranı 0,1 olarak belirlenmiştir.



Şekil 4.1 ANN Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi

Şekil 4.1, modelin eğitim ve doğrulama kayıplarının epoch'lar boyunca değişimini göstermektedir. Eğitim kaybı, ilk 50 epoch içinde hızlı bir düşüş sergileyerek yaklaşık 0,065 seviyesinden 0,030 seviyesine inmiştir. Bu hızlı düşüş, modelin eğitim verisine hızlı bir şekilde uyum sağladığını ve öğrenme sürecinin başlangıçta etkin olduğunu göstermektedir. 50. epoch'tan sonra eğitim kaybı, 0,025 civarında stabilize olmuş ve 500 epoch boyunca belirgin bir iyileşme göstermemiştir. Bu durum, modelin eğitim verisi üzerinde öğrenme kapasitesinin sınırına ulaştığını ve daha fazla epoch ile eğitimin eğitim kaybını anlamlı bir şekilde azaltmayacağını düşündürmektedir. Doğrulama kaybı ise eğitim kaybına benzer bir başlangıç trendi izlemiş, ancak daha fazla dalgalanma göstermiştir. İlk 50 epoch içinde doğrulama kaybı 0,050 seviyesinden 0,030 civarına düşmüştür. Ancak, 50. epoch'tan sonra doğrulama kaybı, 0,025 ile 0,035 arasında değişken bir seyir izlemiş ve bazı epoch'larda ani sıçramalar gözlenmiştir. Bu dalgalanmalar, modelin doğrulama verisi üzerinde tutarsız bir performans sergilediğini ve genelleme yeteneğinde bazı sınırlamalar olduğunu göstermektedir. Eğitim kaybının doğrulama kaybından genel olarak daha düşük olması, modelin eğitim verisine hafif bir şekilde aşırı uyum sağladığını işaret etmektedir. Ancak, bu farkın sınırlı olması, aşırı öğrenmenin ciddi bir sorun olmadığını göstermektedir. Elde edilen sonuçlar, modelin daha fazla epoch ile eğitilmesinin performans üzerinde anlamlı bir iyileşme sağlamayacağını

göstermektedir. Doğrulama kaybı, 50. epoch civarında stabilize olmuş ve 500 epoch boyunca belirgin bir düşüş trendi göstermemiştir. Bu nedenle, erken durdurma gibi bir strateji uygulanarak, doğrulama kaybı iyileşmeyi durdurduğunda eğitim sürecinin sonlandırılması daha verimli bir yaklaşım olabilir. Ayrıca, modelin genelleme yeteneğini artırmak için bazı iyileştirmeler önerilebilir. Örneğin, L2 düzenlileştirme gibi ek düzenlileştirme teknikleri uygulanarak aşırı öğrenme riski daha etkin bir şekilde azaltılabilir. Öğrenme oranının düşürülmesi veya bir öğrenme oranı zamanlayıcısı kullanılması, doğrulama kaybındaki dalgalanmaları azaltabilir. Son olarak, veri setinin kalitesi ve eğitim/doğrulama verilerinin dağılımı gözden geçirilerek, modelin genelleme performansı daha da iyileştirilebilir.


4.2.2 CNN SONUÇLARI

CNN modeli, filtre sayısı, çekirdek boyutu, aktivasyon fonksiyonları ve dropout oranı gibi hiperparametrelerle tasarlanmıştır. Optimal yapılandırmayı belirlemek amacıyla çeşitli kombinasyonlar test edilmiştir. Özellikle, 32, 64 ve 128 filtre sayıları; 3 ve 5 olan çekirdek boyutları; relu, sigmoid ve tanh aktivasyon fonksiyonları; ve 0,1, 0,2 ve 0,5 dropout oranları incelenmiştir. Model, regresyon görevlerini yerine getirmek için 1D konvolüsyonel katmanlar, maksimum havuzlama, dropout ve tam bağlı katmanlar kullanmaktadır. Toplamda, özel bir eğitim döngüsü kullanılarak 486 parametre kombinasyonu değerlendirilmiştir. Modeller, Adam optimizasyon algoritması ve MSE kayıp fonksiyonu ile eğitilmiştir. Test edilen hiperparametreler Tablo 4.4'te özetlenmiştir:

Tablo 4.4 Test Edilen CNN Hiperparametreleri

Hiperparametre	Test Edilen Değerler
Filtre Sayısı (<i>Filters</i>)	32 - 64 - 128
Gizli Katman Birim Sayısı (<i>Units</i>)	32 - 64 - 128
Çekirdek Boyutu (<i>Kernel Size</i>)	3 - 5
Bırakma Oranı (<i>Dropout</i>)	0,1 - 0,2 - 0,5
Konvolüsyon Aktivasyonu	relu - sigmoid - tanh
Gizli Katman Aktivasyonu	relu - sigmoid - tanh

En iyi yapılandırma, Tablo A.3'te görülebileceği gibi, 64 filtreye sahip, 1D konvolüsyonel katman için tanh aktivasyon fonksiyonu ve 128 birime sahip, relu aktivasyon fonksiyonu ile ve 0,2 dropout oranı ile belirlenmiştir.



Şekil 4.2 CNN Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi

Şekil 4.2, 1D CNN modelinin eğitim ve doğrulama kayıplarının epoch'lar boyunca değişimini göstermektedir. Eğitim kaybı, ilk 100 epoch içinde hızlı bir düşüş sergileyerek yaklaşık 0,038 seviyesinden 0,026 seviyesine inmiştir. Bu hızlı düşüş, modelin eğitim verisine hızlı bir şekilde uyum sağladığını ve evrişim katmanlarının sıralı verilerden anlamlı özellikler çıkarabildiğini göstermektedir. 100. epoch'tan sonra eğitim kaybı, 0,024 civarında stabilize olmuş ve 500 epoch boyunca küçük dalgalanmalarla bu seviyede devam etmiştir. Bu durum, modelin eğitim verisi üzerinde öğrenme kapasitesinin sınırına ulaştığını ve daha fazla epoch ile eğitimin eğitim kaybını anlamlı bir şekilde azaltmayacağını düşündürmektedir. Doğrulama kaybı ise eğitim kaybına benzer bir başlangıç trendi izlemiş, ancak daha fazla dalgalanma göstermiştir. İlk 20 epoch içinde doğrulama kaybı 0,034 seviyesinden 0,026 civarına düşmüştür. Ancak, 20. epoch'tan sonra doğrulama kaybı, 0,026 ile 0,034 arasında değişken bir seyir izlemiş ve bazı epoch'larda ani sıçramalar gözlenmiştir. Bu dalgalanmalar, modelin doğrulama verisi üzerinde tutarsız bir performans sergilediğini ve genelleme yeteneğinde bazı sınırlamalar olduğunu göstermektedir. Eğitim kaybının doğrulama kaybından genel olarak daha düşük olması ve doğrulama kaybındaki 20. epoch' tan sonraki artış, modelin eğitim verisine hafif bir şekilde aşırı uyum sağladığını işaret etmektedir. Elde edilen sonuçlar, modelin daha fazla epoch ile eğitilmesinin performans üzerinde anlamlı bir iyileşme sağlamayacağını göstermektedir. Doğrulama kaybı, 20. epoch itibariyle artış göstermiştir. Bu nedenle, erken durdurma gibi bir strateji uygulanarak, doğrulama kaybı iyileşmeyi durdurduğunda eğitim sürecinin

sonlandırılması daha verimli bir yaklaşım olabilir.


4.2.3 LSTM SONUÇLARI

LSTM modeli, her biri bir dropout katmanı ile takip edilen iki LSTM katmanı ve regresyon görevleri için bir final dense katmanından oluşmaktadır. Modelin hiperparametreleri, birim sayısı ve dropout oranını içermekte olup, Adam optimizasyon algoritması ve MSE kayıp fonksiyonu kullanılmaktadır. Optimal yapılandırmanın belirlenebilmesi amacıyla toplamda 27 farklı kombinasyon test edilmiştir. Test edilen hiperparametreler Tablo 4.5'te özetlenmiştir:

Tablo 4.5 Test Edilen LSTM Hiperparametreleri

Hiperparametre	Test Edilen Değerler
İlk Katman LSTM Birim Sayısı (<i>Units</i>)	32 - 64 - 128
İkinci Katman LSTM Birim Sayısı (<i>Units</i>)	32 - 64 - 128
Bırakma Oranı (<i>Dropout</i>)	0,1 - 0,2 - 0,5

En iyi performansı sergileyen yapılandırma, Tablo A.4'te görülebileceği gibi, 128 ve 32 birimden oluşan iki LSTM katmanı ile 0,2 dropout oranını içermektedir.



Şekil 4.3 LSTM Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi

Şekil 4.3, LSTM modelinin eğitim ve doğrulama kayıplarının epoch'lar boyunca değişimini göstermektedir. Modelin hem eğitim hem de doğrulama kaybı eğrileri genel olarak azalan bir eğilim sergilemektedir; bu da modelin öğrenme sürecinde istikrarlı bir şekilde hata oranını düşürdüğünü göstermektedir. Özellikle ilk

10 epoch boyunca her iki kayıpta da hızlı bir azalma gözlemlenmiş, bu da modelin erken dönemde veri setindeki temel örüntüleri başarıyla öğrenmeye başladığını göstermektedir. Eğitim kaybı eğrisi, genel olarak doğrulama kaybı eğrisinden daha düşük seyretmektedir. Ancak, bu fark minimal düzeydedir ve doğrulama kaybının belirli noktalarda eğitime kıyasla daha düşük seviyelere inmesi, modelin genellenabilirliğinin yüksek olduğuna işaret etmektedir. 20. epoch sonrası doğrulama kaybı eğrisi daha yatay bir seyir izlemekte olup, bu durum modelin daha fazla öğrenme kapasitesine sahip olmadığını ve erken durdurma kriterlerinin değerlendirilebileceğini düşündürmektedir. Sonuç olarak, elde edilen sonuçlar önerilen LSTM modelinin öğrenme performansının başarılı olduğunu, aşırı öğrenme eğilimlerinin gözlenmediğini ve modelin doğrulama verisi üzerinde tatmin edici bir genelleme performansı sergilediğini ortaya koymaktadır.


4.2.4 CNN-LSTM SONUÇLARI

CNN-LSTM modeli, bir 1D konvolüsyonel katman, maksimum havuzlama, dropout, bir LSTM katmanı ve regresyon görevleri için bir final dense katmanından oluşan hibrit bir ağıdır. Modelin hiperparametreleri, birim sayısı, filtre sayısı, çekirdek boyutu, aktivasyon fonksiyonu ve dropout oranını içermektedir ve Adam optimizasyon algoritması ile MSE kayıp fonksiyonu kullanılmaktadır. Optimal yapılandırmanın belirlenebilmesi amacıyla toplamda 162 farklı kombinasyon test edilmiştir. Test edilen hiperparametreler Tablo 4.6’da özetlenmiştir:

Tablo 4.6 Test Edilen CNN-LSTM Hiperparametreleri

Hiperparametre	Test Edilen Değerler
Filtre Sayısı (<i>Filters</i>)	32 - 64 - 128
LSTM Birim Sayısı (<i>Units</i>)	32 - 64 - 128
Çekirdek Boyutu (<i>Kernel Size</i>)	3 - 5
Bırakma Oranı (<i>Dropout</i>)	0,1 - 0,2 - 0,5
Konvolüsyon Aktivasyonu	relu - sigmoid - tanh

En iyi yapılandırma, Tablo A.5’te görülebileceği gibi, 128 filtreli, 3 çekirdek boyutu ve tanh aktivasyon fonksiyonu ile 128 birimden oluşan bir LSTM katmanı ve 0,1 dropout oranından oluşmaktadır.



Şekil 4.4 CNN-LSTM Modelinin Eğitim ve Doğrulama Kayıplarının Epoch'lar Boyunca Değişimi

Şekil 4.4, CNN-LSTM modelinin eğitim ve doğrulama kayıplarının epoch'lar boyunca değişimini göstermektedir.

Elde edilen eğitim kaybı eğrisi, modelin artan epoch sayısı ile birlikte giderek daha düşük hata oranlarına ulaştığını açıkça ortaya koymaktadır. Ancak, doğrulama kaybı eğrisi 20. epoch civarından itibaren yatay bir seyir izlemeye başlamış ve ilerleyen dönemlerde belirgin bir azalma göstermemiştir. Bu durum, modelin eğitim verisine uyum sağlarken, doğrulama verisi üzerinde genelleme yeteneğinin sınırlı kaldığını düşündürmektedir. Özellikle 50. epoch sonrasında doğrulama kaybındaki hafif dalgalanmalar ve artış eğilimleri, modelin aşırı öğrenmeye başladığına işaret etmektedir. Modelin konvolüsyonel bileşeni, verideki kısa süreli lokal örüntüleri başarılı bir şekilde yakalayabilmekte, ancak zamanla LSTM katmanının doğrulama verisinde daha karmaşık ve değişken desenleri genellemede zorlandığı görülmektedir. Bu bağlamda, erken durdurma stratejisinin uygulanması veya modelin genel kapasitesinin yeniden yapılandırılması, doğrulama performansının artırılması açısından faydalı olabilir. Sonuç olarak, CNN-LSTM mimarisi eğitim verisi üzerinde güçlü bir öğrenme kapasitesi sergilemiş olsa da, doğrulama performansındaki sınırlı iyileşme ve dalgalanmalar, modelin genelleme kabiliyetinin artırılması gerektiğini göstermektedir. Bu durum, daha dengeli ve kararlı bir model elde etmek adına hiperparametre optimizasyonunun önemini ortaya koymaktadır.


