

Araştırma Makalesi

Yapay Sinir Ağları ile Aktif Kullanıcı Sayısı Tahmini Üzerine Bir Uygulama

Nurkut Nuray Urgan¹, *^{ORCID}, Mücahit Tamgöz²^{ORCID}

¹Department of Mathematics, The Faculty of Arts and Sciences, Tekirdağ Namık Kemal University, Süleymanpaşa,
Tekirdağ, Turkey
²Air Force Academy, National Defence University, Yeşilyurt, İstanbul, Turkey

Geliş: 23.10.2020

Kabul: 29.12.2020

Özet: Yapay sinir ağları, doğrusal olmayan yapılara sahiptir. Dolayısıyla bu tip problemlerin sıkça yer aldığı mühendislik, savunma, sanayi, veri analizi gibi birçok alanda kullanılmaktadır. Yapay sinir ağları lineer olmayan yapılar olduğundan bilgisayarların çözümünde tıkanıdığı gerçek yaşamdan alınan örneklerin çözümünde daha doğru çözümler sunmaktadır. Son zamanlarda yaş gözetmeksizin uluslararası ağ üzerinden oyun sağlayıcılar vasıtasıyla oyun oynayan kullanıcılar sayısında belirgin artış gözlenmektedir. Bu artış ile oyun sağlayıcılarında da artış gözlenmektedir. Ancak bu sağlayıcıların finansal açıdan ayakta kalabilmesi için sundukları oyunları kullanan aktif oyuncuların sayısı önem arz etmektedir. Valve Corporation tarafından geliştirilen Steam, bir dijital dağıtım, dijital hak yönetimi, çok oyunculu oynayıp ve iletişim sunan platformdur. Oyunların geniş çapta dağıtımını ve onlarla ilgili çoklu ortamların tamamen internet ağı üzerinden yayılımı için kullanılmaktadır. Bu çalışmada, Steam'in genel aktif kullanıcı sayısı, sunduğu oyunlardan seçilen 5 oyunun bir gündeki belirlenen saatlerdeki aktif kullanıcı sayısı üzerinden yapay sinir ağları ile tahmin edilmektedir. Tahmin uygulamasında, tasarladığımız yapay sinir ağ yapısının eğitiminde MATLAB uygulamasının yapay sinir ağları için geliştirilmiş olan NNTool kullanılmıştır.

Anahtar kelimeler: Aktif Kullanıcı Tahmini, Steam İstatistikleri, Yapay Sinir Ağları.

An Application on Estimating of The Active Users Number with Artificial Neural Networks

Abstract: Artificial neural networks have nonlinear structures, therefore they are used in many areas such as engineering, defense industry, data analysis, where such problems are frequently involved. Since artificial neural networks are non-linear structures, they offer more accurate solutions in the solution of real-life examples that are clogged in solving computers. Recently, there has been a significant increase in the number of users playing games on the international network through game providers, regardless of age. With this increase, an increase is observed in game providers. However, for these providers to survive financially, the number of active players using the games they offer is important. Developed by Valve Corporation, Steam is a digital distribution, digital rights management, multiplayer gameplay and communication platform. It is used for the wide distribution of games and the distribution of the multimedia associated with them over the internet. In this study, the general number of active users of Steam is estimated by artificial neural networks over the number of active users in the specified hours of the 5 games selected from the games it offers. In the prediction application, NNTool developed for the artificial neural networks of the Matlab application was used in the training of the artificial neural network we designed.

Keywords: Active User Prediction, Steam Statistics, Artificial Neural Networks.

* Sorumlu Yazar.

E-posta adresi: nurgan@nku.edu.tr (N.N. Urgan:)

