



Yapay Sinir Ağını Kullanarak Müşteri Memnuniyeti Analizi

Yunus Emre ARAÇ*

Istanbul Aydın Üniversitesi, Bilgisayar Mühendisliği Bölümü, İstanbul
yunusarac@aydin.edu.tr ORCID: 0000-0001-8346-8802

Ahmet GÜRHANLI

Istanbul Aydın Üniversitesi, Bilgisayar Mühendisliği Bölümü, İstanbul
ahmetgurhanli@aydin.edu.tr ORCID: 0000-0002-2568-7991

Geliş: 09.05.2019, Revizyon: 29.07.2019, Kabul Tarihi: 05.08.2019

Öz

Günümüz teknolojilerinde en önemli merak konularından biri ileriye tahmin etmek olmuştur. Bu konuda birçok çalışma makine öğrenmesi üzerine yoğunlaşmıştır ama doğrusal olmayan durumlarda klasik makine öğrenmesi yöntemleri yeterli gelmemiştir. Yapay sinir ağları da eldeki verilerden yola çıkarak tahminler yapabilmemize olanak sağlayan bir sistem olarak hayatımıza girmiştir. Müşteriye yönelik çalışan tüm kuruluşların daha fazla müşteri kazanabilmek ve var olan müşterilerini ellerinde tutabilmek için müşterilerinin memnuniyetlerini öğrenmeleri gerekmektedir. Bu memnuniyet durumu içine sadece nesnel veriler değil insan duyguları da girebileceği için doğrusal bir denklem oluşturulamamaktadır. Eldeki veriler iyi analiz edilerek, yeni gelecek müşteriler için de doğru kararlar verilip onların kalıcılığının artırılması gerekmektedir. Klasik makine öğrenmesi bu tür bir uygulamada yetersiz kalmaktadır, ancak otomatik olarak eğitilen ve doğrusal olmayan bileşenler içeren yapay sinir ağları doğruluğu yüksek sonuçlar verebilmektedir. Yapay sinir ağları sayesinde doğrusal olmayan denklemler kurularak bu uygulamalara yönelik tahminlerin en iyi şekilde yapılması amaçlanmaktadır. Son yıllarda yapılan karşılaştırmalar ve çalışmalar da yapay sinir ağlarının klasik makine öğrenmesi yöntemlerine göre doğrusal olmayan durumlarda daha iyi sonuç verdiğini göstermektedir. Bu çalışma da derin öğrenme ile müşteriler üzerinde memnuniyet analizi ve tahmini yapılırsa daha iyi sonuçlar alınabileceğini ortaya koymaktadır. Bu makalede bir yapay sinir ağında bu uygulama özelinde karşılaşılan durumlar raporlanmaktadır. Çalışmamız müşteri memnuniyet analizi için ağdaki parametrelerin nasıl ayarlanması gerektiğini belirtmekte ve farklı algoritma seçimlerinin nasıl sonuç verdiğini göstermektedir.

Anahtar Kelimeler: YSA; Yapay Sinir Ağı; Müşteri Memnuniyeti

* Yazışmaların yapılacağı yazar

Giriş

Yapay sinir ağlarının (YSA) tahminde kullanılmasına olan ilgi, son on yılda araştırma faaliyetlerinde büyük bir artışa neden olmuştur. Yapay sinir ağları büyük bir umut vaat etmelerine rağmen, aynı zamanda belirsizlik de içermektedir. Bugüne kadar araştırmacılar, temel faktörlerin yapay sinir ağlarında tahmin performansına etkisi konusunda kesin değillerdir. Son yıllarda diğer makine öğrenmesi teknikleri ile kıyaslama yapıldığı zaman yapay sinir ağlarının bu tekniklere göre daha iyi olduğunu yapılan çalışma ve örneklemelerde görülebilmektedir. Bu durumun oluşumundaki en büyük sebeplerden biri ise çözülmesi en zor olan doğrusal olmayan problemlerde daha gerçeğe uygun bir model sunmasıdır. Burada oluşan giriş ve çıkış değerleri arasında doğrusal bir bağlantı kurulamamasından dolayı diğer çoğu yöntem yetersiz kalmaktadır (Akin, 2018).

Bir makine öğrenmesi algoritması yanlış bir tahmin verirse, o zaman bir mühendis içeri girmeli ve ayarlamalar yapmalıdır. Ancak, derin öğrenme modeliyle, bir tahminin doğru olup olmadığını algoritmalar kendi başlarına belirleyebilmektedir. Doğrusal olmayan bir denklemin çözülmesinde ise bu denklemi etkileyecek birden fazla etken yer almaktadır. Sonucu etkileyen tüm bu etkenlerin karar verme mekanizmasına dâhil olarak etkileme oranına göre sonucun belirlenmesinde kullanılmalıdır.