4.2.5 KAN SONUÇLARI

KAN modeli, gizli katman sayısı, genel ceza katsayısı, entropi ceza katsayısı ve optimizasyon algoritması gibi hiperparametrelerle tasarlanmıştır. Model, MSE kayıp fonksiyonunu kullanmaktadır. Özellikle, katman sayısı parametresi 2, 3, 4 ve 5 değerleri ile test edilmiştir; λ parametresi 0,0001, 0,001 ve 0,01 değerleri ile test edilmiştir; λ_{entropy} parametresi 0,5, 1,0 ve 2,0 değerleri ile test edilmiştir; optimizer parametresi ise Adam ve LBFGS değerleri ile test edilmiştir. En iyi yapılandırmayı belirlemek amacıyla toplamda 72 kombinasyon test edilmiştir. Tablo 4.7’de özetlenmiştir:

Tablo 4.7 Test Edilen KAN Modeli Hiperparametreleri

Hiperparametre	Test Edilen Değerler
Gizli Katman Sayısı (Hidden Layers)	2 - 3 - 4 - 5
Genel Ceza Katsayısı (λ)	0,0001 - 0,001 - 0,01
Entropi Ceza Katsayısı (λ_{entropy})	0,5 - 1,0 - 2,0
Optimizasyon Algoritması (optimizer)	Adam - LBFGS

Optimal yapılandırma, Tablo A.6’da görülebileceği gibi, LBFGS optimizasyon algoritması, 0,0001 λ değeri ve 0,5 λ_{entropy} değeri ile 2 gizli katmandan oluşmaktadır.



Şekil 4.5 KAN Modelinin Eğitim ve Doğrulama Kayıplarının Epoch’lar Boyunca Değişimi

Şekil 4.5, KAN modelinin eğitim ve doğrulama kayıplarının epoch’lar boyunca değişimini göstermektedir. Grafik incelendiğinde, eğitim kaybı ile doğrulama kaybı

eğrilerinin genel olarak birbiriyle paralel bir seyir izlediği ve eğitim sürecinin başlangıcında her iki kaybın da hızlı bir şekilde azaldığı görülmektedir. Bu durum, modelin erken evrelerde veri setindeki temel örüntüleri başarıyla öğrenebildiğini göstermektedir. Ancak, yaklaşık 35. epoch civarında doğrulama kaybında ani bir sıçrama yaşanmış, ardından tekrar düşüşe geçerek stabil bir hale ulaşmıştır. Bu sıçrama, LBFGS algoritmasının ikinci türevlere dayalı güncellemeleri nedeniyle oluşan lokal optimizasyon etkisiyle açıklanabilir. Eğitim sürecinin ilerleyen aşamalarında doğrulama kaybının belirli bir seviyede plato çizdiği ve eğitim kaybının ise daha düşük bir eğilimle azalmaya devam ettiği gözlemlenmektedir. Bu durum, modelin eğitim verisine aşırı uyum sağlamaya eğilimli olduğunu ve genelleme performansının sınırlı kalabileceğini düşündürmektedir. Ancak, doğrulama kaybındaki artış çok yüksek seviyelerde gerçekleşmemiştir; dolayısıyla modelin genel performansı kabul edilebilir düzeydedir. Sonuç olarak, KAN mimarisi, düşük boyutlu veri temsilde etkili bir yapı ortaya koymakta olup, eğitim sürecinde stabilite ve öğrenme başarısı bakımından tatmin edici sonuçlar vermektedir. Bununla birlikte, doğrulama kaybındaki sıçramalar ve son dönemlerdeki yatay seyir, bu tür modellerde erken durdurma stratejisi, alternatif optimizasyon teknikleri veya hiperparametre ayarlarının yeniden değerlendirilmesi gerektiğini ortaya koymaktadır.

4.3 MODELLERİN KARŞILAŞTIRILMASI

Bu çalışmada, emlak fiyat tahmini problemine yönelik olarak hem makine öğrenmesi hem de derin öğrenme modelleri detaylı bir şekilde analiz edilmiş ve performansları çeşitli metrikler üzerinden değerlendirilmiştir. Modellerin karşılaştırmalı sonuçları, Tablo 4.8’de MAE, MSE, RMSE ve MAPE metrikleri kullanılarak sunulmuştur. Bu metrikler, modellerin tahmin doğruluğunu ve hata dağılımlarını farklı açılardan değerlendirmek için seçilmiştir.

Tablo 4.8 Model Performans Sonuçları

Model Adı	MAE	MSE	RMSE	MAPE
XGBoost	322.401,501	219.171.594,868	468.157,660	0,110
ANN	344.397,264	236.606.390,340	486.422,029	0,120
CNN	343.078,208	240.662.898,127	490.574,050	0,117
LSTM	340.625,180	238.109.317,538	487.964,463	0,116
CNN-LSTM	344.585,272	237.339.686,480	487.175,211	0,120
KAN	345.663,792	240.267.581,177	490.170,971	0,119

Tablo 4.8’de sunulan sonuçlar incelendiğinde, XGBoost modelinin 468.157,660 RMSE ve 0,110 MAPE değerleriyle tüm modeller arasında en iyi performansı

sergilediği görülmektedir. Bu durum, XGBoost'un gradient boosting tabanlı yapısının, emlak fiyat tahmini probleminde seçilen özelliklerle yüksek derecede uyum sağladığını ve tahmin hatalarını en aza indirdiğini göstermektedir. Ayrıca, MAE değerinin 322.401,501 ile en düşük olması, XGBoost'un mutlak hata açısından da diğer modellere üstünlük sağladığını doğrulamaktadır. Bu sonuçlar, XGBoost'un hem doğruluk hem de genelleme kapasitesi açısından bu veri setinde güçlü bir seçenek olduğunu ortaya koymaktadır.

Derin öğrenme modelleri arasında ise LSTM, 487.964,463 RMSE ve 0,116 MAPE ile en iyi performansı sergilemiştir. LSTM'nin sıralı veri işleme yeteneği, emlak fiyat tahmini gibi zamanla değişebilen örüntülerin bulunduğu problemlerde avantaj sağladığını göstermektedir. CNN-LSTM hibrit modeli, 487.175,211 RMSE ile LSTM'ye oldukça yakın bir performans sunmuş, ancak 0,120 MAPE ile biraz daha yüksek bir yüzde hata oranına sahip olmuştur. Bu durum, CNN-LSTM'nin konvolüsyonel katmanlarının lokal örüntüleri yakalamada etkili olduğunu, ancak LSTM bileşeniyle birleştiğinde genelleme performansında sınırlı bir iyileşme sağladığını düşündürmektedir.

ANN, CNN ve KAN modelleri ise sırasıyla 486.422,029, 490.574,050 ve 490.170,971 RMSE değerleriyle XGBoost ve LSTM'ye kıyasla daha yüksek hata oranları sergilemiştir. ANN'nin 344.397,264 MAE ve 0,120 MAPE değerleri, modelin temel yapısının bu problemde tatmin edici bir performans sunduğunu, ancak karmaşık örüntüleri yakalamada XGBoost kadar etkili olmadığını göstermektedir. CNN, 490.574,050 RMSE ile derin öğrenme modelleri arasında en yüksek hata oranına sahip olmuş, bu da 1D konvolüsyonel katmanların bu veri setindeki örüntüleri tam olarak modellemede yetersiz kalabileceğini işaret etmektedir. KAN modeli ise 345.663,792 MAE ve 0,119 MAPE ile nispeten rekabetçi bir performans sunmuş, ancak RMSE değeri (490.170,971) bakımından diğer derin öğrenme modellerine göre belirgin bir üstünlük sağlayamamıştır.

Modellerin MSE değerleri de hata dağılımlarını değerlendirmede önemli bir gösterge sunmaktadır. XGBoost'un 219.171.594,868 ile en düşük MSE'ye sahip olması, tahmin hatalarının karelerinin toplamının diğer modellere kıyasla daha az olduğunu ve dolayısıyla daha tutarlı tahminler ürettiğini göstermektedir. Buna karşılık, CNN (240.662.898,127) ve KAN (240.267.581,177) modelleri en yüksek MSE değerlerine sahip olmuş, bu da bu modellerin daha büyük hatalar üretebileceğini ve genelleme kapasitelerinin sınırlı olabileceğini düşündürmektedir.

Genel olarak, XGBoost'un düşük hata oranları ve tutarlı performansı, bu çalışmada emlak fiyat tahmini için en uygun model olduğunu ortaya koymaktadır. Derin

öğrenme modelleri arasında LSTM ve CNN-LSTM, sıralı ve karmaşık veri yapılarında avantaj sağlasa da, hesaplama maliyeti ve genelleme performansı açısından XGBoost'un gerisinde kalmıştır. ANN, CNN ve KAN modelleri ise daha basit yapılarla rekabetçi sonuçlar sunmuş, ancak karmaşık veri örüntülerini modellemede yetersiz kalmıştır. Bu bulgular, model seçiminde veri setinin yapısı, hesaplama kaynakları ve hedeflenen doğruluk seviyesinin dikkate alınması gerektiğini göstermektedir. Özellikle büyük veri setlerinde ve gerçek zamanlı uygulamalarda, XGBoost'un hem doğruluk hem de verimlilik açısından öne çıktığı söylenebilir.



5 SONUÇ

Bu çalışmada, Türkiye emlak piyasasında konut fiyat tahmini için makine öğrenmesi ve derin öğrenme tekniklerini inceleyerek güçlü bir fiyatlandırma sistemi geliştirilmiştir. XGBRegressor, 468.157,660 RMSE ve %11 MAPE ile en yüksek performansı sergileyerek Türkiye'nin tipik pazarlık oranlarıyla uyumlu, yüksek tahmin doğruluğu sunmuş ve ekonomik koşullar, konum, mülk özellikleri gibi karmaşık piyasa dinamiklerini yansıtarak yatırımcılar ile alıcılar için değerli bir araç olduğunu kanıtlamıştır. Modelin başarısı, 384 hiperparametre kombinasyonu ile optimize edilmesiyle ve 0,81 saniyelik hızlı eğitim süresiyle desteklenirken, derin öğrenme modelleri daha yüksek hata oranlarıyla XGBRegressor'ın gerisinde kalmış, bu da emlak fiyatlarının doğrusal veya az sıralı örüntüler izlediğini ve derin öğrenme modellerinin bu verilerde avantaj sağlayamadığını düşündürmektedir. Diğer makine öğrenmesi modellerinden LGBMRegressor ve HistGradientBoostingRegressor 0,05 RMSE ile iyi sonuçlar vermiş ancak 1,35 ve 2,50 saniyelik eğitim süreleriyle XGBRegressor kadar verimli olamamış, RandomForestRegressor (145,59 saniye) ve ExtraTreesRegressor (61,73 saniye) ise hesaplama maliyetiyle dezavantajlı bulunmuş, doğrusal modeller ise hızlı ancak genelleme kapasitesi sınırlı kalmıştır; veri ön işleme, 128.670'ten 93.350 ilana indirgenen veri setinde kaliteyi koruyarak model doğruluğunu artırmada kritik rol oynamış ve nicelikten çok niteliğin önemini vurgulamıştır.

En yüksek hatanın bulunduğu örnekte, fiyatı 599.000 TL olarak belirtilen bir emlağın model tarafından 2.312.211 TL olarak tahmin edildiği görülmektedir. Bu hatanın nedeni, emlak ilanının açıklama kısmından anlaşılabilmektedir. İlgili ilanda, belirtilen fiyatın yalnızca peşin ödeme tutarı olduğu, kalan kısmın ise taksitli olarak ödeneceği ifade edilmiştir. Bu durum, modelin yalnızca görünen fiyatı baz alarak yaptığı tahmini yanıltmıştır.

Sonuç olarak, XGBRegressor'ın düşük hata oranları ve pratikliği, bu modeli Türkiye emlak piyasası için en uygun seçenek haline getirmekte, gelecekte NLP ile metin analizi ve kullanıcı dostu bir arayüz eklenmesiyle daha da geliştirilebileceği

önerilmektedir. Böylece bu araştırma, emlak sektöründe makine öğrenmesinin kullanımını teşvik ederek diğer piyasalara da uygulanabilir sağlam bir temel sunmaktadır.