1. Giriş

Alan Turing' in[1] adını verdiği Turing makinesiyle başlayan, insanların kendi işlevlerini taklit etmeyi sağlayan makineler yapma uğraşı; yapay zekâ kavramını ve ardından insanın öğrenme, karar verme gibi beyin fonksiyonlarını taklit eden yapay sinir ağlarının geliştirilmesi ile devam etmiştir. Yapay sinir ağları doğrusal olmayan yapıları sayesinde yine doğrusal olmayan birçok problemin çözümünde başarı ile kullanılmaktadır. Gurney [3] ve Haykin [4] kitaplarında yapay sinir ağlarında oyunlarla ilgili algoritmalara yer vermiştir. Champandard [5] ve Sweetser [6] yapay sinir ağlarıyla dijital oyunlarla ilgili başlangıç düzeyde sayılabilecek çalışmalar yapmıştır. McGlinchey, [7] çalışmasında yapay zekâ öğrenme algoritmaları ile oyuncuları gözlemleyip modellemesini yapmıştır. Bu sayede oyunculara göre oyun grupları ve hatta oyuncuların karakterlerine uygun karakterler (avatarlar) yaratmayı hedeflemiştir. Dijital oyunlardaki gelişim bu çalışmalarla birlikte gerçek zamanlı oynanabilen, aktif oyuncuyu yansıtan karakterlere sahip oyunlar olarak günümüze kadar gelmiş olup gelişerek devam etmektedir. Gelişen bu oyunların programlayıcılarını ve bunları ağ üzerinden sunan oyun sağlayıcılarını, finansal açıdan tatmin etmesi aktif kullanıcı sayısına bağlıdır. Chang [8] yapay sinir ağları kullanarak dijital oyunların stok fiyatlarını bir hibrit model ile tahminlemiştir. Ancak aktif kullanıcı sayısı tahminlemesi yaparak hangi oyunların oyun sağlayıcıyı finansal açıdan tatmin edip etmediği ile ilgili çalışmaya rastlanmamıştır. Tarafımızca yapılan literatür taramasında aktif kullanıcı sayısı tahmini için yapılan araştırma bulunamamış olup, Khademi ve ark. [13,14] YSA da çoklu doğrusal yöntemlerle tahminler yapmışlardır. Shams [15] yapay sinir ağları ve çoklu regresyon ile tahminleme yapmış ve uyguladığı verilerde yapay sinir ağlarının daha iyi sonuç verdiğini göstermiştir. Öztürk [16], Chandar [17], Yokoyama [18] da yapay sinir ağları kullanarak tahminleme yapmışlardır.

Bu çalışmada yapay sinir ağlarıyla aktif kullanıcı sayısı tahminlemesi MATLAB programının NNTool paketi kullanılarak yapılmıştır. Bu bağlamda önce yapay sinir ağları ile ilgili kısa bilgi verilmiştir. Uygulamada ise Steam oyun sağlayıcısının sunduğu oyunlardan Counter-Strike: Offensive, Dota 2, Destiny 2, Grand Theft Auto V ve Playerunknown's Battle Grounds (PUBG) oyunları seçilerek bu oyunların 14 Haziran 2020 tarihinde saat bazlı alınan verilerinin analizi yapıp, genel olarak Steam oyun sağlayıcısına bağlanabilecek aktif kullanıcı sayısı tahmin edilmiştir.

2. Yapay Sinir Ağları

Bir çok basit işlemci elemandan oluşan yapılar yapay sinir ağlarıdır. Bu elemanlar farklı formda ifade edilebilen nümerik verileri taşıyan bağlantılar veya ağırlıklar ile birbirlerine bağlıdır. YSA karmaşık yapıya ve üstün özelliklere sahip olan beyin davranışlarının matematiksel modellenmesi için bir sistemdir. Ayrıca YSA beyin hücrelerinin işleyişi gibi yapay sinir hücrelerinin birbirlerine bağlanmasından ve katmanlar halinde düzenlenmesinden oluşur. Beynin bilgi işleme yapısına benzer biçimde öğrenme sürecinden sonra bilgiyi saklama ve bilgi ile genelleme

yapabilme yeteneğine sahip bir işlemcidir. YSA, algoritma veya matematiksel model geliştirmez, istatistik yöntemlere başvurmaz, bunun yerine veri içindeki ilişkileri ve desenleri tanıyarak ve tekrar ederek öğrenir, bu nedenle basit ve esnek bir yapısı vardır. Yapay sinir ağlarının yapılarına göre farklı öğrenme yaklaşımları kullanılır ve bu yaklaşımlara göre ağırlıklar değiştirilir; bu değişim öğrenmeyi ifade eder. Değişim olmazsa öğrenme işlemi durmuş demektir [9]. Haykin [4] yapay sinir ağlarını bilgiyi depolamak için doğal eğilimi olan, basit birimlerden oluşan, paralel dağılmış ve sinaptik ağırlıklar olarak bilinen nöronlar arasındaki bağlantı kuvvetlerini bilgi depolamak için kullanan bir işlemci olarak tanımlar. Zurada [2] ise bu ağları deneysel bilgiyi alan ve depolayan fiziksel hücre sistemleri olarak tanımlar.