İnsan beyni, gerçek dünyadaki durumların bağlamını bilgisayarların yapamayacağı şekilde yorumlamaktadır. Bu sorunu çözmek için ilk olarak 1950'lerde sinir ağları geliştirilmiştir. Yapay bir sinir ağı, insan beynini oluşturan nöron ağını benzetim etme girişimidir, böylece bilgisayar bir şeyler öğrenebilir ve insani bir şekilde kararlar alabilir. Yapay sinir ağları düzenli bilgisayarları birbirine bağlı beyin hücreleriymiş gibi davranacak şekilde programlayarak oluşturulmaktadır.

İnsanlar da kararlarını düşünerek, daha önceki deneyimlerinden faydalanarak test ederler ve bu

testler sonucu doğruluk oranına göre ileriye dönük yeni durumlar için tahminlerde bulunabilirler. Aslında baktığımız zaman bu günlük hayatımızın her anında kullanılan bir yöntemdir. Bir yapay sinir ağı da aslında bu şekilde ilerlemektedir. Doğru bir kurgu yapıldığı zaman var olan geriye dönük bilgilerin belirli bir kısmı ile kendisini eğitir, geri kalan kısmını da bu eğitimin ne kadar doğru bir şekilde yapıldığını test etmek için kullanır. Doğru modele karar verdiğine emin olduktan sonra yeni gelen veriler üzerinden tahminlerini yapabilecek şekilde hazır hale gelir.

Yapay sinir ağ sistemlerinde nesnel olmayan durumları da çözebilmemiz için var olan kurgumuzu doğrusal olmayacak şekilde gerçekleştirmemizi sağlayan en önemli faktörlerden biri de aktivasyon fonksiyonudur. Aktivasyon fonksiyonu seçimine göre de veri setinden alınan doğruluk oranı sonuçları değişecektir. Bunun gibi yapay sinir ağını etkileyen birçok parametre vardır. Bunların veri setine uygun bir şekilde seçilmesi sonuç için önem arz etmektedir.

Literatür Taraması

Bu alanda birçok çalışma yapılmaktadır. En önemli çalışmalar incelendiği zaman birçoğunda aslında klasik makine öğrenmesi yöntemlerinin zorlandığı kısım olan insan duygu ve algılarının etkilediği durumlar ele alınmaktadır.

Go oyunu muazzam arama alanı ve tahta pozisyonlarını ve hareketlerini değerlendirme zorluğu nedeniyle yapay zekâ için klasik oyunların en zoru olarak görülmektedir. Burada, tahta pozisyonlarını değerlendirmek için 'değer ağlarını' kullanan ve hareketleri seçmek için 'politika ağlarını' kullanan Go oyununa yeni bir yaklaşım getirilmiştir. Bu derin sinir ağları, denetimli öğrenmenin ve destekleyici öğrenmenin yeni bir kombinasyonu ile eğitilmiştir. Herhangi bir arama araştırması olmadan, sinir ağları, binlerce rastgele oyun oynamayı simüle eden en gelişmiş Monte Carlo ağacı arama programları düzeyinde Go oyunu oynar. Ayrıca Monte Carlo simülasyonunu değer

ve politika ağları ile birleştiren yeni bir arama algoritması sunmaktadır. Bu arama algoritmasını kullanarak, AlphaGo programı diğer Go programlarına karşı %99,8 kazanma oranı elde etmiş ve 5 Avrupa Şampiyonunu 5 maçta mağlup etmiştir. Bir bilgisayar programı ilk kez en az on yıl uzakta olduğu düşünülen bir başarı olan tam boyutlu Go oyununda profesyonel bir insan oyuncuyu yenmiştir (Silver, 2016).

Sinir ağı tabanlı dik ön yüz tespit sistemi kullanılarak yüz tanıma sistemi yapılmıştır. Kameraya bağlı bir sinir ağı, bir görüntünün küçük pencerelerini inceler ve her bir pencerenin bir yüz içerip içermediğine karar verir. Sistem, tek bir ağ üzerinden performansı artırmak için çoklu ağlar arasında tahkim edilir. Eğitim sırasında olumlu yüz örneklerini hizalamak için basit bir prosedür sunulur. Olumsuz örnekleri toplamak için, eğitim ilerledikçe eğitim setine yanlış tespitler ekleyen bir bootstrap algoritması kullanılmıştır. Bu, yüzeysel olmayan görüntülerin tüm alanını kapsayacak şekilde seçilmesi gereken örgün olmayan eğitim örneklerini elle seçmenin zor görevini ortadan kaldırır. Görüntülerde nadiren örtüşen yüzlerin kullanılması gibi basit sezgisel tarama, doğruluğu daha da artırabilir. Diğer son teknoloji ürünü yüz algılama sistemleri ile karşılaştırmalar yapılarak, sistemin tespit ve yanlış pozitif oranlar açısından karşılaştırılabilir bir performans gösterdiği görülmektedir (Rowley, 1998).