- [1] L. Wang, G. Wang, H. Yu F. Wang, “Prediction and analysis of residential house price using a flexible spatiotemporal model,” *Journal of Applied Economics*, c. 25, no. 1, ss. 503–522, 2022.
- [2] A. Hjort, J. Pensar, I. Scheel D. E. Sommervoll, “House price prediction with gradient boosted trees under different loss functions,” *Journal of Property Research*, c. 39, no. 4, ss. 338–364, 2022.
- [3] A. B. Adetunji, O. N. Akande, F. A. Ajala, O. Oyewo, Y. F. Akande G. Oluwadara, “House price prediction using random forest machine learning technique,” *Procedia Computer Science*, c. 199, ss. 806–813, 2022.
- [4] D. Dua C. Graff, *UCI Machine Learning Repository: Real estate valuation data set*, <https://archive.ics.uci.edu/dataset/477/real+estate+valuation+data+set>, Accessed: 2025-04-06, 2024.
- [5] K. Kopczewska P. Ćwiakowski, “Spatio-temporal stability of housing submarkets. Tracking spatial location of clusters of geographically weighted regression estimates of price determinants,” *Land Use Policy*, c. 103, s. 105 292, 2021.
- [6] S. Özögür Akyüz, B. Eygi Erdogan, Ö. Yıldız P. Karadayı Ataş, “A novel hybrid house price prediction model,” *Computational economics*, c. 62, no. 3, ss. 1215–1232, 2023.
- [7] G. M. Ahlfeldt, S. Heblich T. Seidel, “Micro-geographic property price and rent indices,” *Regional Science and Urban Economics*, c. 98, s. 103 836, 2023.
- [8] R. Gupta, H. A. Marfatia, C. Pierdzioch A. A. Salisu, “Machine learning predictions of housing market synchronization across US states: the role of uncertainty,” *The Journal of Real Estate Finance and Economics*, ss. 1–23, 2022.
- [9] X. Xu Y. Zhang, “House price forecasting with neural networks,” *Intelligent Systems with Applications*, c. 12, s. 200 052, 2021.
- [10] J. R. Rico-Juan P. T. de La Paz, “Machine learning with explainability or spatial hedonics tools? An analysis of the asking prices in the housing market in Alicante, Spain,” *Expert Systems with Applications*, c. 171, s. 114 590, 2021.
- [11] A. Nouriani L. Lemke, “Vision-based housing price estimation using interior, exterior & satellite images,” *Intelligent Systems with Applications*, c. 14, s. 200 081, 2022.

- [12] C. Çılğın H. Gökçen, “Machine learning methods for prediction real estate sales prices in Turkey,” *Revista de la construcción*, c. 22, no. 1, ss. 163–177, 2023.
- [13] M. Kuru Erdem, O. Yiğit Erdem G. Calis, “Sale price classification models for real estate appraisal,” *Revista de la construcción*, c. 20, no. 3, ss. 440–451, 2021.
- [14] M. Tekin I. U. Sari, “Real estate market price prediction model of Istanbul,” *Real Estate Management and Valuation*, c. 30, no. 4, ss. 1–16, 2022.
- [15] T. Chen C. Guestrin, “Xgboost: A scalable tree boosting system,” *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, ss. 785–794.
- [16] W. Commons, *Artificial Neuron Model (English)*, Erişim Tarihi: 7 Nisan 2025, 2025. erişim adresi: https://commons.wikimedia.org/wiki/File:ArtificialNeuronModel_english.png.
- [17] Y. LeCun, Y. Bengio G. Hinton, “Deep learning,” *nature*, c. 521, no. 7553, ss. 436–444, 2015.
- [18] Y. LeCun ve diğ., “Backpropagation applied to handwritten zip code recognition,” *Neural computation*, c. 1, no. 4, ss. 541–551, 1989.
- [19] A. Shenfield M. Howarth, “A novel deep learning model for the detection and identification of rolling element-bearing faults,” *Sensors*, c. 20, no. 18, s. 5112, 2020.
- [20] S. Hochreiter J. Schmidhuber, “Long short-term memory,” *Neural computation*, c. 9, no. 8, ss. 1735–1780, 1997.
- [21] A. Zhang, Z. C. Lipton, M. Li A. J. Smola, *Chapter 10: Long Short-Term Memory*, Erişim Tarihi: 7 Nisan 2025, 2025. erişim adresi: https://d2l.ai/chapter_recurrent-modern/lstm.html.
- [22] Z. Liu ve diğ., “Kan: Kolmogorov-arnold networks,” *arXiv preprint arXiv:2404.19756*, 2024.

A

ÖZNİTELİK AÇIKLAMALARI VE MODEL SONUÇLARI

Tablo A.1 İlan Öznitelikleri

No	Özellik	Açıklama
1	id	İlanın ait benzersiz kimlik numarası
2	created_at	İlanın oluşturulma tarihi ve saati
3	updated_at	İlanın son güncellenme tarihi ve saati
4	is_sale	İlandaki emlağın satılık mı bilgisi
5	title	İlanın başlığı
6	description	İlan hakkında detaylı açıklama
7	url	İlana ait bağlantı
8	from_owner	İlandaki emlak sahibinden mi bilgisi
9	whatsapp_number	İlan ile ilgili iletişime geçilebilecek WhatsApp numarası
10	price	Emlak satış fiyatı
11	opportunity	Emlak fırsat bir ilan mı bilgisi
12	coordinate_lat	Emlak konumunun enlem koordinatı
13	coordinate_lon	Emlak konumunun boylam koordinatı
14	city_id	Emlak konumunun bağlı olduğu şehir ID'si
15	city_name	Emlak konumunun bağlı olduğu şehir adı
16	town_id	Emlak konumunun bağlı olduğu ilçe ID'si
17	town_name	Emlak konumunun bağlı olduğu ilçe adı
18	district_id	Emlak konumunun bağlı olduğu semt ID'si
19	district_name	Emlak konumunun bağlı olduğu semt adı
20	valuation_min_price	Emlak minimum değerlendirme fiyatı
21	valuation_max_price	Emlak maksimum değerlendirme fiyatı
22	is_duplex	Emlak dubleks mi bilgisi
23	estate_type	Emlak türü
24	net_square	Emlak net kullanım alanı
25	gross_square	Emlak brüt alanı
26	room_count	Emlak içindeki toplam oda sayısı
27	build_age	Emlak binasının yaşı
28	floor_number	Emlak kat numarası
29	floor_count	Emlak toplam kat sayısı
30	heating_type	Emlakta kullanılan ısınma tipi

No	Özellik	Açıklama
31	usability	Emlak kullanım durumu
32	suitability_for_credit	Emlak kredibilitesi
33	suitability_for_investor	Yatırımcılar için uygunluk bilgisi
34	is_second_hand	İkinci el mi bilgisi
35	deed_status	Emlak tapu durumu
36	in_site	Emlak bir site içinde mi bilgisi
37	has_furniture	Emlak eşyalı mı bilgisi
38	bath_count	Emlakta bulunan banyo sayısı
39	has_balcony	Emlakta balkon var mı bilgisi
40	wc_count	Emlakta bulunan WC sayısı
41	build_age_categorical	Emlak bina yaşı kategorisi
42	net_m2_price	Emlak net alan başına m ² fiyatı
43	gross_m2_price	Emlak brüt alan başına m ² fiyatı
44	created_at_diff	İlanın oluşturulma tarihine göre geçen süre
45	updated_at_diff	İlanın güncellenme tarihine göre geçen süre
46	total_room_count	Emlak içindeki toplam oda sayısı
47	is_mezzanine_floor	Emlak ara kat mı bilgisi
48	room_per_m2	m ² başına düşen oda sayısı
49	total_population	Emlak çevresindeki toplam nüfus
50	total_population_density	Emlak çevresindeki nüfus yoğunluğu
51	educational_level_density	Çevredeki eğitim seviyesi yoğunluğu
52	marital_status_density	Çevredeki evlilik durumu yoğunluğu
53	socioeconomic_status_density	Çevredeki sosyoekonomik durum yoğunluğu
54	average_age	Emlak çevresindeki ortalama yaş
55	house_income_total	Emlak çevresindeki toplam hane geliri
56	average_price_for_sale	Satılık emlakların ortalama fiyatı
57	average_price_for_rent	Kiralık emlakların ortalama fiyatı
58	amortization	Emlak satış fiyatının kira cinsinden yıl olarak geri ödeme süresi
59	educational_level	Emlak çevresindeki eğitim seviyesi
60	marital_status	Emlak çevresindeki evlilik durumu
61	city_popularity	Emlağın bulunduğu şehrin toplam veri kümesindeki şehirlere oranı
62	district_popularity	Emlağın bulunduğu ilçenin toplam veri kümesindeki ilçelere oranı
63	town_popularity	Emlağın bulunduğu semtin toplam veri kümesindeki semtlere oranı
64	adsl	ADSL internet bağlantısı mevcut mu bilgisi
65	cable_tv_satellite	Kablo TV veya uydu yayını mevcut mu bilgisi
66	bathtub	Küvet mevcut mu bilgisi
67	shower_cabin	Duşakabin mevcut mu bilgisi
68	hot_water	Sıcak su mevcut mu bilgisi
69	built_in_wardrobe	Gömme dolap mevcut mu bilgisi

No	Özellik	Açıklama
70	ceramic_floor	Seramik zemin mevcut mu bilgisi
71	satin_paint	Saten boya kullanımı mevcut mu bilgisi
72	steel_door	Çelik kapı mevcut mu bilgisi
73	panel_door	Panel kapı mevcut mu bilgisi
74	laminate	Laminat zemin mevcut mu bilgisi
75	cornice	Kartonpiyer mevcut mu bilgisi
76	spot_light	Spot ışık mevcut mu bilgisi
77	parquet	Parke zemin mevcut mu bilgisi
78	air_conditioner	Klima mevcut mu bilgisi
79	built_in_kitchen	Ankastre mutfak mevcut mu bilgisi
80	cabinet_kitchen	Dolaplı mutfak mevcut mu bilgisi
81	american_kitchen	Amerikan mutfak mevcut mu bilgisi
82	pantry	Kiler mevcut mu bilgisi
83	gas_stove	Doğalgazlı ocak mevcut mu bilgisi
84	kitchen_furniture	Mutfak mobilyası mevcut mu bilgisi
85	heat_insulation	Isı yalıtımı mevcut mu bilgisi
86	apartment_attendant	Apartman görevlisi hizmeti mevcut mu bilgisi
87	shared_garden	Ortak kullanım bahçesi mevcut mu bilgisi
88	video_intercom	Görüntülü diafon mevcut mu bilgisi
89	detached_garden	Müstakil bahçe mevcut mu bilgisi
90	water_pump	Hidrofor mevcut mu bilgisi
91	fire_escape	Yangın merdiveni mevcut mu bilgisi
92	elevator	Asansör mevcut mu bilgisi
93	water_tank	Su deposu mevcut mu bilgisi
94	pvc_frame	PVC doğrama pencere mevcut mu bilgisi
95	generator	Jeneratör mevcut mu bilgisi
96	insulated_glass	Isıcam pencere mevcut mu bilgisi
97	sound_insulation	Ses yalıtımı mevcut mu bilgisi
98	childrens_park	Çocuk parkı mevcut mu bilgisi
99	open_parking	Açık otopark mevcut mu bilgisi
100	basketball_court	Basketbol sahası mevcut mu bilgisi
101	closed_parking	Kapalı otopark mevcut mu bilgisi
102	shopping_center	Alışveriş merkezi var mı bilgisi
103	walking_track	Yürüyüş parkuru var mı bilgisi
104	green_view	Yeşil alan manzarası var mı bilgisi
105	highway	Otobana yakın mı bilgisi
106	near_street	Caddeye yakın mı bilgisi
107	near_hospital	Hastaneye yakın mı bilgisi
108	near_school	Okula yakın mı bilgisi
109	fiber	Fiber internet bağlantısı mevcut mu bilgisi
110	intercom	Görüntülü interkom sistemi mevcut mu bilgisi
111	sauna	Sauna mevcut mu bilgisi
112	washing_machine	Çamaşır makinesi mevcut mu bilgisi
113	high_ceiling	Yüksek tavan mevcut mu bilgisi
114	lacquer_kitchen	Lake mutfak var mı bilgisi
115	wooden_frame	Ahşap doğrama pencere var mı bilgisi