Biyolojik sinir sistemi, bilgiyi alan, yorumlayan ve uygun bir karar üreten bir merkez ve bu merkezin kontrolünde bulunan alıcı ve tepki sinirlerden oluşur. Alıcı sinirler (reseptör), iç veya dış ortamlardan algıladıkları uyarıları, elektriksel sinyallere dönüştürerek beyine iletirler. Tepki sinirleri (efektör) ise, beyinin ürettiği elektriksel sinyalleri çıktı olarak uygun tepkilere dönüştürür. Sinir hücreleri nöron olarak bilinir. Nöron, sinir sisteminin temel birimidir. Nöronlar, gövde (cell body), gövdeye giren sinyal alıcılar (dentrit) ve gövdeden çıkan sinyal ileticiler (akson) olmak üzere başlıca üç kısımdan oluşur.[10]

2.1. Yapay Nöron

Yapay sinir ağları (YSA)' lar birbirlerine bağlı doğrusal ve/veya doğrusal olmayan birçok elemandan oluşur. Bir yapay nöron temel olarak girdiler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıktı olmak üzere beş bölümden oluşur. p adet girdili, n adet çıktılı bir yapay nöronun gösterimi Şekil 2.1' de verilmiştir. Şekil 2.1 de, x, girdileri, y, çıktıları, F, fonksiyonu, p, nöron girdi sayısını, n, çıktı sayısını, w ise ağırlıkları ifade eder. Dentrit gösteriminde presinaptik aktiviteler, girdilerin p-elemanlı sütun vektörü

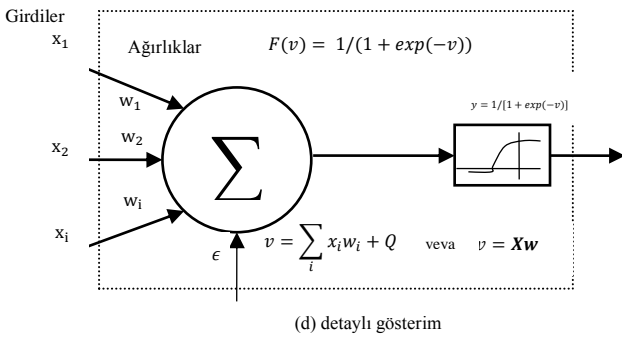


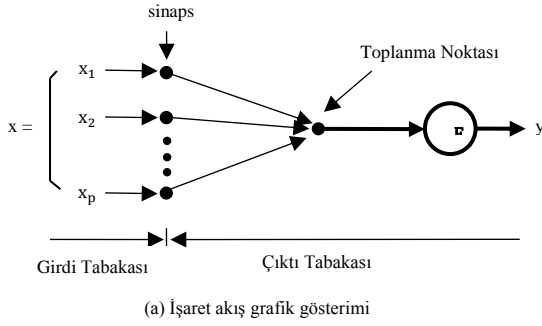
$$X = [X_1 X_2 \dots X_p]^T \quad (1)$$

olarak gösterilir, yani girdi desenlerinin uzayı p-boyutludur. Sinapslar ayarlanabilen parametreler olan ağırlıklar ile karakterize edilir ve ağırlıklar p-boyutlu satır vektörü

$$w = [w_1 w_2 \dots w_p] \quad (2)$$

olarak gösterilir.

Şekil 2.1 (a) deki işaret-akış gösteriminde, p tane ağırlığı olan bir nöron, girdi noktalarının bir katmanı olarak düzenlenir, ağırlıklar girdi ile toplama noktaları arasındaki bağlantılara karşılık gelir. Şekil 2.1(b) deki sinapslardan ve dentritten geçen girdiler toplam aktiviteyi tanımlayan aktivasyon potansiyeli olarak toplanır. Şekil 2.1(c) deki aktivasyon potansiyeli, girdilerin ve ağırlıkların lineer toplamı olarak şekillenir.