Elektrik yükü tahmini için de yapay sinir ağı (YSA) yaklaşımı kullanılmıştır. YSA geçmiş, şimdiki ve gelecekteki sıcaklık ve yükler arasındaki ilişkiyi öğrenmek için kullanılmıştır. Öngörülen yükü sağlamak için, YSA bir eğitim veri setindeki yük ve sıcaklık verileri arasında enterpolasyon yapar. Gerçek fayda verileri üzerindeki testlerde 1 saat ve 24 saat ilerideki tahminlerin ortalama mutlak hataları sırasıyla % 1,40 ve % 2,06 olarak gösterilmiştir. Bu, aynı verilere uygulanan hâlihazırda kullanılan bir tahmin tekniğiyle 24 saatlik ön tahminlerde ortalama % 4.22'lik bir hata ile karşılaştırılmaktadır (Park, 1991).

Yapay sinir ağları (YSA) kullanarak gen ekspresyon imzalarına dayanan belirli tanı kategorilerine kanser vakalarını sınıflandırmak için bir yöntem geliştirilmiştir. YSA'lar küçük yuvarlak mavi hücreli tümörleri (SRBCT) kullanan bir model ile eğitilir. Bu kanserler dört farklı tanı kategorisine aittir ve sıklıkla klinik pratikte tanı ikilemleri sunarlar. YSA tüm örnekleri doğru şekilde sınıflandırmıştır ve sınıflandırmaya en uygun genleri tanımlamıştır. Bu genlerin birkaçının sentezlenmesi SRBCT'lerde bildirilmiştir, ancak çoğu bu kanserler ile ilişkilendirilmemiştir. Eğitimli YSA modellerinin SRBCT'leri tanıma kabiliyetini test etmek için, daha önce antrenman prosedürü için kullanılmayan ve tüm durumlarda doğru şekilde sınıflandırılan ek körlenmiş örnekler analiz edilmiştir. Bu çalışma, bu yöntemlerin tümör teşhisi için potansiyel uygulamalarını ve tedavi için aday hedeflerin tanımlanmasını göstermektedir (Khan, 2001).

Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Her makine öğrenmesi sistemi gibi yapay sinir ağlarının da kullanımında avantajlar ve dezavantajlar bulunmaktadır. Bu avantaj ve dezavantajlar göz önünde bulundurularak yapay sinir ağlarının hangi durumlarda kullanılıp kullanılmayacağına karar verilebilir.

Yapay sinir ağlarının avantajlarını maddeler halinde sıralanacak olunursa:

- **Bilgilerin tüm ağda saklanması:** Geleneksel programlamadaki bilgiler, bir veri tabanında değil tüm ağda saklanır. Birkaç bilginin bir yerde kaybolması ağın çalışmasını engellemez.
- **Eksik bilgi ile çalışabilme becerisi:** Yapay sinir ağı eğitiminden sonra, veriler eksik bilgilerle bile çıktı üretebilir. Buradaki performans kaybı, eksik bilgilerin önemine bağlıdır.
- **Hata toleransına sahip olmak:** Bir veya daha fazla sayıda yapay sinir ağı hücresinin bozulması, bunun çıkış

oluşturmasını engellemez. Bu özellik ağların hataya dayanıklı olmasını sağlar.

- **Dağıtılmış bir belleğe sahip olmak:** Yapay sinir ağının öğrenebilmesi için, örnekleri belirlemek ve bu örnekleri ağa göstererek şebekeye istenen çıktıya göre öğretmek gerekir. Ağın başarısı seçilen örneklerle doğrudan orantılıdır ve olay ağa tüm yönleriyle gösterilemiyorsa, ağ yanlış çıktı üretebilir.
- **Kademeli bozulma:** Bir ağ zaman içinde yavaşlar ve göreceli olarak bozulmaya uğrar. Ağ sorunu hemen derhal aşınmaz.
- **Makine öğrenmesi yeteneği:** Yapay sinir ağları benzer olayları yorumlayarak olayları öğrenir ve karar alır.
- **Paralel işleme yeteneği:** Yapay sinir ağları, aynı anda birden fazla işi gerçekleştirebilecek sayısal güce sahiptir.

Yapay sinir ağlarının dezavantajları maddeler halinde sıralanacak olursa:

- **Donanım bağımlılığı:** Yapay sinir ağları, yapılarına uygun olarak paralel işlem gücüne sahip işlemciler gerektirir. Bu nedenle donanımın bu işlem gücünü gerçekleştirilmesi gerekmektedir.
- **Açıklanamayan ağ davranışı:** Bu yapay sinir ağlarının en önemli sorunudur. YSA bir sondalama çözümü ürettiğinde, neden ve nasıl olduğu hakkında bir ipucu vermez. Bu, ağa olan güveni azaltır.
- **Uygun ağ yapısının belirlenmesi:** Yapay sinir ağlarının yapısını belirlemek için belirli bir kural yoktur. Uygun ağ yapısı, tecrübe ve deneme yanılma yoluyla elde edilir.
- **Sorunu ağa gösterme zorluğu:** Yapay sinir ağları sayısal bilgilerle çalışabilir. Problemlerin yapay sinir ağlarına sunulmadan önce sayısal değerlere çevrilmesi gerekir. Burada belirlenecek olan görüntüleme mekanizması ağın performansını doğrudan etkileyecektir. Bu kullanıcının yeteneğine bağlıdır.