No	Özellik	Açıklama
116	bus	Otobüs durağına yakın mı bilgisi
117	hilton_bathroom	Hilton tipi banyo var mı bilgisi
118	laminat_kitchen	Laminat mutfak mevcut mu bilgisi
119	north_facing	Emlak kuzey cepheli mi bilgisi
120	west_facing	Emlak batı cepheli mi bilgisi
121	near_local_market	Semt pazarına yakın mı bilgisi
122	main_road	Anayola yakın mı bilgisi
123	metro	Metro istasyonuna yakın mı bilgisi
124	near_mosque	Camiye yakın mı bilgisi
125	e_5	E-5 Karayolu'na yakın mı bilgisi
126	metrobus	Metrobüs durağına yakın mı bilgisi
127	minibus	Dolmuş durağına yakın mı bilgisi
128	oven	Fırın var mı bilgisi
129	electric_stove	Setüstü ocak var mı bilgisi
130	east_facing	Emlak doğu cepheli mi bilgisi
131	garden	Bahçe mevcut mu bilgisi
132	city_view	Şehir manzarası var mı bilgisi
133	jacuzzi	Jakuzi mevcut mu bilgisi
134	burglar_alarm	Hırsız alarmı mevcut mu bilgisi
135	south_facing	Emlak güney cepheli mi bilgisi
136	water_heater	Şofben mevcut mu bilgisi
137	en_suite_bathroom	Ebeveyn banyosu mevcut mu bilgisi
138	shutters	Panjur mevcut mu bilgisi
139	dressing_room	Giyinme odası mevcut mu bilgisi
140	cloakroom	Vestiye mevcut mu bilgisi
141	laundry_room	Çamaşır odası mevcut mu bilgisi
142	ready_kitchen	Hazır mutfak var mı bilgisi
143	camera_system	Kamera güvenlik sistemi mevcut mu bilgisi
144	security	24 saat güvenlik mevcut mu bilgisi
145	accessible_for_disabled	Engellilere uygun mu bilgisi
146	tennis_court	Tenis kortu mevcut mu bilgisi
147	outdoor_pool	Açık havuz mevcut mu bilgisi
148	pool_view	Havuz manzarası var mı bilgisi
149	airport	Havaalanına yakın mı bilgisi
150	near_sea	Denize yakın mı bilgisi
151	wi_fi	Wi-Fi bağlantısı mevcut mu bilgisi
152	fireplace	Şömine mevcut mu bilgisi
153	siding	Siding dış cephe var mı bilgisi
154	lake_view	Göl manzarası var mı bilgisi
155	sea_view	Deniz manzarası var mı bilgisi
156	white_goods	Beyaz eşya mevcut mu bilgisi
157	volleyball_court	Voleybol sahası mevcut mu bilgisi
158	football_field	Futbol sahası mevcut mu bilgisi
159	fitness	Fitness salonu var mı bilgisi
160	ferry_pier	Vapur iskelesine yakın mı bilgisi

No	Özellik	Açıklama
161	sea_bus	Deniz otobüsü iskelesine yakın mı bilgisi
162	fire_alarm	Yangın alarmı mevcut mu bilgisi
163	wallpaper	Duvar kağıdı var mı bilgisi
164	aluminum_frame	Alüminyum doğrama pencere var mı bilgisi
165	train_station	Tren istasyonuna yakın mı bilgisi
166	italian_bathroom	İtalyan tarzı banyo var mı bilgisi
167	dishwasher	Bulaşık makinesi mevcut mu bilgisi
168	marley	Marley zemin var mı bilgisi
169	italian_kitchen	İtalyan tarzı mutfak var mı bilgisi
170	marmaray	Marmaray'a yakın mı bilgisi
171	eurasia_tunnel	Avrasya Tüneli'ne yakın mı bilgisi
172	indoor_pool	Kapalı havuz mevcut mu bilgisi
173	bosphorus_bridges	Boğaz köprülerine yakın mı bilgisi
174	tram	Tramvay hattına yakın mı bilgisi
175	tem	TEM otoyoluna yakın mı bilgisi
176	squat_toilet	Alaturka tuvalet var mı bilgisi
177	seafront	Denize sıfır mı bilgisi
178	bosphorus_view	Boğaz manzarası var mı bilgisi
179	trolleybus	Trolleybüs durağına yakın mı bilgisi
180	cable_car	Teleferik hattına yakın mı bilgisi
181	refrigerator	Buzdolabı mevcut mu bilgisi
182	smart_home	Emlak akıllı ev sistemiyle mi donatılmış bilgisi
183	face_and_fingerprint_recognition	Yüz tanıma ve parmak izi güvenlik sistemi var mı bilgisi
184	fingerprint	Parmak izi güvenlik sistemi var mı bilgisi
185	turkish_bath	Hamam mevcut mu bilgisi
186	dryer	Çamaşır kurutma makinesi mevcut mu bilgisi
187	private_pool	Müstakil havuz mevcut mu bilgisi
188	avg_city_id_gross_m2_price	İlgili şehirdeki tüm emlakların brüt m ² fiyatlarının ortalaması
189	avg_city_id_build_age_categorical_gross_m2_price	İlgili şehirdeki tüm emlakların, bina yaşına göre gruplandırılmış brüt m ² fiyatlarının ortalaması
190	avg_city_id_room_count_gross_m2_price	İlgili şehirdeki tüm emlakların oda sayısına göre gruplandırılmış brüt m ² fiyatlarının ortalaması
191	avg_city_id_is_mezzanine_floor_gross_m2_price	İlgili şehirdeki tüm emlakların, ara kat olup olmadığına göre brüt m ² fiyatlarının ortalaması
192	avg_city_id_heating_type_gross_m2_price	İlgili şehirdeki tüm emlakların, ısıtma tipine göre gruplandırılmış brüt m ² fiyatlarının ortalaması
193	avg_district_id_gross_m2_price	İlgili ilçede yer alan tüm emlakların brüt m ² fiyatlarının ortalaması

No	Özellik	Açıklama
194	avg_district_id_build_age_categorical_gross_m2_price	İlgili ilçedeki tüm emlakların, bina yaşına göre gruplandırılmış brüt m ² fiyatlarının ortalaması
195	avg_district_id_room_count_gross_m2_price	İlgili ilçedeki tüm emlakların oda sayısına göre gruplandırılmış brüt m ² fiyatlarının ortalaması
196	avg_district_id_is_mezzanine_floor_gross_m2_price	İlgili ilçedeki tüm emlakların, ara kat olup olmadığına göre brüt m ² fiyatlarının ortalaması
197	avg_district_id_heating_type_gross_m2_price	İlgili ilçedeki tüm emlakların, ısıtma tipine göre gruplandırılmış brüt m ² fiyatlarının ortalaması
198	avg_town_id_gross_m2_price	İlgili mahalledeki tüm emlakların brüt m ² fiyatlarının ortalaması
199	avg_town_id_build_age_categorical_gross_m2_price	İlgili mahalledeki tüm emlakların, bina yaşına göre gruplandırılmış brüt m ² fiyatlarının ortalaması
200	avg_town_id_room_count_gross_m2_price	İlgili mahalledeki tüm emlakların oda sayısına göre gruplandırılmış brüt m ² fiyatlarının ortalaması
201	avg_town_id_is_mezzanine_floor_gross_m2_price	İlgili mahalledeki tüm emlakların, ara kat olup olmadığına göre brüt m ² fiyatlarının ortalaması
202	avg_town_id_heating_type_gross_m2_price	İlgili mahalledeki tüm emlakların, ısıtma tipine göre gruplandırılmış brüt m ² fiyatlarının ortalaması
203	avg_town_id_gross_price	İlgili mahalledeki tüm emlakların brüt fiyatlarının ortalaması
204	avg_town_id_build_age_categorical_gross_price	İlgili mahalledeki tüm emlakların, bina yaşına göre gruplandırılmış brüt fiyatlarının ortalaması
205	avg_town_id_room_count_gross_price	İlgili mahalledeki tüm emlakların oda sayısına göre gruplandırılmış brüt fiyatlarının ortalaması
206	avg_town_id_is_mezzanine_floor_gross_price	İlgili mahalledeki tüm emlakların, ara kat olup olmadığına göre gruplandırılmış brüt fiyatlarının ortalaması
207	avg_town_id_heating_type_gross_price	İlgili mahalledeki tüm emlakların, ısıtma tipine göre gruplandırılmış brüt fiyatlarının ortalaması

Tablo A.2 ANN Hipermatre Sonuçları

No	1.Gizli Katman Birim Sayısı	2.Gizli Katman Birim Sayısı	1.Gizli Katman Aktivasyonu	2.Gizli Katman Aktivasyonu	Dropout Oranı	RMSE
1	128	128	tanh	tanh	0,1	0,053
2	128	64	tanh	sigmoid	0,1	0,053
3	64	64	sigmoid	relu	0,1	0,053

No	1.Gizli Katman Birim Sayısı	2.Gizli Katman Birim Sayısı	1.Gizli Katman Aktivasyon Fonksiyonu	2.Gizli Katman Aktivasyon Fonksiyonu	Dropout	RMSE
4	64	128	sigmoid	sigmoid	0,1	0,053
5	32	128	tanh	sigmoid	0,1	0,053
6	128	64	relu	tanh	0,1	0,053
7	128	128	sigmoid	tanh	0,1	0,053
8	128	32	tanh	relu	0,1	0,053
9	64	128	tanh	relu	0,1	0,053
10	128	64	relu	relu	0,1	0,053
11	64	64	sigmoid	sigmoid	0,1	0,053
12	128	64	sigmoid	tanh	0,1	0,053
13	32	128	sigmoid	tanh	0,2	0,053
14	128	32	relu	relu	0,1	0,053
15	64	64	tanh	tanh	0,1	0,053
16	64	128	tanh	relu	0,5	0,053
17	64	128	sigmoid	sigmoid	0,5	0,053
18	128	64	sigmoid	tanh	0,5	0,053
19	32	128	tanh	relu	0,2	0,053
20	128	128	relu	tanh	0,1	0,053
21	32	64	tanh	tanh	0,1	0,053
22	64	128	tanh	sigmoid	0,2	0,053
23	128	32	sigmoid	sigmoid	0,2	0,053
24	32	128	sigmoid	sigmoid	0,2	0,053
25	128	64	sigmoid	tanh	0,2	0,053
26	128	64	relu	sigmoid	0,1	0,053
27	64	32	relu	relu	0,2	0,053
28	32	64	relu	tanh	0,2	0,053
29	128	128	sigmoid	relu	0,2	0,053
30	32	64	relu	relu	0,1	0,053
31	64	64	tanh	sigmoid	0,1	0,053
32	64	128	sigmoid	relu	0,2	0,053
33	128	128	tanh	relu	0,1	0,053
34	128	128	sigmoid	sigmoid	0,5	0,053
35	128	32	sigmoid	relu	0,2	0,053
36	128	64	relu	sigmoid	0,5	0,053
37	128	128	sigmoid	relu	0,1	0,053
38	128	32	sigmoid	sigmoid	0,1	0,053
39	64	128	tanh	tanh	0,2	0,053
40	64	32	sigmoid	sigmoid	0,2	0,053
41	64	128	tanh	sigmoid	0,1	0,053
42	64	128	sigmoid	sigmoid	0,2	0,053
43	64	32	tanh	sigmoid	0,2	0,053
44	64	64	sigmoid	tanh	0,1	0,053
45	64	32	tanh	tanh	0,2	0,053
46	32	128	tanh	relu	0,1	0,053

No	1.Gizli Katman Birim Sayısı	2.Gizli Katman Birim Sayısı	1.Gizli Katman Aktivasyon Fonksiyonu	2.Gizli Katman Aktivasyon Fonksiyonu	Dropout	RMSE
47	32	64	tanh	sigmoid	0,1	0,053
48	32	32	relu	relu	0,2	0,053
49	64	64	tanh	relu	0,1	0,053
50	64	32	relu	tanh	0,2	0,053
51	128	128	relu	relu	0,1	0,053
52	64	128	sigmoid	relu	0,5	0,053
53	128	64	tanh	tanh	0,1	0,053
54	32	32	relu	tanh	0,1	0,053
55	32	32	sigmoid	sigmoid	0,2	0,053
56	32	64	sigmoid	sigmoid	0,1	0,053
57	128	64	tanh	relu	0,1	0,053
58	64	32	relu	sigmoid	0,1	0,053
59	64	64	tanh	sigmoid	0,2	0,053
60	32	128	relu	sigmoid	0,2	0,053
61	64	128	relu	relu	0,1	0,053
62	64	128	relu	tanh	0,2	0,053
63	32	128	relu	tanh	0,5	0,053
64	128	128	tanh	sigmoid	0,1	0,053
65	128	128	tanh	sigmoid	0,2	0,053
66	32	64	relu	relu	0,2	0,053
67	64	32	tanh	tanh	0,1	0,053
68	64	64	tanh	relu	0,2	0,053
69	128	32	sigmoid	tanh	0,1	0,053
70	32	128	relu	sigmoid	0,5	0,053
71	64	64	sigmoid	sigmoid	0,2	0,053
72	64	128	sigmoid	tanh	0,5	0,053
73	64	128	relu	tanh	0,5	0,053
74	128	32	tanh	tanh	0,1	0,053
75	64	32	tanh	relu	0,2	0,053
76	32	64	sigmoid	sigmoid	0,5	0,053
77	128	128	tanh	tanh	0,2	0,053
78	128	128	relu	tanh	0,2	0,053
79	32	64	sigmoid	relu	0,2	0,053
80	128	128	sigmoid	sigmoid	0,2	0,053
81	64	64	relu	sigmoid	0,1	0,053
82	64	128	relu	relu	0,5	0,053
83	32	128	tanh	sigmoid	0,5	0,053
84	64	64	tanh	tanh	0,5	0,053
85	64	128	tanh	sigmoid	0,5	0,053
86	64	128	sigmoid	tanh	0,2	0,053
87	128	128	relu	relu	0,5	0,053
88	64	32	sigmoid	tanh	0,2	0,053
89	128	128	tanh	relu	0,2	0,053