Şekil 2.1. p-girdili bir nöronun temel grafik gösterimleri: (a) işaret-akış grafik gösterimi, (b) dentrit gösterimi, (c) blok diyagram gösterimi, (d) yapay sinir ağı modeli.

Aktivasyon potansiyeli

$$v = \sum_{i=1}^p w_i x_i = [w_1 \ w_2 \ \dots \ w_p] \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix} = WX^T \quad (3)$$

ile ifade edilir. Daha sonra, aktivasyon potansiyeli, çıktıları üreten bir F aktivasyon fonksiyonundan geçirilir ve

$$y = F(v) \quad (4)$$

çıkıtı değeri elde edilir. F aktivasyon fonksiyonu, aktivasyon potansiyelini çıktının standart değeri ile normalize eden bir

fonksiyondur.

YSA' da girdilere önce toplama fonksiyonları uygulanır. Her bir elemanın çıktısı değeri olan y nin hesaplanması için aktivasyon potansiyeli,

$$v = \sum_{i=1}^n x_i w_{ij} - \theta_j \quad (5)$$

ile bulunur. Burada, x_i , i -inci girdi, w_{ij} , j -inci elemandan i -inci elemana bağlantı ağırlığını ve θ_j eşik (threshold) değerini göstermektedir. (5) denklemini sigmoid bir aktivasyon fonksiyonuna uygulanırsa, çıktı,

$$y = F(v) = \frac{1}{1 + e^{-v}} \quad (6)$$

olarak bulunur.


2.2. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları öğrenme eğrileridir. Bu fonksiyonlarla nöronun çıktılarının değer aralığı istenilen değerler arasında sınırlandırılır. Bu Aktivasyon fonksiyonları kullanım amaçlarına göre tek veya çift fonksiyonlar olabilir ve türevleri alınabileceğinden sürekli bir fonksiyon olmak zorundadır. Aktivasyon fonksiyonları olarak; doğrusal fonksiyon, sigmoid fonksiyon, basamak fonksiyonu, hiperbolik tanjant fonksiyonu, kuadratik ve ters kuadratik fonksiyon, Couchy fonksiyonu, Gauss fonksiyonu gibi fonksiyonlar kullanılır.

Tek kutuplu aktivasyon fonksiyonu olarak da bilinen Sigmoid fonksiyonu, YSA uygulamalarında en çok kullanılan aktivasyon fonksiyonudur. Bu fonksiyonun grafiği Şekil 2.2 deki gibidir ve en aktif bölgesi 0.2 ile 0.8 arasındadır. Bu eğri,

$$y = \frac{1}{1 + e^{-v}} = \frac{1}{2} \left(\tanh\left(\frac{v}{2}\right) + 1 \right) \quad (7)$$

ile formülize edilir.



Şekil 2.2. Sigmoid Fonksiyonu


3. Yapay Sinir Ağlarının Sınıflandırılması

Yapay Sinir Ağları, yapılarına ve öğrenme algoritmalarına göre ileri beslemeli ve geri beslemeli olarak sınıflandırılır.


İleri beslemeli ağlarda işlemci elemanlar katmanlara ayrılmıştır. İşlemci elemanlar, Şekil 3.1 de görüldüğü gibi, bir katmandan diğerine bağlantı kurarken aynı katman içinde bağlantı kurmazlar. Bu ağlara örnek olarak çok katmanlı perseptronlar (MLP) ve Kohonen-ağı (LVQ -learning Vector Quantization) [11] verilebilir.

Geri beslemeli ağ ise, Şekil 3.2 deki gibi çıktı ve ara katman

çıktılarının, girdi birimlerini veya önceki ara katmanları geri beslediği ağ yapısıdır. Bu ağda girdiler hem ileri hem geri yöne aktarılmış olur. Geri beslemeli ağların dinamik hafızaları vardır ve bir andaki çıktı hem o andaki hem de önceki girdileri yansıtır. Bundan dolayı tahmin uygulamaları için uygun ağlardır. Bu ağlara örnek olarak Hopfield, Elman ve Jordan ağları verilebilir.