- **Ağın eğitim süresinin tam bilinmemesi:** Ağ eğitimi, numune üzerindeki hata belirli bir değere düşürüldüğünde tamamlanır. Bu değer bize optimum sonuç vermemektedir.

Müşteri Memnuniyet Analizi Uygulaması için Yapay Sinir Ağındaki Algoritma ve Parametrelerin Belirlenmesi

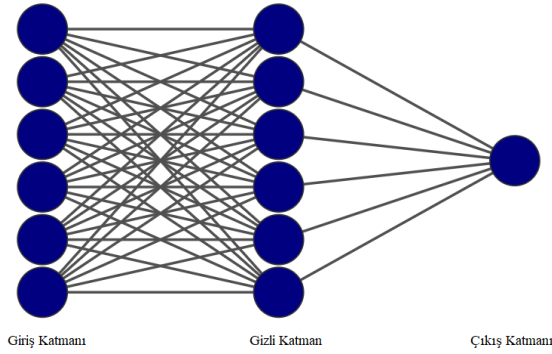
Yapay sinir ağları doğrusal olmayan durumlarda kullanıldığı için parametrelerinin alacağı değerler arasında doğrusal bir mantık kurulması söz konusu olmayacaktır. Bundan dolayı bu değerlerin en iyi şekilde belirlenebilmesi için veri seti üzerinde kıyaslamalar yaparak en iyi değerleri bulmamız gerekmektedir. Bu parametreler sayesinde en iyi doğruluk oranını verecek yapay sinir ağı modeli oluşturulabilir.

Bu araştırmada daha önceden kurulan bir model ve veri seti kullanılarak, müşteri memnuniyet analizi ve tahmini uygulaması için yapay sinir ağlarındaki algoritma ve parametrelerin nasıl seçilmesi ve ayarlanması gerektiği üzerinde çalışıldı. Örnek alınan yapay sinir ağı modelinin (Akin, 2018) aynı veri seti üzerinde daha iyi sonuç vermesi için en optimal kalibrasyon ve tercihler belirlenmeye çalışıldı. Bu alınan örnekte belirlenen parametre değerleri ile sistem çalıştırıldığı zaman %80 civarında bir doğruluk oranı ile karşılaşılmaktadır.

Bu çalışmada belirlenen müşteri memnuniyeti veri dizisi 'GridSearchCV' yöntemi ile işlenip adım adım tüm sistem bileşenleri için en iyi seçeneğin bulunması hedeflenmiştir. Belirlenen farklı yöntemlerin nasıl sonuçlar oluşturacağı çıkartılarak karşılaştırmalar yapıldı ve farklı değer ve yöntemlerin doğruluk oranını nasıl etkilediği araştırıldı.

İlk olarak başlangıç için bir yapay sinir ağı modelinin olması gerekmektedir. Başlangıç

olarak Şekil 1’de yer alan yapay sinir ağı modeli kullanılmıştır.



Şekil 1: Başlangıç Yapay Sinir Ağı Modeli

En iyi sonuca ulaşabilmek için her bir sistem değişkenini sırası ile değerlendirmek gerekmektedir. İlk model kurulduğu zaman bu parametreler için rastgele değerler ve yöntemler kullanılacaktır. Her kontrolde bir önceki değerlendirmede en iyi sonucu veren değer ve yöntemler kullanılarak ilerlenecektir. Sonuca etkisi değerlendirilen sistem bileşenlerini aşağıdaki gibi sıralayabiliriz:

- Evreler ve Küme Boyutu (Epochs and Batch Size)
- Optimizasyon Algoritması (Optimizer)
- Başlama Modu (Init Mode)
- Aktivasyon Fonksiyonu (Activation Function)
- Düşürme Oranı (Dropout Rate)
- Sinir Sayısı (Neurons)

Evreler ve Küme Boyutu


Bu iki parametre için de rastgele belirlenen bir dizi tanımlaması olması gerekmektedir. Bu tanımlamalar için her iki parametrede de belirli bir standart ya da sınır bulunmamaktadır. Bundan dolayı Evre Sayısı (Epochs) parametresi için 10, 50, 100, 150, 200 ve Küme Boyutu (Batch Size) parametresi için ise 10, 20, 40, 60, 80, 100 değerlerini alarak her biri için veri setinde nasıl sonuç oluşturacağını analiz etmeye çalıştık.

Bu parametrelerin her biri için kombinasyon yapıldığında aşağıdaki sonuçlara ulaşılmaktadır.