No	1.Gizli Katman Birim Sayısı	2.Gizli Katman Birim Sayısı	1.Gizli Katman Aktivasyon Fonksiyonu	2.Gizli Katman Aktivasyon Fonksiyonu	Dropout	RMSE
90	64	64	relu	tanh	0,2	0,053
91	32	128	relu	relu	0,5	0,054
92	64	128	relu	tanh	0,1	0,054
93	32	128	tanh	tanh	0,1	0,054
94	32	64	tanh	relu	0,2	0,054
95	128	64	sigmoid	sigmoid	0,2	0,054
96	128	32	relu	relu	0,2	0,054
97	32	32	relu	sigmoid	0,1	0,054
98	32	128	relu	sigmoid	0,1	0,054
99	32	64	sigmoid	relu	0,1	0,054
100	64	32	sigmoid	relu	0,2	0,054
101	64	64	sigmoid	tanh	0,2	0,054
102	32	128	sigmoid	relu	0,5	0,054
103	32	32	sigmoid	sigmoid	0,1	0,054
104	64	64	relu	tanh	0,1	0,054
105	64	64	relu	tanh	0,5	0,054
106	128	128	sigmoid	relu	0,5	0,054
107	32	64	tanh	sigmoid	0,2	0,054
108	32	128	relu	relu	0,2	0,054
109	128	128	relu	tanh	0,5	0,054
110	32	128	relu	tanh	0,2	0,054
111	32	64	relu	tanh	0,1	0,054
112	64	64	sigmoid	relu	0,5	0,054
113	64	64	relu	sigmoid	0,5	0,054
114	64	128	relu	sigmoid	0,5	0,054
115	32	128	sigmoid	relu	0,1	0,054
116	32	128	sigmoid	tanh	0,5	0,054
117	32	128	relu	relu	0,1	0,054
118	64	32	relu	relu	0,1	0,054
119	128	128	tanh	sigmoid	0,5	0,054
120	128	32	sigmoid	tanh	0,2	0,054
121	32	32	sigmoid	tanh	0,1	0,054
122	64	64	relu	sigmoid	0,2	0,054
123	32	32	sigmoid	sigmoid	0,5	0,054
124	64	128	tanh	relu	0,2	0,054
125	32	32	sigmoid	tanh	0,2	0,054
126	128	128	tanh	tanh	0,5	0,054
127	32	64	tanh	tanh	0,2	0,054
128	64	128	relu	sigmoid	0,1	0,054
129	128	64	relu	sigmoid	0,2	0,054
130	128	64	sigmoid	sigmoid	0,5	0,054
131	128	128	sigmoid	tanh	0,5	0,054
132	64	32	relu	tanh	0,5	0,054

No	1.Gizli Katman Birim Sayısı	2.Gizli Katman Birim Sayısı	1.Gizli Katman Aktivasyon Fonksiyonu	2.Gizli Katman Aktivasyon Fonksiyonu	Dropout	RMSE
133	128	64	tanh	tanh	0,5	0,054
134	32	64	sigmoid	relu	0,5	0,054
135	64	32	relu	tanh	0,1	0,054
136	32	32	tanh	sigmoid	0,2	0,054
137	128	64	tanh	relu	0,5	0,054
138	128	128	relu	relu	0,2	0,054
139	32	64	sigmoid	tanh	0,1	0,054
140	32	64	relu	sigmoid	0,5	0,054
141	64	64	sigmoid	sigmoid	0,5	0,054
142	128	64	relu	tanh	0,2	0,054
143	64	32	sigmoid	sigmoid	0,1	0,054
144	128	128	sigmoid	sigmoid	0,1	0,054
145	128	32	tanh	relu	0,5	0,054
146	128	32	relu	sigmoid	0,1	0,054
147	128	64	sigmoid	relu	0,2	0,054
148	32	32	relu	sigmoid	0,5	0,054
149	32	64	relu	sigmoid	0,2	0,054
150	32	128	tanh	tanh	0,2	0,054
151	64	128	sigmoid	relu	0,1	0,054
152	32	128	sigmoid	relu	0,2	0,054
153	128	128	sigmoid	tanh	0,2	0,054
154	32	32	relu	tanh	0,5	0,054
155	32	32	tanh	sigmoid	0,1	0,054
156	32	64	tanh	tanh	0,5	0,054
157	64	64	sigmoid	relu	0,2	0,054
158	32	64	tanh	relu	0,5	0,054
159	64	64	relu	relu	0,1	0,054
160	32	64	sigmoid	sigmoid	0,2	0,054
161	128	32	tanh	relu	0,2	0,054
162	32	128	sigmoid	tanh	0,1	0,054
163	128	32	relu	tanh	0,2	0,054
164	32	128	tanh	relu	0,5	0,054
165	128	128	relu	sigmoid	0,5	0,054
166	64	64	relu	relu	0,2	0,054
167	64	32	tanh	relu	0,1	0,054
168	32	32	relu	relu	0,1	0,054
169	32	64	relu	sigmoid	0,1	0,054
170	32	64	tanh	sigmoid	0,5	0,054
171	32	32	tanh	relu	0,1	0,054
172	32	32	relu	sigmoid	0,2	0,055
173	128	32	relu	sigmoid	0,2	0,055
174	128	32	relu	tanh	0,1	0,055
175	64	32	tanh	tanh	0,5	0,055

No	1.Gizli Katman Birim Sayısı	2.Gizli Katman Birim Sayısı	1.Gizli Katman Aktivasyon Fonksiyonu	2.Gizli Katman Aktivasyon Fonksiyonu	Dropout	RMSE
176	32	32	tanh	tanh	0,2	0,055
177	64	32	sigmoid	tanh	0,1	0,055
178	64	32	relu	sigmoid	0,5	0,055
179	64	32	tanh	sigmoid	0,1	0,055
180	64	128	relu	sigmoid	0,2	0,055
181	128	32	tanh	tanh	0,5	0,055
182	64	128	sigmoid	tanh	0,1	0,055
183	128	32	relu	relu	0,5	0,055
184	64	64	tanh	relu	0,5	0,055
185	64	64	tanh	tanh	0,2	0,055
186	32	128	relu	tanh	0,1	0,055
187	128	128	relu	sigmoid	0,1	0,055
188	64	32	sigmoid	sigmoid	0,5	0,055
189	32	32	sigmoid	relu	0,1	0,055
190	64	32	sigmoid	relu	0,1	0,055
191	128	32	sigmoid	relu	0,1	0,055
192	128	64	relu	relu	0,5	0,055
193	64	32	tanh	sigmoid	0,5	0,055
194	64	32	relu	relu	0,5	0,055
195	128	64	sigmoid	relu	0,5	0,055
196	32	128	sigmoid	sigmoid	0,1	0,055
197	32	32	tanh	tanh	0,5	0,055
198	32	32	tanh	tanh	0,1	0,055
199	32	32	relu	relu	0,5	0,055
200	128	64	tanh	sigmoid	0,5	0,055
201	32	32	tanh	relu	0,5	0,055
202	128	64	tanh	sigmoid	0,2	0,055
203	32	64	relu	relu	0,5	0,055
204	32	64	relu	tanh	0,5	0,055
205	128	32	relu	sigmoid	0,5	0,055
206	64	128	tanh	tanh	0,5	0,055
207	128	128	relu	sigmoid	0,2	0,055
208	128	32	sigmoid	tanh	0,5	0,055
209	32	32	relu	tanh	0,2	0,055
210	32	32	sigmoid	relu	0,2	0,055
211	32	32	tanh	sigmoid	0,5	0,055
212	32	128	tanh	tanh	0,5	0,055
213	64	64	tanh	sigmoid	0,5	0,056
214	64	64	relu	relu	0,5	0,056
215	128	32	tanh	sigmoid	0,1	0,056
216	128	32	tanh	sigmoid	0,2	0,056
217	128	64	tanh	relu	0,2	0,056
218	64	32	sigmoid	tanh	0,5	0,056

No	1.Gizli Katman Birim Sayısı	2.Gizli Katman Birim Sayısı	1.Gizli Katman Aktivasyon Fonksiyonu	2.Gizli Katman Aktivasyon Fonksiyonu	Dropout	RMSE
219	128	128	tanh	relu	0,5	0,056
220	128	64	sigmoid	relu	0,1	0,056
221	32	32	sigmoid	relu	0,5	0,056
222	128	32	tanh	sigmoid	0,5	0,056
223	128	64	relu	relu	0,2	0,056
224	32	64	sigmoid	tanh	0,2	0,056
225	64	128	tanh	tanh	0,1	0,056
226	128	64	sigmoid	sigmoid	0,1	0,056
227	64	32	tanh	relu	0,5	0,057
228	32	64	sigmoid	tanh	0,5	0,057
229	32	128	tanh	sigmoid	0,2	0,057
230	32	64	tanh	relu	0,1	0,057
231	128	32	sigmoid	relu	0,5	0,057
232	32	128	sigmoid	sigmoid	0,5	0,057
233	128	32	sigmoid	sigmoid	0,5	0,058
234	128	32	tanh	tanh	0,2	0,058
235	128	32	relu	tanh	0,5	0,058
236	32	32	tanh	relu	0,2	0,058
237	64	32	sigmoid	relu	0,5	0,058
238	64	64	sigmoid	tanh	0,5	0,058
239	64	32	relu	sigmoid	0,2	0,059
240	128	64	relu	tanh	0,5	0,059
241	32	32	sigmoid	tanh	0,5	0,06
242	128	64	tanh	tanh	0,2	0,063
243	64	128	relu	relu	0,2	0,063

Tablo A.3 CNN Hipermatre Sonuçları

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
1	64	128	5	0,1	tanh	relu	0,053
2	32	128	3	0,2	tanh	relu	0,053
3	64	64	5	0,1	tanh	relu	0,053
4	32	128	5	0,1	tanh	relu	0,053
5	32	64	5	0,2	tanh	relu	0,053
6	64	128	3	0,1	relu	relu	0,053
7	128	64	5	0,1	tanh	relu	0,053
8	32	128	3	0,1	tanh	relu	0,053
9	128	128	5	0,1	relu	relu	0,053
10	64	128	3	0,2	tanh	relu	0,053
11	32	64	5	0,1	relu	relu	0,053

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
12	128	64	5	0,2	tanh	relu	0,053
13	128	32	5	0,1	relu	relu	0,053
14	64	64	3	0,2	tanh	relu	0,053
15	32	32	5	0,2	tanh	relu	0,053
16	64	128	5	0,2	tanh	relu	0,054
17	64	32	3	0,2	tanh	relu	0,054
18	32	32	3	0,1	tanh	relu	0,054
19	128	32	5	0,2	tanh	relu	0,054
20	128	128	5	0,2	tanh	relu	0,054
21	64	32	5	0,2	tanh	relu	0,054
22	128	64	5	0,1	relu	relu	0,054
23	128	32	3	0,1	relu	relu	0,054
24	128	128	3	0,2	tanh	relu	0,054
25	64	128	5	0,2	relu	relu	0,054
26	128	128	3	0,1	relu	relu	0,054
27	32	32	5	0,1	relu	relu	0,054
28	32	64	5	0,5	tanh	relu	0,054
29	64	128	3	0,2	relu	relu	0,054
30	64	32	3	0,1	tanh	relu	0,054
31	32	128	5	0,1	relu	relu	0,054
32	64	64	5	0,2	tanh	relu	0,054
33	64	64	3	0,2	relu	relu	0,054
34	128	32	5	0,1	tanh	relu	0,054
35	128	128	3	0,2	relu	relu	0,054
36	128	128	5	0,5	tanh	relu	0,054
37	32	64	3	0,2	tanh	relu	0,054
38	128	64	3	0,5	tanh	relu	0,054
39	32	64	3	0,1	tanh	relu	0,054
40	64	64	3	0,1	relu	relu	0,054
41	32	64	5	0,1	tanh	relu	0,054
42	64	64	5	0,1	relu	relu	0,054
43	64	32	5	0,1	tanh	relu	0,054
44	128	64	3	0,1	relu	relu	0,054
45	32	32	3	0,1	relu	relu	0,054
46	64	32	5	0,2	tanh	sigmoid	0,054
47	128	128	3	0,1	tanh	relu	0,054
48	128	32	3	0,1	tanh	relu	0,054
49	128	32	3	0,5	tanh	relu	0,054
50	128	64	3	0,2	tanh	relu	0,054
51	32	64	3	0,5	tanh	relu	0,054
52	128	128	3	0,5	tanh	relu	0,054
53	128	128	5	0,1	tanh	relu	0,054
54	32	128	5	0,5	tanh	relu	0,054
55	128	32	3	0,1	relu	sigmoid	0,054