Şekil.3.1. İleri beslemeli ağ




Şekil 3.2. Geri beslemeli ağ

4. YSA ile Aktif Kullanıcı Sayısı Tahmini


Steam oyun sağlayıcısının internet sayfasından [12] alınan veriler kullanılarak, Yapay Sinir Ağları ile aktif kullanıcı sayısı tahmini üzerine bir uygulama yapılmıştır. Uygulamada, Steam'in istenilen saat değerindeki aktif kullanıcı sayısı tahmini üzerine etkisi olduğu düşünülen değişkenler kullanılmıştır ve eğitim sonrası bulunan sonuçlarla iki gün sonrası yani 16 Haziran 2020 tarihine ait gerçek kullanıcı sayıları ile karşılaştırma yapılmıştır. Bu değişkenler; 14 Haziran 2020 tarihinde, 01:00,02:00,...,23:00,00:00 şeklinde tam saatlerde alınan, Counter-Strike: Global Offensive aktif kullanıcı sayısı, Dota 2 aktif kullanıcı sayısı, Destiny 2 aktif kullanıcı sayısı, Grand Theft Auto V aktif kullanıcı sayısı, Playerunknown's Battle Grounds (PUBG) aktif kullanıcı sayısıdır. 14 Haziran 2020 tarihindeki verilen saatlerde oyunların kullanıcı grafikleri sırasıyla Şekil 4.1, Şekil 4.2, Şekil 4.3, Şekil 4.4 ve Şekil 4.5 de ve Şekil 4.6 da tüm oyunların grafikleri verilmiştir. Grafiklerde görüldüğü gibi saat 10:00-20:00 arasında kullanıcı sayısında üstel bir artış olup, 20:00-21:00 saatleri arasında da tepe değere ulaşmıştır.




Şekil 4.1. 14 Haziran 2020 tarihinde Counter-Strike: Global Offensive aktif kullanıcı sayısı




Şekil 4.2. 14 Haziran 2020 tarihinde Dota 2 aktif kullanıcı sayısı



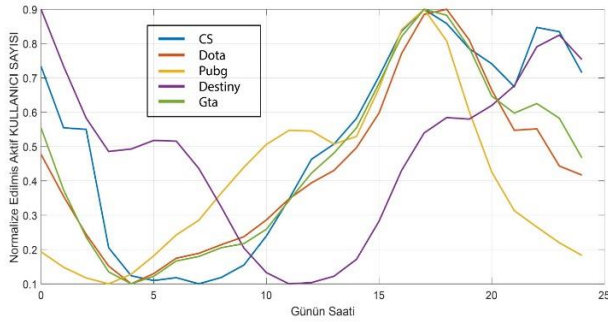
Şekil 4.3. 14 Haziran 2020 tarihinde PUBG aktif kullanıcı sayısı



Şekil 4.4. 14 Haziran 2020 tarihinde Destiny 2 aktif kullanıcı sayısı



Şekil 4.5. 14 Haziran 2020 tarihindeki Grand Theft Auto V aktif kullanıcı sayısı




Şekil 4.6. Steam [12] den alınan GS-GO, DO2, DT2, GTA-V, PUBG oyunlarının aktif kullanıcı sayıları

Tahmin çalışmalarında, en çok kullanılan model olması ve hem doğrusal hem de doğrusal olmayan modellerdeki başarısı nedeniyle, verilere ileri beslemeli geri yayılım ağı uygulanmıştır. Model, MATLAB yazılımına ait NNTool paketi kullanılarak oluşturulmuştur. Veriler büyük olduğundan,


$$N.D. = \left(0.8 \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) \right) + 0.1 \quad (8)$$

Normalizasyon formülü kullanılarak 0.1 ile 0.9 arasına normalize edilmiştir.