Ortalama doğruluk oranı için:

Tablo 1: Evre Sayısı ve Küme Boyutu için Ortalama Doğruluk Oranı Sonuç Tablosu

Evre Sayısı \ Küme Boyutu	10	50	100	150	200
10	0.841	0.832	0.833	0.843	0.835
20	0.822	0.835	0.841	0.831	0.843
40	0.813	0.831	0.841	0.842	0.851
60	0.802	0.833	0.832	0.840	0.833
80	0.796	0.836	0.845	0.832	0.841
100	0.796	0.838	0.847	0.855	0.839




Şekil 2: Evre Sayısı ve Küme Boyutu için Ortalama Doğruluk Oranı Sonuç Grafiği

Standart sapma oranı için:

Tablo 2: Evre Sayısı ve Küme Boyutu için Standart Sapma Oranı Sonuç Tablosu

Evre Sayısı \ Küme Boyutu	10	50	100	150	200
10	0.015	0.005	0.005	0.009	0.004
20	0.003	0.002	0.008	0.005	0.008
40	0.015	0.005	0.012	0.011	0.014
60	0.013	0.003	0.003	0.013	0.006
80	0.003	0.010	0.007	0.003	0.008
100	0.003	0.016	0.009	0.004	0.010



Şekil 3: Evre Sayısı ve Küme Boyutu için Standart Sapma Oranı Sonuç Grafiği

Bu sonuçların hepsi karşılaştırıldığı zaman içerisinde en iyi sonucu veren kombinasyon 0.855000 oranı ile küme boyutu için 100 ve evre sayısı için 150 değerleri olmuştur.

Optimize Edici

Optimizasyon yöntemi için kütüphane içerisinde yer alan yöntemler tek tek denenerek en iyi doğruluk oranını veren algoritma tespit edilmeye çalışıldı. Bunlar 'SGD' (Mei, 2018), 'RMSprop'

(Teileman ve Hinton, 2012), 'Adagrad' (Duchi, Hazan, ve Singer, 2011), 'Adadelta' (Zeiler, 2012), 'Adam' (Diederik ve Ba, 2014), 'Adamax'(Diederik ve Ba, 2014) ve 'Nadam' (Dozat, 2016) olarak adlandırılmaktadır. En iyi sonucu hangisinin vereceği bilinmeyeceği için tüm değerlerin karşılaştırılması gerekmektedir. Bu yöntemlerin matematik formülleri Tablo 3'te özetlenmiştir.

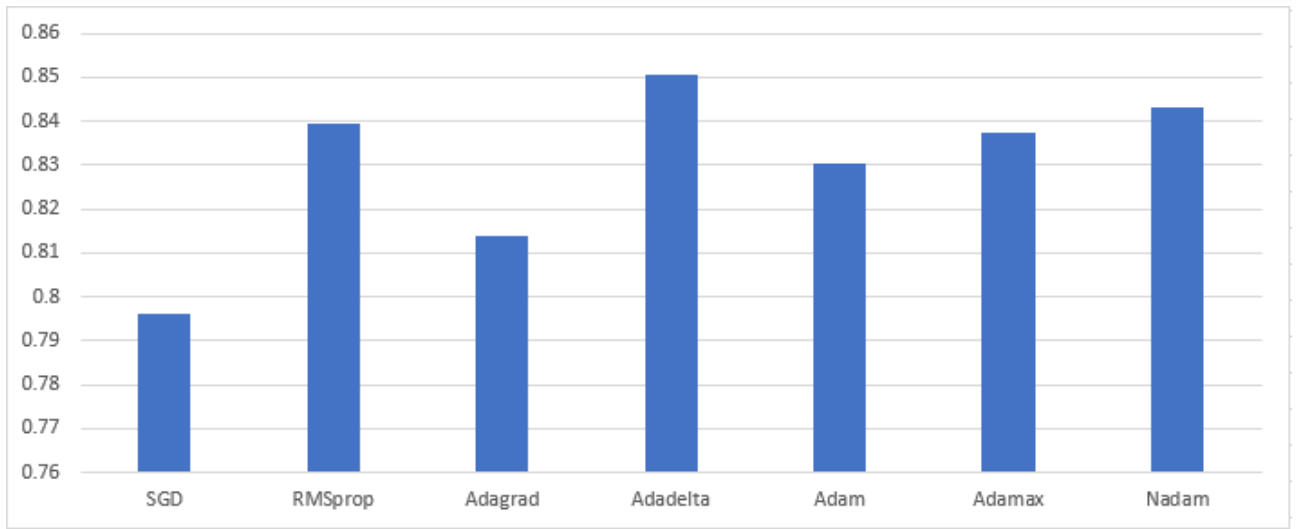
Tablo 3: Optimizasyon Fonksiyonlarının Formülleri

Optimizör	Formül
Stochastic Gradient Descent (SGD)	$Q(w) = \frac{1}{n} \sum_{i=1}^n Q_i(w),$
Root Mean Square Propagation (RMSprop)	$w := w - \frac{\eta}{\sqrt{v(w, t)}} \nabla Q_i(w)$
Adaptive Gradient Descent (Adagrad)	$G = \sum_{\tau=1}^t g_{\tau} g_{\tau}^T$
Adaptive Learning Rate (Adadelta)	$\Delta x_t = -\frac{\eta}{\text{RMS}[g]_t} g_t$
Adaptive Moment Estimation (Adam)	$w^{(t+1)} \leftarrow w^{(t)} - \eta \frac{\hat{m}_w}{\sqrt{\hat{v}_w + \epsilon}}$
Adaptive Moment Estimation Maximum Adamax	$w_{t+1} = w_t - \frac{\alpha}{S_t} \cdot \hat{V}_t$
Nesterov-accelerated Adaptive Moment Estimation (Nadam)	$w_{t+1} = w_t - \frac{\alpha}{\sqrt{\hat{S}_t + \epsilon}} \left(\beta_1 \hat{V}_t + \frac{1 - \beta_1}{1 - \beta_1^t} \cdot \frac{\partial L}{\partial w_t} \right)$

Farklı optimizasyon algoritmaları için ortalama doğruluk oranı ve standart sapma oranı değerleri Tablo 4 ve Grafik 3'te verilmiştir.