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
56	32	128	3	0,5	tanh	relu	0,054
57	32	64	3	0,1	relu	tanh	0,054
58	64	128	5	0,2	tanh	sigmoid	0,054
59	32	64	5	0,1	relu	sigmoid	0,054
60	64	32	3	0,1	tanh	sigmoid	0,054
61	64	64	5	0,2	relu	relu	0,054
62	32	64	5	0,1	tanh	tanh	0,054
63	128	64	3	0,2	relu	relu	0,054
64	32	128	5	0,1	tanh	tanh	0,055
65	64	32	3	0,1	relu	sigmoid	0,055
66	128	32	3	0,2	tanh	relu	0,055
67	32	64	3	0,1	relu	relu	0,055
68	32	64	3	0,2	relu	relu	0,055
69	64	128	5	0,1	tanh	sigmoid	0,055
70	128	64	5	0,5	relu	relu	0,055
71	32	32	3	0,1	relu	sigmoid	0,055
72	32	64	5	0,2	relu	relu	0,055
73	128	32	5	0,5	tanh	relu	0,055
74	128	32	5	0,2	tanh	tanh	0,055
75	64	64	5	0,5	tanh	relu	0,055
76	64	128	3	0,5	tanh	relu	0,055
77	32	128	5	0,2	relu	relu	0,055
78	32	64	5	0,1	relu	tanh	0,055
79	64	128	5	0,1	tanh	tanh	0,055
80	32	128	3	0,1	relu	relu	0,055
81	128	128	5	0,1	tanh	sigmoid	0,055
82	32	128	5	0,2	tanh	tanh	0,055
83	32	64	5	0,1	tanh	sigmoid	0,055
84	128	64	3	0,2	relu	sigmoid	0,055
85	32	128	3	0,1	tanh	sigmoid	0,055
86	64	128	5	0,5	tanh	relu	0,055
87	64	64	3	0,1	relu	sigmoid	0,055
88	64	32	3	0,2	tanh	tanh	0,055
89	128	64	5	0,5	tanh	relu	0,055
90	64	64	3	0,1	tanh	tanh	0,055
91	64	32	3	0,2	tanh	sigmoid	0,055
92	64	32	5	0,1	tanh	tanh	0,055
93	32	64	5	0,2	tanh	tanh	0,055
94	64	64	5	0,1	relu	tanh	0,055
95	32	128	3	0,1	tanh	tanh	0,055
96	128	128	5	0,5	relu	relu	0,055
97	128	32	3	0,1	relu	tanh	0,055
98	32	32	5	0,1	tanh	sigmoid	0,055
99	64	128	3	0,1	relu	tanh	0,055

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
100	64	32	5	0,1	relu	tanh	0,055
101	64	32	5	0,1	relu	relu	0,055
102	128	64	5	0,2	relu	relu	0,055
103	64	32	5	0,5	tanh	relu	0,055
104	128	128	5	0,2	relu	relu	0,055
105	64	64	5	0,2	tanh	tanh	0,055
106	64	128	5	0,1	relu	tanh	0,055
107	32	32	5	0,1	relu	tanh	0,055
108	128	32	3	0,5	tanh	tanh	0,055
109	64	32	3	0,1	relu	tanh	0,055
110	32	32	5	0,2	tanh	tanh	0,055
111	64	64	5	0,2	tanh	sigmoid	0,055
112	64	32	5	0,2	relu	relu	0,055
113	128	64	3	0,5	relu	relu	0,055
114	32	32	3	0,1	relu	tanh	0,055
115	128	32	3	0,2	relu	tanh	0,055
116	128	128	3	0,5	relu	relu	0,055
117	32	32	5	0,5	tanh	relu	0,055
118	64	32	3	0,5	tanh	relu	0,055
119	32	64	5	0,2	relu	sigmoid	0,055
120	128	64	3	0,1	relu	tanh	0,055
121	64	64	3	0,2	tanh	tanh	0,055
122	32	128	5	0,1	relu	sigmoid	0,055
123	32	128	5	0,2	relu	tanh	0,055
124	64	32	5	0,5	relu	relu	0,055
125	128	32	5	0,1	relu	tanh	0,055
126	32	32	3	0,2	tanh	sigmoid	0,055
127	32	32	3	0,2	tanh	tanh	0,055
128	64	128	5	0,2	relu	sigmoid	0,055
129	64	64	5	0,5	relu	relu	0,055
130	128	32	3	0,2	tanh	sigmoid	0,055
131	64	32	3	0,2	relu	tanh	0,055
132	32	128	5	0,1	relu	tanh	0,055
133	32	32	5	0,2	relu	relu	0,055
134	64	64	3	0,1	relu	tanh	0,055
135	128	128	3	0,1	relu	tanh	0,055
136	64	32	5	0,1	tanh	sigmoid	0,055
137	32	128	3	0,2	relu	relu	0,055
138	32	32	3	0,5	tanh	relu	0,055
139	32	32	5	0,2	relu	sigmoid	0,055
140	32	64	5	0,2	tanh	sigmoid	0,055
141	128	32	5	0,5	relu	relu	0,055
142	32	32	3	0,1	tanh	sigmoid	0,055
143	128	64	5	0,1	tanh	sigmoid	0,055

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
144	128	64	3	0,1	tanh	tanh	0,055
145	128	32	5	0,5	tanh	tanh	0,056
146	64	128	5	0,2	tanh	tanh	0,056
147	32	32	5	0,1	tanh	relu	0,056
148	64	64	5	0,1	tanh	tanh	0,056
149	32	128	5	0,2	relu	sigmoid	0,056
150	32	64	3	0,2	tanh	tanh	0,056
151	32	32	3	0,2	relu	tanh	0,056
152	64	64	3	0,2	relu	tanh	0,056
153	64	32	5	0,2	tanh	tanh	0,056
154	64	128	3	0,1	tanh	relu	0,056
155	64	64	5	0,5	tanh	sigmoid	0,056
156	32	64	5	0,2	relu	tanh	0,056
157	32	128	5	0,5	relu	relu	0,056
158	128	32	3	0,1	tanh	tanh	0,056
159	128	64	3	0,1	relu	sigmoid	0,056
160	32	32	5	0,5	relu	relu	0,056
161	128	64	5	0,5	tanh	tanh	0,056
162	32	64	3	0,5	tanh	sigmoid	0,056
163	128	32	5	0,5	tanh	sigmoid	0,056
164	32	64	5	0,5	tanh	sigmoid	0,056
165	128	64	5	0,2	relu	sigmoid	0,056
166	64	128	3	0,1	tanh	sigmoid	0,056
167	128	64	3	0,2	tanh	tanh	0,056
168	128	128	3	0,5	tanh	sigmoid	0,056
169	32	32	5	0,1	tanh	tanh	0,056
170	128	64	3	0,1	tanh	relu	0,056
171	64	64	5	0,5	tanh	tanh	0,056
172	128	128	5	0,2	relu	tanh	0,056
173	64	32	5	0,1	relu	sigmoid	0,056
174	32	128	3	0,5	relu	relu	0,056
175	32	32	3	0,2	tanh	relu	0,056
176	128	128	5	0,1	relu	sigmoid	0,056
177	64	32	3	0,5	relu	relu	0,056
178	64	32	5	0,2	relu	tanh	0,056
179	64	64	5	0,1	relu	sigmoid	0,056
180	64	128	3	0,2	tanh	sigmoid	0,056
181	128	32	3	0,1	tanh	sigmoid	0,056
182	64	32	3	0,5	tanh	sigmoid	0,056
183	128	128	3	0,2	relu	sigmoid	0,056
184	64	128	5	0,2	relu	tanh	0,056
185	64	64	3	0,5	tanh	relu	0,056
186	64	64	5	0,2	relu	sigmoid	0,056
187	64	32	3	0,2	relu	relu	0,056

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
188	32	32	5	0,5	relu	tanh	0,056
189	32	32	5	0,1	relu	sigmoid	0,056
190	128	32	5	0,2	relu	tanh	0,056
191	64	128	3	0,2	tanh	tanh	0,056
192	32	64	3	0,1	tanh	tanh	0,056
193	128	128	3	0,5	tanh	tanh	0,056
194	128	128	5	0,2	relu	sigmoid	0,056
195	128	128	3	0,2	relu	tanh	0,056
196	128	32	5	0,2	tanh	sigmoid	0,056
197	32	64	5	0,5	relu	relu	0,056
198	32	64	3	0,2	relu	tanh	0,056
199	32	64	3	0,2	relu	sigmoid	0,056
200	64	32	3	0,2	relu	sigmoid	0,056
201	64	128	5	0,1	relu	relu	0,056
202	32	32	5	0,5	tanh	sigmoid	0,056
203	64	32	3	0,5	tanh	tanh	0,056
204	64	128	3	0,5	relu	relu	0,056
205	32	128	3	0,2	tanh	sigmoid	0,056
206	64	32	5	0,2	relu	sigmoid	0,057
207	32	32	3	0,5	relu	relu	0,057
208	64	32	5	0,5	relu	tanh	0,057
209	128	32	3	0,5	relu	relu	0,057
210	32	32	5	0,5	tanh	tanh	0,057
211	64	32	5	0,5	tanh	sigmoid	0,057
212	128	64	3	0,5	relu	tanh	0,057
213	128	64	5	0,1	relu	tanh	0,057
214	64	32	3	0,1	tanh	tanh	0,057
215	128	32	3	0,2	relu	relu	0,057
216	128	32	5	0,2	relu	sigmoid	0,057
217	128	32	3	0,5	relu	sigmoid	0,057
218	32	128	3	0,1	relu	tanh	0,057
219	32	128	3	0,2	tanh	tanh	0,057
220	64	128	3	0,2	relu	tanh	0,057
221	128	64	3	0,1	tanh	sigmoid	0,057
222	32	64	3	0,1	tanh	sigmoid	0,057
223	64	128	5	0,5	tanh	tanh	0,057
224	32	64	3	0,5	tanh	tanh	0,057
225	32	128	5	0,1	tanh	sigmoid	0,057
226	128	32	5	0,5	relu	tanh	0,057
227	32	32	3	0,2	relu	relu	0,057
228	64	64	5	0,2	relu	tanh	0,057
229	64	64	3	0,2	relu	sigmoid	0,057
230	32	32	3	0,5	tanh	sigmoid	0,057
231	64	64	5	0,5	relu	sigmoid	0,057

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
232	128	128	3	0,2	tanh	tanh	0,057
233	64	128	3	0,5	tanh	sigmoid	0,057
234	32	128	3	0,2	relu	sigmoid	0,057
235	32	128	5	0,5	tanh	tanh	0,057
236	32	128	5	0,2	tanh	relu	0,057
237	128	64	5	0,1	relu	sigmoid	0,057
238	32	32	5	0,2	tanh	sigmoid	0,057
239	128	32	3	0,2	relu	sigmoid	0,057
240	32	32	3	0,1	tanh	tanh	0,057
241	128	128	5	0,2	tanh	tanh	0,057
242	128	64	3	0,5	relu	sigmoid	0,057
243	64	64	5	0,5	relu	tanh	0,057
244	64	64	3	0,5	relu	relu	0,057
245	64	64	3	0,5	relu	sigmoid	0,057
246	128	32	5	0,2	relu	relu	0,057
247	32	64	3	0,5	relu	sigmoid	0,057
248	64	64	3	0,1	tanh	relu	0,057
249	128	32	3	0,5	relu	tanh	0,057
250	128	128	5	0,2	tanh	sigmoid	0,057
251	64	128	5	0,5	relu	relu	0,057
252	32	128	3	0,2	relu	tanh	0,057
253	128	32	5	0,1	relu	sigmoid	0,057
254	64	32	3	0,5	relu	tanh	0,058
255	64	64	3	0,5	relu	tanh	0,058
256	128	64	5	0,5	relu	tanh	0,058
257	128	128	5	0,1	tanh	tanh	0,058
258	32	64	3	0,5	relu	relu	0,058
259	64	64	3	0,2	tanh	sigmoid	0,058
260	64	128	5	0,5	relu	tanh	0,058
261	32	32	5	0,2	relu	tanh	0,058
262	128	128	5	0,5	relu	sigmoid	0,058
263	128	32	5	0,1	tanh	tanh	0,058
264	64	128	3	0,5	relu	tanh	0,058
265	64	128	3	0,5	tanh	tanh	0,058
266	64	64	3	0,5	tanh	tanh	0,058
267	128	32	3	0,2	tanh	tanh	0,058
268	32	64	5	0,5	tanh	tanh	0,058
269	64	128	5	0,5	relu	sigmoid	0,058
270	128	64	5	0,2	tanh	tanh	0,058
271	32	64	3	0,2	tanh	sigmoid	0,058
272	32	32	5	0,5	relu	sigmoid	0,058
273	64	32	5	0,5	tanh	tanh	0,058
274	32	128	3	0,1	relu	sigmoid	0,058
275	64	128	5	0,1	relu	sigmoid	0,058