Modelde bağımlı değişken olarak, Steam aktif kullanıcı sayısı (A.K.), bağımsız değişkenler ise Counter Strike: Global Offensive aktif kullanıcı sayısı (GS-GO), Dota 2 aktif kullanıcı sayısı (DO2), Destiny 2 aktif kullanıcı sayısı (DT2), Grand Theft Auto V (GTA-V) ve Playerunknown's Battle Grounds aktif kullanıcı sayısı (PUBG) olarak alınmıştır. Bu beş girdi ve bir çıktı değişkenine sahip model, tek gizli katmanlı ileri beslemeli bir geri yayılım ağıdır. Şekil 4.7'da yapılan yapay sinir ağı modellenmesi gösterilmiştir. Girdi katmanında ağa sunulan beş bağımsız değişkene ait beş adet girdi işlemci elemanı, çıktı katmanında ise bağımsız değişkene ait bir adet çıktı işlemci elemanı bulunmaktadır. Öğrenme fonksiyonu olarak GDX (Momentum ile gradiyent azalan ve adaptif öğrenme oranlı geri yayılım) fonksiyonu kullanılmıştır. Çeşitli nöron sayıları ile yapılan denemeler sonucunda ara katman nöron sayısı on olarak belirlenmiştir. Programın performans ölçüt birimi olarak hataların karalarının ortalamasını, yani tahmini değerler ile gerçek değer arasındaki ortalama kare farkını ölçen MSE (Mean Squared error) fonksiyonu kullanılmıştır.



Şekil 4.7. Yapay sinir ağı modellenmesi




Şekil 4.8. Ağın eğitim verilerine ilişkin tablo




Şekil 4.9. Regresyon eğrisi

Model 1.000 döngü (İterasyon, Epoch) kullanılarak eğitilmiş ve bu eğitime ilişkin sonuçlar Şekil 4.8 de verilmiştir. Bu sonuçlara göre performans değeri problem için YSA' nın uygun olduğunu göstermektedir. Eğitimi tamamlanan ağın regresyon değerleri Şekil 4.9 de gösterilmiştir. Şekil 4.10 da görüldüğü üzere belirlilik katsayısı 0.99 un üzerinde çıkmıştır. Yani A.K bağımlı değişkeni, bağımsız değişkenler tarafından %99 un üzerinde açıklanmaktadır. Uygulanan model ile eğitimi tamamlanan ağın bağımsız değişkenlere ait test verisi elde edilerek iki gün sonrasının gerçek verileri ile karşılaştırılmıştır. Üretilen çıktı değerleri ile 16 Haziran 2020 günü saat 16:00-23:00 arasındaki gerçek veriler arasındaki hatanın çok düşük olduğu görülmüştür. Ağın eğitiminde kullanılan veri seti 14 Haziran 2020 tarihine ait 24 farklı saatte alınan verileri kapsamaktadır ancak test verileri 16 Haziran 2020 saat 16:00-00:00 saatleri arasında sekiz farklı


saatte alınan verilerdir. Bunun nedeni inşa ettiğimiz ağın eğitim sonucunda gerçekten öğrenip öğrenmediğini test etmektir. Eğer ağı öğrenmek yerine ezberlemiş ise gün içinde herhangi bir saat aralığında alınan verilerde yaklaşık sonuçlar vermeyecektir. Şekil 4.11 de seçilen GS-GO, DO2, DT2, GTA-V, PUBG oyunlarının kullanıcı sayısı kullanılarak yapay sinir ağı uygulaması sonucu tahmini kullanıcı sayılarının grafiği elde edilmiştir. Şekil 4.12 de ise test çıktılarının, yani 16 Haziran 2020 deki kullanıcı sayılarının grafiği verilmiştir. İki grafik karşılaştırıldığında ağı tahmin yeteneğinin eğitim çıktıları üzerinde düşük hatalı sonuçlar ürettiği görülmektedir.



Şekil 4.10. Ağın regresyon grafikleri



Şekil 4.11. YSA eğitiminde kullanılan, Steam [12] den alınan normalize edilmiş çıktılar (mavi kareler)



Şekil 4.12. Test çıktıları

Şekil 4.11 ve Şekil 4.12 de, beşinci ve sekizinci değer haricinde çok fark görülmemektedir. Diğer normalize edilmiş

kullanıcı sayıları birbirlerine çok yakın değerler olduğu için buradaki hata ihmal edilebilir. Bu çalışmada, YSA kullanılarak;

*saat 16:00 için eğitim sonrası normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.46 ve 16 Haziran 2020 deki normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.50 olduğu görülmüştür yani gerçek çıktılarla eğitim çıktıları arasındaki hata payı ihmal edilebilir düzeyde çok düşüktür.

*17:00 için eğitim sonrası normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.87 ve 16 Haziran 2020 deki normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.84 olduğu görülmüştür. Yani test çıktılarıyla eğitim çıktıları arasındaki hata payı ihmal edilebilir düzeyde çok düşüktür.