Tablo 4: Optimizasyon Yöntemleri için Ortalama Doğruluk Oran Sonuç Tablosu

Optimizer	Ortalama Doğruluk Oranı	Standart Sapma Oranı
SGD	0.796	0.003
RMSprop	0.839	0.011
Adagrad	0.814	0.015
Adadelta	0.850	0.009
Adam	0.830	0.003
Adamax	0.8372	0.009
Nadam	0.843	0.007

**Şekil 4:** Farklı Optimizasyon Yöntemleri için Ortalama Doğruluk Oran Sonuç Grafiği


Bu sonuçlar incelendiği zaman 0.850500 doğruluk oranı ile Adadelta metodunun en iyi neticeyi verdiği görülmüştür.

Bu sonuçların model içerisindeki diğer parametre değerlerinin farklı verilmesine bağlı olarak

değiştiğini göstermek amaçlı en kötü oranı veren evre sayısı 80 ve küme boyutu 10 değerleri için tekrardan optimizasyon algoritmaları karşılaştırılır ise aşağıdaki gibi sonuçlar değişmektedir.

Tablo 5: Farklı Optimizasyon Yöntemleri için Ortalama Doğruluk ve Standart Sapma Oran Sonuç Tablosu

Optimizer	Ortalama Doğruluk Oranı	Standart Sapma Oranı
SGD	0.856	0.001
RMSprop	0.826	0.005
Adagrad	0.827	0.004
Adadelta	0.844	0.013
Adam	0.823	0.016
Adamax	0.840	0.013
Nadam	0.838	0.015



Şekil 5: Farklı Optimizasyon Yöntemleri için Ortalama Doğruluk Sonuç Grafiği

Bu durumdan da görüleceği üzere parametre değişkenleri arasında bir doğrusal yapıdan bahsedilememektedir.

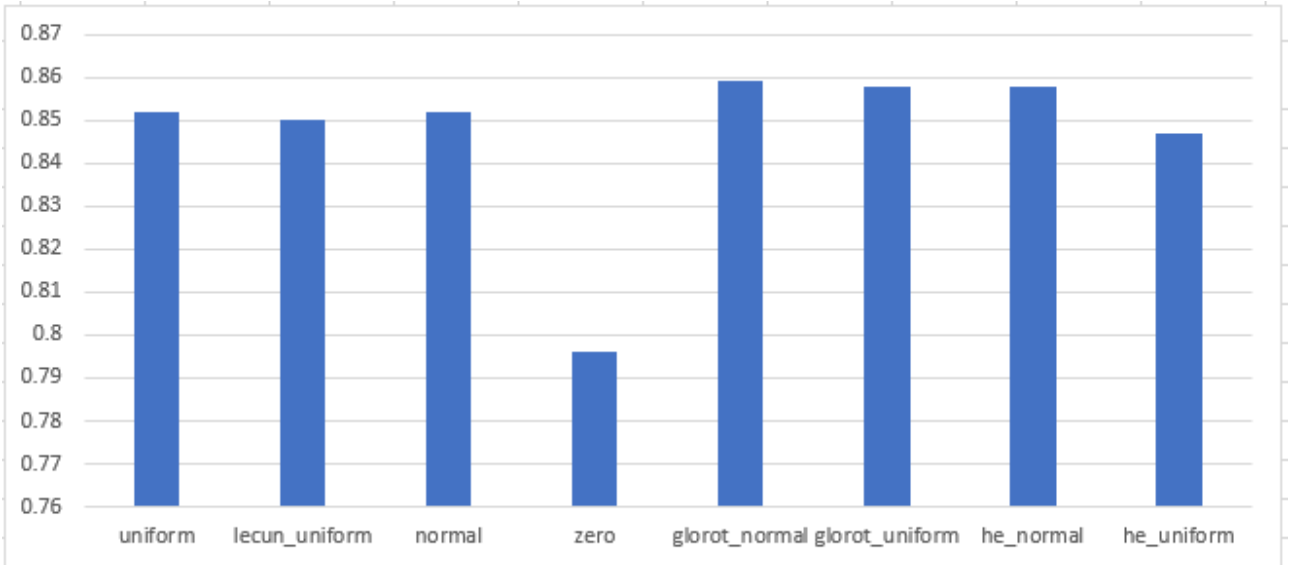
Başlangıç Modu

Bu parametre içinde aynı şekilde kütüphane içerisinde tanımlı olan belirli sayıda yöntemler bulunmaktadır. Bu yöntemler 'uniform', 'lecun_uniform', 'normal', 'zero', 'glorot_normal', 'glorot_uniform', 'he_normal' ve 'he_uniform' olarak adlandırılmaktadır. Karşılaştırma işleminde tüm farklı yöntemler kullanılmıştır.