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
276	128	32	5	0,5	relu	sigmoid	0,058
277	128	128	5	0,1	relu	tanh	0,058
278	32	128	5	0,5	relu	sigmoid	0,058
279	64	32	3	0,5	relu	sigmoid	0,058
280	128	128	5	0,5	tanh	tanh	0,058
281	128	64	3	0,5	tanh	tanh	0,058
282	128	64	3	0,2	relu	tanh	0,058
283	32	64	5	0,5	relu	sigmoid	0,058
284	64	128	3	0,1	tanh	tanh	0,058
285	32	128	5	0,5	relu	tanh	0,058
286	128	64	5	0,1	tanh	tanh	0,059
287	32	128	5	0,5	tanh	sigmoid	0,059
288	32	128	3	0,5	tanh	sigmoid	0,059
289	32	32	3	0,5	relu	sigmoid	0,059
290	64	64	5	0,1	tanh	sigmoid	0,059
291	32	128	3	0,5	relu	tanh	0,059
292	128	64	3	0,5	tanh	sigmoid	0,059
293	128	64	5	0,5	tanh	sigmoid	0,059
294	128	64	5	0,2	tanh	sigmoid	0,059
295	32	32	3	0,5	tanh	tanh	0,059
296	32	64	5	0,5	relu	tanh	0,059
297	64	32	3	0,1	relu	relu	0,059
298	64	32	5	0,5	relu	sigmoid	0,06
299	64	64	3	0,1	tanh	sigmoid	0,06
300	32	128	3	0,5	tanh	tanh	0,06
301	128	32	5	0,1	tanh	sigmoid	0,06
302	32	32	3	0,5	relu	tanh	0,06
303	128	128	3	0,1	tanh	tanh	0,06
304	128	128	5	0,5	relu	tanh	0,06
305	32	64	3	0,1	relu	sigmoid	0,06
306	128	64	3	0,2	tanh	sigmoid	0,061
307	32	128	5	0,2	tanh	sigmoid	0,061
308	128	64	5	0,2	relu	tanh	0,061
309	32	64	3	0,5	relu	tanh	0,061
310	128	32	3	0,1	sigmoid	sigmoid	0,061
311	128	64	5	0,5	relu	sigmoid	0,061
312	32	32	3	0,2	relu	sigmoid	0,061
313	64	32	3	0,1	sigmoid	relu	0,061
314	64	64	5	0,1	sigmoid	sigmoid	0,062
315	32	32	5	0,1	sigmoid	relu	0,062
316	64	64	3	0,1	sigmoid	sigmoid	0,062
317	32	64	5	0,1	sigmoid	relu	0,062
318	32	128	5	0,1	sigmoid	sigmoid	0,062
319	64	32	3	0,2	sigmoid	sigmoid	0,062

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
320	64	32	5	0,2	sigmoid	sigmoid	0,062
321	128	128	3	0,5	relu	tanh	0,062
322	32	64	3	0,1	sigmoid	tanh	0,062
323	32	128	3	0,2	sigmoid	sigmoid	0,062
324	64	128	3	0,1	sigmoid	relu	0,062
325	64	128	3	0,1	sigmoid	sigmoid	0,062
326	128	32	5	0,2	sigmoid	sigmoid	0,062
327	32	128	3	0,1	sigmoid	relu	0,062
328	64	64	3	0,2	sigmoid	sigmoid	0,062
329	32	32	5	0,1	sigmoid	sigmoid	0,062
330	32	128	3	0,5	relu	sigmoid	0,062
331	32	64	3	0,2	sigmoid	relu	0,062
332	32	64	3	0,1	sigmoid	relu	0,063
333	64	32	3	0,1	sigmoid	sigmoid	0,063
334	64	64	5	0,1	sigmoid	relu	0,063
335	64	32	5	0,1	sigmoid	sigmoid	0,063
336	64	128	3	0,2	sigmoid	sigmoid	0,063
337	128	64	3	0,1	sigmoid	sigmoid	0,063
338	32	32	3	0,2	sigmoid	relu	0,063
339	32	64	3	0,1	sigmoid	sigmoid	0,063
340	32	64	5	0,1	sigmoid	tanh	0,063
341	64	64	3	0,5	tanh	sigmoid	0,063
342	128	128	3	0,1	sigmoid	sigmoid	0,063
343	128	64	3	0,2	sigmoid	sigmoid	0,063
344	64	64	5	0,1	sigmoid	tanh	0,063
345	128	64	5	0,1	sigmoid	relu	0,063
346	128	128	5	0,5	tanh	sigmoid	0,063
347	32	32	3	0,1	sigmoid	relu	0,063
348	128	64	3	0,5	sigmoid	sigmoid	0,064
349	32	32	5	0,1	sigmoid	tanh	0,064
350	32	128	3	0,1	sigmoid	sigmoid	0,064
351	32	64	3	0,5	sigmoid	sigmoid	0,064
352	64	128	3	0,5	relu	sigmoid	0,064
353	128	128	3	0,5	relu	sigmoid	0,064
354	128	32	3	0,5	tanh	sigmoid	0,064
355	64	32	3	0,5	sigmoid	sigmoid	0,064
356	32	128	5	0,2	sigmoid	sigmoid	0,064
357	32	128	5	0,2	sigmoid	relu	0,064
358	64	128	5	0,5	sigmoid	sigmoid	0,064
359	64	128	5	0,2	sigmoid	relu	0,064
360	64	64	3	0,5	sigmoid	sigmoid	0,064
361	64	128	3	0,1	relu	sigmoid	0,064
362	64	32	3	0,2	sigmoid	tanh	0,064
363	128	64	5	0,2	sigmoid	sigmoid	0,064

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
364	64	64	5	0,5	sigmoid	sigmoid	0,064
365	32	32	5	0,2	sigmoid	relu	0,064
366	128	128	5	0,1	sigmoid	sigmoid	0,064
367	64	64	3	0,1	sigmoid	tanh	0,064
368	64	32	3	0,2	sigmoid	relu	0,065
369	128	128	5	0,1	sigmoid	relu	0,065
370	32	64	5	0,2	sigmoid	sigmoid	0,065
371	32	128	5	0,1	sigmoid	tanh	0,065
372	64	128	3	0,2	sigmoid	tanh	0,065
373	64	32	5	0,2	sigmoid	relu	0,065
374	32	64	5	0,2	sigmoid	relu	0,065
375	64	128	5	0,2	sigmoid	tanh	0,065
376	32	32	3	0,5	sigmoid	tanh	0,065
377	64	128	3	0,2	sigmoid	relu	0,065
378	32	32	3	0,5	sigmoid	sigmoid	0,065
379	64	64	5	0,2	sigmoid	sigmoid	0,065
380	32	128	3	0,2	sigmoid	tanh	0,065
381	128	32	5	0,5	sigmoid	sigmoid	0,065
382	128	64	5	0,2	sigmoid	relu	0,065
383	32	128	5	0,5	sigmoid	sigmoid	0,065
384	32	32	3	0,2	sigmoid	tanh	0,065
385	32	32	5	0,5	sigmoid	sigmoid	0,065
386	128	128	5	0,5	sigmoid	sigmoid	0,065
387	128	32	3	0,5	sigmoid	sigmoid	0,065
388	128	64	5	0,1	sigmoid	sigmoid	0,065
389	32	64	3	0,2	sigmoid	tanh	0,065
390	32	32	3	0,1	sigmoid	sigmoid	0,066
391	32	64	5	0,5	sigmoid	sigmoid	0,066
392	128	128	5	0,2	sigmoid	relu	0,066
393	64	128	5	0,1	sigmoid	tanh	0,066
394	64	32	5	0,5	sigmoid	sigmoid	0,066
395	64	32	3	0,1	sigmoid	tanh	0,066
396	128	128	3	0,1	sigmoid	relu	0,066
397	32	64	3	0,2	sigmoid	sigmoid	0,066
398	64	128	5	0,1	sigmoid	relu	0,066
399	32	32	3	0,1	sigmoid	tanh	0,066
400	32	32	5	0,5	sigmoid	tanh	0,066
401	128	64	3	0,2	sigmoid	relu	0,066
402	32	128	5	0,2	sigmoid	tanh	0,066
403	128	128	5	0,2	sigmoid	sigmoid	0,066
404	64	64	3	0,1	sigmoid	relu	0,066
405	64	128	3	0,2	relu	sigmoid	0,066
406	128	32	5	0,1	sigmoid	sigmoid	0,066
407	64	64	3	0,5	sigmoid	tanh	0,066

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
408	64	128	5	0,5	tanh	sigmoid	0,066
409	64	64	5	0,2	sigmoid	relu	0,066
410	128	64	5	0,5	sigmoid	sigmoid	0,067
411	128	128	3	0,2	tanh	sigmoid	0,067
412	32	128	5	0,5	sigmoid	relu	0,067
413	32	32	5	0,2	sigmoid	sigmoid	0,067
414	32	64	3	0,5	sigmoid	relu	0,067
415	32	128	5	0,1	sigmoid	relu	0,067
416	32	32	5	0,2	sigmoid	tanh	0,067
417	32	128	3	0,5	sigmoid	relu	0,067
418	32	64	5	0,5	sigmoid	tanh	0,067
419	32	64	3	0,5	sigmoid	tanh	0,067
420	64	32	5	0,5	sigmoid	tanh	0,067
421	64	128	5	0,1	sigmoid	sigmoid	0,068
422	128	128	3	0,1	tanh	sigmoid	0,068
423	32	128	3	0,1	sigmoid	tanh	0,068
424	32	128	3	0,5	sigmoid	sigmoid	0,068
425	64	64	3	0,5	sigmoid	relu	0,068
426	128	32	3	0,1	sigmoid	tanh	0,068
427	64	128	5	0,5	sigmoid	relu	0,068
428	128	128	3	0,5	sigmoid	sigmoid	0,069
429	64	32	5	0,2	sigmoid	tanh	0,069
430	64	32	3	0,5	sigmoid	relu	0,069
431	128	128	3	0,1	relu	sigmoid	0,069
432	128	128	3	0,5	sigmoid	relu	0,069
433	128	32	3	0,2	sigmoid	sigmoid	0,069
434	64	128	5	0,2	sigmoid	sigmoid	0,069
435	64	32	5	0,1	sigmoid	tanh	0,069
436	32	64	5	0,5	sigmoid	relu	0,069
437	32	32	5	0,5	sigmoid	relu	0,07
438	128	64	3	0,5	sigmoid	relu	0,07
439	64	64	5	0,2	sigmoid	tanh	0,07
440	64	32	5	0,5	sigmoid	relu	0,07
441	32	32	3	0,5	sigmoid	relu	0,07
442	32	128	5	0,5	sigmoid	tanh	0,07
443	64	64	5	0,5	sigmoid	relu	0,07
444	64	64	3	0,2	sigmoid	tanh	0,07
445	64	128	3	0,5	sigmoid	relu	0,07
446	32	32	3	0,2	sigmoid	sigmoid	0,07
447	64	64	3	0,2	sigmoid	relu	0,07
448	128	128	5	0,5	sigmoid	relu	0,071
449	32	128	3	0,2	sigmoid	relu	0,071
450	32	64	5	0,1	sigmoid	sigmoid	0,071
451	64	128	3	0,5	sigmoid	sigmoid	0,071

No	Filtre Sayısı	Gizli Katman Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	Gizli Katman Aktivasyonu	RMSE
452	64	128	3	0,5	sigmoid	tanh	0,072
453	128	64	5	0,1	sigmoid	tanh	0,073
454	32	128	3	0,5	sigmoid	tanh	0,073
455	128	128	3	0,2	sigmoid	relu	0,074
456	64	128	5	0,5	sigmoid	tanh	0,074
457	64	64	5	0,5	sigmoid	tanh	0,074
458	128	64	3	0,1	sigmoid	relu	0,075
459	32	64	5	0,2	sigmoid	tanh	0,076
460	128	128	5	0,2	sigmoid	tanh	0,077
461	64	32	5	0,1	sigmoid	relu	0,077
462	64	128	3	0,1	sigmoid	tanh	0,077
463	64	32	3	0,5	sigmoid	tanh	0,078
464	128	128	3	0,1	sigmoid	tanh	0,078
465	128	128	3	0,2	sigmoid	sigmoid	0,08
466	128	128	5	0,1	sigmoid	tanh	0,088
467	128	64	5	0,2	sigmoid	tanh	0,093
468	128	32	3	0,2	sigmoid	relu	0,14
469	128	32	5	0,2	sigmoid	tanh	0,14
470	128	32	5	0,1	sigmoid	relu	0,14
471	128	32	3	0,2	sigmoid	tanh	0,14
472	128	32	5	0,5	sigmoid	relu	0,14
473	128	32	5	0,1	sigmoid	tanh	0,14
474	128	64	3	0,5	sigmoid	tanh	0,14
475	128	32	5	0,2	sigmoid	relu	0,14
476	128	32	3	0,5	sigmoid	relu	0,14
477	128	64	5	0,5	sigmoid	relu	0,14
478	128	64	3	0,2	sigmoid	tanh	0,14
479	128	32	3	0,1	sigmoid	relu	0,14
480	128	64	5	0,5	sigmoid	tanh	0,14
481	128	32	5	0,5	sigmoid	tanh	0,141
482	128	128	3	0,2	sigmoid	tanh	0,141
483	128	32	3	0,5	sigmoid	tanh	0,142
484	128	128	5	0,5	sigmoid	tanh	0,146
485	128	128	3	0,5	sigmoid	tanh	0,148
486	128	64	3	0,1	sigmoid	tanh	0,148

Tablo A.4 LSTM Hipermatre Sonuçları

No	İlk Katman LSTM Birim Sayısı	İkinci Katman LSTM Birim Sayısı	Dropout Oranı	RMSE
1	128	32	0,2	0,062
2	128	64	0,2	0,062
3	128	128	0,2	0,062

No	İlk Katman LSTM Birim Sayısı	İkinci Katman LSTM Birim Sayısı	Dropout Oranı	RMSE
4	128	128	0,1	0,063
5	128	32	0,1	0,063
6	64	32	0,2	0,064
7	64	128	0,1	0,064
8	64	128	0,2	0,064
9	64	32	0,1	0,064
10	32	128	0,2	0,064
11	128	128	0,5	0,064
12	128	64	0,1	0,064
13	32	32	0,1	0,064
14	32	64	0,1	0,064
15	32	64	0,5	0,065
16	64	128	0,5	0,065
17	128	64	0,5	0,065
18	32	64	0,2	0,065
19	32	128	0,5	0,065
20	32	32	0,5	0,065
21	64	64	0,1	0,066
22	32	128	0,1	0,066
23	64	64	0,2	0,066
24	128	32	0,5	0,067
25	32	32	0,2	0,067
26	64	64	0,5	0,068
27	64	32	0,5	0,068