*18:00 için eğitim sonrası normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.90 ve 16 Haziran 2020 deki normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.83 olduğu görülmüştür yani test çıktılarıyla eğitim çıktıları arasındaki hata payı ihmal edilebilir düzeyde çok düşüktür.

*19:00 için eğitim sonrası normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.65 ve 16 Haziran 2020 deki normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.42 olduğu görülmüştür. Yani test çıktılarıyla eğitim çıktıları arasındaki hata payı ihmal edilebilir düzeyde çok düşüktür.

*20:00 için eğitim sonrası normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.42 ve 16 Haziran 2020 deki normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.15 olduğu görülmüştür. Gerçek verilerle eğitim verileri arasında anlamlı hata olduğu görülmektedir.

*21:00 için eğitim sonrası normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.39 ve 16 Haziran 2020 deki normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.28 olduğu görülmüştür. Yani test çıktılarıyla eğitim çıktıları arasındaki hata payı ihmal edilebilir düzeyde çok düşüktür.

*22:00 için eğitim sonrası normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.38 ve 16 Haziran 2020 deki normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.38 olduğu görülmüştür. Yani test çıktılarıyla eğitim çıktıları arasında hiç hata yoktur. Yani bu, en iyi tahmin yapıldığı saattir.

*23:00 için eğitim sonrası normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.10 ve 16 Haziran 2020 deki normalize edilmiş aktif kullanıcı sayısının yaklaşık 0.37 olduğu görülmüştür. Yani test çıktılarıyla eğitim çıktıları anlamlı hata olduğu görülmektedir.

Test çıktıları ile eğitim çıktıları karşılaştırıldığında sadece beşinci ve sekizinci değerler arasında fark olduğu görülmekte ancak geri kalan çıktılar arasındaki farkın çok az olduğu hatta bir değerinde hiç fark olmadığı görülmektedir. Buna göre, veri sayısı az olmasına rağmen yapay sinir ağı ile yapılan tahminin iyi olduğu söylenebilir.

5. Sonuçlar

Bu çalışmada günün herhangi bir zamanındaki oyun kullanıcı sayısı tahmini için yapay sinir ağı kullanılmıştır. Tahmin, gerçekleşecek olayın sonucunu bilmekten ziyade sonuca en yakın değere ulaşmayı amaçlamaktadır. Kullanılan tahmin tekniğine göre hata oranı değişkenlik gösterip, hata oranı ne

kadar düşük ise yapılan tahminin doğruluğu o kadar artmaktadır. Bu nedenle ülkeler, büyük finansal şirketler, ekonomik şirketler, oyun platformları gibi kuruluşlar tahmin araştırmaları noktasında büyük yatırımlar yapan kuruluşlardır.

Uygulama kısmında aktif kullanıcı sayısı tahminine yönelik bir yapay sinir ağı geliştirilmiştir. Tasarlanan YSA modelinde kullanılan ileri beslemeli geri yayılım ağı, tahmin problemlerinin çözümündeki sık kullanılabilirliği ve diğer ağlar ile kıyaslandığında elde edilen daha iyi performansından dolayı seçilmiştir. Aktif Kullanıcı Sayısının oyun sunucuları için önemli olmasına karşın tarafımızca yapılan tarama sonucu bununla ilgili çalışmalara rastlanmamıştır. Yapılan çalışma sonucunda yapay sinir ağları kullanılarak düşük hata paylarıyla oyun sunucularının genel aktif kullanıcı sayılarını belirleyebilecekleri görülmüştür. Aktif kullanıcı sayısına göre oyun sunucuları, sundukları oyunların kullanıcı sayılarını ne oranda arttırdığını veya azalttığını ve bu oyunların finansal açıdan sağlayacakları getirileri ile ilgili önkestimde bulunabilecektir.