Bu yöntemler karşılaştırıldığı zaman sonuçlar aşağıdaki gibi çıkmaktadır.

Tablo 6: Başlangıç Modu için Ortalama Doğruluk ve Standart Sapma Oran Sonuç Tablosu

Init Mode	Ortalama Doğruluk Oranı	Standart Sapma Oranı
uniform	0.852	0.014
lecun_uniform	0.850	0.010
normal	0.852	0.012
zero	0.796	0.003
glorot_normal	0.859	0.0001
glorot_uniform	0.858	0.006
he_normal	0.858	0.007
he_uniform	0.847	0.011



Şekil 6: Başlangıç Modu için Ortalama Doğruluk Sonuç Grafiği

Bu sonuçlar incelendiği zaman en iyi sonucu veren yöntemin 0.859125 ortalama oranı ile 'glorot_normal' olduğu görünmektedir.

Aktivasyon Fonksiyonu

Yapay sinir ağlarının belki de en önemli olan bileşenlerinden biri aktivasyon fonksiyonudur. Yapay sinir ağlarının doğrusal olmayan durumları çözebilmesi için yapılan işlemleri doğrusal olandan doğrusal olmayan yapıya dönüştürülmesini sağlayan fonksiyondur.

Bu parametre için de kütüphane içerisinde tanımlı belirli bazı fonksiyonlar bulunmaktadır. Bu fonksiyonlar 'softmax' (Bishop, 2006), 'softplus', 'softsign', 'relu', 'tanh', 'sigmoid', 'hard_sigmoid' ve 'linear' olarak adlandırılmaktadır. Adı geçen aktivasyon fonksiyonlarının matematiksel formülleri Tablo 7'de verilmiştir.


Tablo 7: Aktivasyon Fonksiyonu Formülleri

Activation	Formül
softmax	$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{for } j = 1, \dots, K.$
softplus	$\phi(x) = \ln(1 + e^x)$
softsign	$\phi(x) = \frac{x}{1 + x }$
relu	$f(x) = \max(0, x)$
tanh	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
sigmoid	$\zeta_\alpha(x) = \frac{1}{1 + e^{-\alpha x}} = \frac{\tanh(\alpha x / 2) + 1}{2}$
hard_sigmoid	$\max(0, \min(1, x))$

Tüm bu farklı aktivasyon fonksiyonları baz alınarak aralarında karşılaştırılma yapıldığı zaman aşağıdaki gibi sonuçlara ulaşılmaktadır.

Tablo 8: Aktivasyon Fonksiyonları için Ortalama Doğruluk ve Standart Sapma Oranı Sonuç Tablosu

Activation	Ortalama Doğruluk Oranı	Standart Sapma Oranı
softmax	0.860	0.0008
softplus	0.860	0.003
softsign	0.857	0.003
relu	0.847	0.010
tanh	0.857	0.002
sigmoid	0.852	0.005
hard_sigmoid	0.845	0.014
linear	0.808	0.007



Şekil 7: Aktivasyon Fonksiyonları için Ortalama Doğruluk Sonuç Grafiği


Bu sonuçlar incelendiği zaman en iyi sonucu 0.860375 doğruluk oranı ile 'softmax' değişkeni vermektedir.

Düşürme Oranı

Düşürme yöntemi aslında aşırı düzeltme problemini önleme görevi görmektedir. Yapar sinir ağında yer alan nöronlardan belirlenen değerden küçük sonuç veren nöronları sistemden çıkararak daha yüksek orana ulaşılmasını ve düşük olasılıkların sisteme etkisini engelleme amaçlı kullanılmaktadır. Bu parametre içinde değişken değerleri 0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9 olacak şekilde tanımlama yapabilmektedir. Bu parametreler ile gerekli karşılaştırmayı yapıldığı zaman aşağıdaki sonuçlar elde edilmiştir.

Tablo 9: Düşürme Oranı için Ortalama Doğruluk ve Standart Sapma Oranı Sonuç Tablosu

Dropout Rate	Ortalama Doğruluk Oranı	Standart Sapma Oranı
0.0	0.858	0.0003
0.1	0.860	0.005
0.2	0.851	0.014
0.3	0.848	0.006
0.4	0.816	0.002
0.5	0.796	0.003
0.6	0.796	0.003
0.7	0.796	0.003
0.8	0.796	0.003
0.9	0.796	0.003



Şekil 8: Düşürme Oranı için Ortalama Doğruluk Sonuç Grafiği


Sonuçlar incelendiği zaman en iyi sonucu veren değişken değeri 0.860125 ile '0.1' olduğu görülmektedir.