Tablo A.5 CNN-LSTM Hipermatre Sonuçları

No	Filtre Sayısı	LSTM Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	RMSE
1	128	128	3	0,1	tanh	0,055
2	128	128	5	0,1	tanh	0,055
3	32	128	3	0,1	tanh	0,056
4	64	128	5	0,1	tanh	0,056
5	128	128	5	0,2	tanh	0,056
6	128	128	5	0,1	relu	0,057
7	128	64	5	0,1	relu	0,057
8	32	128	3	0,2	tanh	0,057
9	128	64	5	0,2	tanh	0,057
10	128	32	5	0,1	relu	0,057
11	64	128	3	0,1	tanh	0,057
12	32	128	5	0,2	tanh	0,057
13	64	32	5	0,1	relu	0,057
14	32	128	5	0,1	relu	0,057
15	64	32	5	0,1	tanh	0,057

No	Filtre Sayısı	LSTM Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	RMSE
16	128	64	3	0,2	tanh	0,057
17	128	64	5	0,2	relu	0,058
18	64	128	5	0,2	relu	0,058
19	128	128	3	0,2	tanh	0,058
20	64	128	3	0,2	tanh	0,058
21	128	128	3	0,1	relu	0,058
22	64	64	5	0,1	relu	0,058
23	128	64	3	0,1	tanh	0,058
24	32	128	5	0,2	relu	0,058
25	32	64	5	0,2	tanh	0,058
26	64	64	5	0,1	tanh	0,058
27	32	64	5	0,1	tanh	0,058
28	128	32	5	0,2	relu	0,058
29	128	128	5	0,2	relu	0,058
30	128	128	5	0,5	tanh	0,058
31	32	32	5	0,2	relu	0,058
32	32	128	5	0,1	tanh	0,058
33	64	32	5	0,2	relu	0,058
34	128	32	5	0,1	tanh	0,058
35	32	32	5	0,1	tanh	0,059
36	64	32	5	0,2	tanh	0,059
37	128	64	5	0,1	tanh	0,059
38	128	64	5	0,5	relu	0,059
39	128	128	5	0,5	relu	0,059
40	64	64	3	0,1	tanh	0,059
41	128	32	5	0,5	relu	0,059
42	32	32	5	0,1	relu	0,059
43	128	32	3	0,1	tanh	0,059
44	64	64	5	0,5	relu	0,059
45	32	32	5	0,2	tanh	0,059
46	128	64	5	0,5	tanh	0,059
47	128	128	3	0,2	relu	0,059
48	32	64	3	0,1	tanh	0,059
49	32	128	3	0,1	relu	0,06
50	64	128	3	0,1	relu	0,06
51	128	128	3	0,5	tanh	0,06
52	32	128	5	0,5	relu	0,06
53	64	128	5	0,5	relu	0,06
54	64	32	5	0,5	relu	0,06
55	64	128	3	0,2	relu	0,06
56	64	64	3	0,2	tanh	0,06
57	64	64	5	0,2	tanh	0,06
58	128	32	3	0,2	tanh	0,06
59	32	64	5	0,2	relu	0,06
60	32	64	3	0,1	relu	0,06

No	Filtre Sayısı	LSTM Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	RMSE
61	64	128	5	0,5	tanh	0,06
62	32	64	3	0,2	relu	0,061
63	64	32	3	0,1	relu	0,061
64	64	128	5	0,2	tanh	0,061
65	128	32	3	0,1	relu	0,061
66	128	32	5	0,5	tanh	0,061
67	128	64	3	0,2	relu	0,061
68	128	64	3	0,1	relu	0,061
69	64	64	5	0,2	relu	0,061
70	32	64	5	0,1	relu	0,061
71	64	32	5	0,5	tanh	0,061
72	128	128	3	0,5	relu	0,061
73	128	64	3	0,5	tanh	0,062
74	32	32	3	0,1	tanh	0,062
75	32	128	5	0,5	tanh	0,062
76	64	128	3	0,5	relu	0,062
77	64	128	3	0,5	tanh	0,062
78	128	32	3	0,5	tanh	0,062
79	64	128	5	0,1	relu	0,062
80	64	32	3	0,2	relu	0,062
81	64	32	3	0,2	tanh	0,062
82	128	32	5	0,2	tanh	0,062
83	32	64	5	0,5	relu	0,062
84	64	64	3	0,1	relu	0,062
85	32	32	5	0,5	relu	0,062
86	64	64	5	0,5	tanh	0,063
87	32	32	3	0,2	tanh	0,063
88	128	32	3	0,2	relu	0,063
89	64	32	3	0,5	relu	0,063
90	128	64	3	0,5	relu	0,063
91	128	64	5	0,1	sigmoid	0,063
92	64	64	3	0,2	relu	0,063
93	64	32	3	0,1	tanh	0,063
94	32	64	5	0,5	tanh	0,063
95	64	128	3	0,1	sigmoid	0,063
96	32	128	3	0,5	tanh	0,063
97	32	64	3	0,2	tanh	0,064
98	32	32	5	0,1	sigmoid	0,064
99	32	128	5	0,1	sigmoid	0,064
100	128	128	3	0,1	sigmoid	0,064
101	128	32	3	0,5	relu	0,064
102	32	64	3	0,5	tanh	0,064
103	32	64	3	0,5	relu	0,064
104	32	128	3	0,2	relu	0,064
105	128	128	5	0,1	sigmoid	0,064

No	Filtre Sayısı	LSTM Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	RMSE
106	64	64	3	0,1	sigmoid	0,064
107	32	128	3	0,2	sigmoid	0,064
108	64	128	3	0,2	sigmoid	0,064
109	32	128	3	0,5	relu	0,064
110	32	32	3	0,5	relu	0,064
111	32	64	3	0,2	sigmoid	0,064
112	128	64	3	0,1	sigmoid	0,064
113	128	32	5	0,1	sigmoid	0,064
114	64	64	3	0,5	tanh	0,065
115	64	32	5	0,1	sigmoid	0,065
116	64	64	5	0,2	sigmoid	0,065
117	32	128	5	0,2	sigmoid	0,065
118	128	128	3	0,5	sigmoid	0,065
119	32	32	3	0,1	relu	0,065
120	64	32	3	0,2	sigmoid	0,065
121	64	128	5	0,1	sigmoid	0,065
122	64	32	3	0,5	tanh	0,065
123	128	32	5	0,2	sigmoid	0,065
124	32	32	3	0,2	relu	0,065
125	128	128	5	0,2	sigmoid	0,065
126	32	32	5	0,2	sigmoid	0,065
127	32	32	3	0,1	sigmoid	0,065
128	32	64	5	0,1	sigmoid	0,065
129	64	32	5	0,2	sigmoid	0,065
130	64	128	5	0,5	sigmoid	0,066
131	32	128	3	0,1	sigmoid	0,066
132	64	64	5	0,1	sigmoid	0,066
133	128	32	3	0,1	sigmoid	0,066
134	32	32	3	0,5	tanh	0,066
135	32	64	5	0,2	sigmoid	0,066
136	64	128	3	0,5	sigmoid	0,066
137	128	64	5	0,2	sigmoid	0,066
138	128	128	3	0,2	sigmoid	0,066
139	128	64	3	0,2	sigmoid	0,067
140	64	32	3	0,1	sigmoid	0,067
141	32	32	3	0,2	sigmoid	0,067
142	128	32	3	0,2	sigmoid	0,068
143	128	32	5	0,5	sigmoid	0,068
144	64	64	3	0,5	sigmoid	0,068
145	128	64	5	0,5	sigmoid	0,068
146	32	128	5	0,5	sigmoid	0,068
147	32	32	5	0,5	tanh	0,068
148	64	32	5	0,5	sigmoid	0,068
149	32	128	3	0,5	sigmoid	0,068
150	128	128	5	0,5	sigmoid	0,068

No	Filtre Sayısı	LSTM Birim Sayısı	Çekirdek Boyutu	Dropout Oranı	Konvolüsyon Aktivasyonu	RMSE
151	64	128	5	0,2	sigmoid	0,069
152	32	32	5	0,5	sigmoid	0,069
153	128	32	3	0,5	sigmoid	0,069
154	64	64	3	0,5	relu	0,069
155	64	64	5	0,5	sigmoid	0,069
156	64	64	3	0,2	sigmoid	0,069
157	32	64	3	0,1	sigmoid	0,071
158	128	64	3	0,5	sigmoid	0,071
159	32	64	3	0,5	sigmoid	0,072
160	32	32	3	0,5	sigmoid	0,072
161	64	32	3	0,5	sigmoid	0,073
162	32	64	5	0,5	sigmoid	0,078

Tablo A.6 KAN Hipermatre Sonuçları

No	Katman Sayısı	Optimizer	Lamb	Lamb Entropy	RMSE
1	2	LBFGS	0,0001	0,5	0,052
2	5	LBFGS	0,0001	0,5	0,052
3	3	LBFGS	0,0001	0,5	0,052
4	2	LBFGS	0,0001	1	0,052
5	3	LBFGS	0,0001	1	0,052
6	5	LBFGS	0,0001	1	0,052
7	2	LBFGS	0,0001	2	0,052
8	3	LBFGS	0,0001	2	0,052
9	4	LBFGS	0,0001	0,5	0,052
10	4	LBFGS	0,0001	1	0,053
11	5	LBFGS	0,0001	2	0,053
12	4	LBFGS	0,0001	2	0,054
13	3	LBFGS	0,001	0,5	0,055
14	2	LBFGS	0,001	0,5	0,056
15	3	LBFGS	0,001	1	0,056
16	5	LBFGS	0,001	0,5	0,057
17	3	LBFGS	0,001	2	0,057
18	2	LBFGS	0,001	1	0,057
19	4	LBFGS	0,001	0,5	0,057
20	2	LBFGS	0,001	2	0,058
21	5	LBFGS	0,001	1	0,058
22	4	LBFGS	0,001	1	0,059
23	4	LBFGS	0,001	2	0,06
24	5	LBFGS	0,001	2	0,06
25	4	LBFGS	0,01	0,5	0,115
26	5	LBFGS	0,01	0,5	0,128
27	2	LBFGS	0,01	0,5	0,14
28	4	LBFGS	0,01	2	0,14

No	Katman Sayısı	Optimizer	Lamb	Lamb Entropy	RMSE
29	3	LBFGS	0,01	0,5	0,14
30	3	LBFGS	0,01	2	0,14
31	4	LBFGS	0,01	1	0,14
32	3	LBFGS	0,01	1	0,14
33	5	LBFGS	0,01	1	0,14
34	5	LBFGS	0,01	2	0,14
35	2	LBFGS	0,01	1	0,14
36	2	LBFGS	0,01	2	0,14
37	4	Adam	0,01	2	0,306
38	2	Adam	0,0001	0,5	0,306
39	2	Adam	0,001	0,5	0,306
40	2	Adam	0,0001	2	0,306
41	2	Adam	0,0001	1	0,306
42	3	Adam	0,0001	1	0,306
43	4	Adam	0,0001	2	0,306
44	2	Adam	0,01	0,5	0,306
45	3	Adam	0,0001	0,5	0,306
46	2	Adam	0,01	1	0,306
47	2	Adam	0,001	2	0,306
48	2	Adam	0,01	2	0,306
49	4	Adam	0,0001	1	0,306
50	2	Adam	0,001	1	0,306
51	4	Adam	0,0001	0,5	0,306
52	3	Adam	0,0001	2	0,306
53	4	Adam	0,01	1	0,306
54	4	Adam	0,01	0,5	0,306
55	5	Adam	0,0001	0,5	0,306
56	5	Adam	0,0001	1	0,306
57	5	Adam	0,0001	2	0,306
58	4	Adam	0,001	1	0,306
59	3	Adam	0,001	2	0,306
60	4	Adam	0,001	2	0,306
61	4	Adam	0,001	0,5	0,306
62	3	Adam	0,01	0,5	0,306
63	3	Adam	0,001	1	0,307
64	3	Adam	0,01	2	0,326
65	3	Adam	0,001	0,5	0,67
66	5	Adam	0,001	2	0,735
67	5	Adam	0,01	1	5,645
68	3	Adam	0,01	1	6,001
69	5	Adam	0,01	0,5	7,252
70	5	Adam	0,001	0,5	8,294
71	5	Adam	0,001	1	8,418
72	5	Adam	0,01	2	30,31

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirisi

1. R. F. Koçyiğit, A. Elbir, B. Diri, “*Navigating Turkey’s Real Estate: Advanced Property Valuation and Recommendation Systems with Machine and Deep Learning*”, 20. Uluslararası İstanbul Fen, Mühendislik, Mimarlık ve Matematik Bilimlerinde Bilimsel Araştırmalar Kongresi, 21–23 Şubat 2025, İstanbul, Türkiye.
DOI: 10.30546/19023.978-9952-8553-0-2.2025.2034.