Test çıktıları ile eğitim çıktıları karşılaştırıldığında sadece saat 20:00 ve saat 23:00 deki değerler arasında fark olduğu görülmekte ancak geri kalan çıktılar arasındaki farkın çok az olduğu hatta bir değerde hiç fark olmadığı ve 14 Haziranın hafta sonuna 16 Haziranın ise hafta içine denk gelmesi – genel olarak hafta sonları aktif oyuncuların sayısı hafta içine göre daha fazladır- göz önüne alındığında bu hatalar ihmal edilebilirler. Oyuncu sayısının en fazla olduğu saatlerde özellikle saat 22:00’de yapay sinir ağları en iyi tahmini yapmıştır. Bu da farklı günler ve farklı saatlerde alınacak daha çok kullanıcı sayısı barındıran veriler kullanıldığında yapay sinir ağlarının daha iyi tahmin sonuçları verebileceği anlamına gelebilir. Bundan sonraki çalışmalarda haftalık veya aylık saat bazlı veriler alınarak yapay sinir ağlarıyla tahminleme yapılabilir. Ayrıca bu sonuçlar regresyon model tahminleriyle karşılaştırılarak en iyi tahmin yöntemi seçilebilir.

Kaynaklar

- [1] Turing, A. M. (1936). On computable numbers, with an application to the Entscheidungsproblem. Proceedings of the London Mathematical Society, Series 2, 41, 230–267.
- [2] Zurada, J. M. (1992). Introduction to artificial neural systems (Vol. 8). St. Paul: West.
- [3] Gurney, K.(1997). Introduction to Neural Networks. Routledge.
- [4] Haykin, S(1998). Neural Networks: A Comprehensive Foundation, Prentice Hall.
- [5] Champanand, A. (2002). The Dark Art of Neural Networks. AI Game Programming Wisdom, pp 640-651, Charles River Media.
- [6] Sweetser, P. (2004). How to Build Neural Networks for Games. AI Game Programming Wisdom II, pp 615-625, Charles River Media.
- [7] McGlinchey, S. (2003). Learning of AI Players from Game Observation Data. GAME-ON 2003, 4th International

Conference on Intelligent Games and Simulation, pp. 106-110, Nov.2003.

- [8] Chang, T. S. (2011). A comparative study of artificial neural networks, and decision trees for digital game content stocks price prediction. Expert systems with applications, 38(12), 14846-14851.
- [9]Sağiroğlu, Ş., Beşdok, E. ve Erler, M. (2003). Mühendislikte Yapay Zeka Uygulamaları I Yapay Sinir Ağları, Ufuk Kitap Kırtasiye-Yayıncılık Tic. Ltd. Şti., Kayseri.
- [10] Öztemel, E. (2003). Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul
- [11] Kohonen, T. (2001). Learning vector quantization. In Self-organizing maps (pp. 245-261). Springer, Berlin, Heidelberg.
- [12] “Steam ve oyun istatistikleri” Erişim adresi: <https://store.steampowered.com/stats/?l=turkish>. Son erişim Tarihi: 16.06.2020
- [13] Khademi, F., Akbari, M., Jamal, S. M., & Nikoo, M. (2017). Multiple linear regression, artificial neural network, and fuzzy logic prediction of 28 days compressive strength of concrete. Frontiers of Structural and Civil Engineering, 11(1), 90-99.
- [14] Khademi, F., Jamal, S. M., Deshpande, N., & Londhe, S. (2016). Predicting strength of recycled aggregate concrete using artificial neural network, adaptive neuro-fuzzy inference system and multiple linear regression. International Journal of Sustainable Built Environment, 5(2), 355-369.
- [15] Shams, S. R., Jahani, A., Moeinaddini, M., & Khorasani, N. (2020). Air carbon monoxide forecasting using an artificial neural network in comparison with multiple regression. Modeling Earth Systems and Environment, 6(3), 1467-1475.
- [16] Öztürk, P., Alisoy, H. & Mutlu, R. (2019). Yapay Sinir Ağları Kullanarak İkili ve Üçlü Büküm Makinaların Ürettiği CAT 6A U/FTP Kabloların Parametrelerinin Tahmini ve Tahmin Edilen Sonuçların Karşılaştırılması, European Journal of Engineering and Applied Sciences, vol. 2, pp. 41-51.
- [17] Chandar, K. R., Sastry, V. R., & Hegde, C. (2017). A critical comparison of regression models and artificial neural networks to predict ground vibrations. Geotechnical and geological engineering, 35(2), 573-583.
- [18] Yokoyama, M., Koyama, R., & Yanagisawa, M. (2017). An evaluation of hand-force prediction using artificial neural-network regression models of surface EMG signals for handwear devices. Journal of Sensors, 2017.