Sinir Sayısı

Bu parametre yapay sinir ağlarını etkileyen en önemli faktörlerden biridir. Bu parametre değeri için de herhangi bir değer kısıtlaması yoktur. Bundan dolayı karşılaştırmada 1, 5, 10, 15, 20, 25, 30 değerleri kullanılabilir. Bu parametreler karşılaştırıldığı zaman aşağıdaki sonuçlar elde edilmiştir.

Tablo 10: Sinir Sayısı için Ortalama Doğruluk ve Standart Sapma Oran Sonuç Tablosu

Sinirler	Ortalama Doğruluk Oranı	Standart Sapma Oranı
1	0.796	0.003
5	0.851	0.013
10	0.860	0.001
15	0.860	0.0007
20	0.858	0.001
25	0.860	0.0001
30	0.852	0.008



Şekil 9: Sinir Sayısı için Ortalama Doğruluk Sonuç Grafiği

Çıkan sonuçlar karşılaştırıldığı zaman en iyi sonucun 0.860750 doğruluk oranı ile 10 değeri ile alındığı görülmektedir.

Bu parametrelerin bazılarının değişken değerleri isteğe göre artırılabilir hatta daha da azaltılabilir. Burada sadece en temel parametreleri temel alınarak gerekli incelemeler yapılmıştır. Bu şekilde yapay sinir ağında değişiklik yapılabilecek tüm parametrelere bu yöntem uygulanarak verilebilecek en iyi değişken değerleri bulunabilmektedir. Bu yöntemlerin tamamı birleştirilerek tek seferde birbiri ile uyumlu en iyi parametre değerleri bulunabilir ama bunun için kombinasyon sayısı artacağı için hem yüksek güçlü bir bilgisayar hem de uzun bir süreye ihtiyaç duyulmaktadır.

Alınan değerler sonucunda görebileceğiniz gibi en kötü ortalama doğruluk oranı %79 çıkmıştır. Bu değerden daha düşük bir oranla çalışmak yerine son durumda %86 civarında bir doğruluk oranı ile belki de daha yüksek bir oranla testler sürdürülebilir. Bu sonuçlar aynı parametreler ve aynı veri setini kullanıldığı zaman bile %1 e yakın bir oranda sapma gösterebilmektedir.

Daha Hızlı ve Performanslı Çalışma Yöntemleri

Şimdiye kadarki süreçte incelenen bilgiler doğrultusunda bir veri modeline göre en iyi sonucu verebilecek olan yapay sinir ağı modellemesinin tamamlanmasının uzun bir zaman ve uğraş gerektirdiği görüldü. Bu süreçler bir defa tamamlandıktan sonra her seferinde aynı veri seti için bu kadar zaman kaybı yaşanılması

istenilmeyebilir. Bunun için hem yapay sinir ağı modelini hem de en iyi sonucun alındığı ağırlık değerlerini kaydederek bir sonraki sorgulamamızda bu model ve ağırlıkları sisteme yükleyebiliriz. Bu sayede tekrardan bir yapay sinir ağı modeli kurmadan ve sistemi eğitmeye zaman harcamadan istenilen veri üzerinde çalışma gerçekleştirilebilir.

Bunların yanı sıra yapay sinir ağında her çalıştırma farklı bir sonuç vereceği bilindiği için her yeni çalıştırmadan model ve ağırlıkları yükledikten sonra sistemi tekrardan eğiterek yeni değerlerin daha iyi sonuç verip vermediği kontrol edilebilir. Eğer daha iyi bir oran alınmış ise bu yeni oran için ağırlık değerleri güncellenir ama bu değer daha düşük bir oran çıkar ise bu değere karışmadan eski ağırlık değerleri ile tekrardan yüklenerek sonuç alınabilir.

Sonuç

Bu çalışmada müşteri memnuniyeti analizinde veri setine uygun olarak en iyi doğruluk oranını veren yöntem ve parametre değerleri bulunmaya çalışıldı. Yapay sinir ağının doğrusal olmadığı ve verilen parametre değerlerine göre nasıl değişiklik gösterdiği görüldü. Veri setinde bulunan müşteri bilgileri için yapılan son 10 testte aşağıdaki başarı oranları sağlanmış oldu.

- 0.8615
- 0.8605
- 0.86
- 0.8625
- 0.861
- 0.862


- 0.868
- 0.863
- 0.871
- 0.869

Yeni gelecek bir müşteri içinde aynı oranda bir doğruluk söz konusu olacaktır. Burada herhangi bir netlik söz konusu olmadan insan duygularının da yer alabileceği bir durumda tahmin gerçekleştirilmesi sağlanmıştır.

Bunun yanı sıra müşteri memnuniyeti için veri seti kullanarak oluşturulan yapay sinir ağında en iyi sonuç veren yöntem ve değerler aşağıda listelenmiştir:

- Evre Sayısı (Epochs): 100
- Küme Boyutu (Batch Size): 150
- Optimizasyon Algoritması (Optimizer): Adadelta
- Başlangıç Modu (Init Mode): glorot_normal
- Aktivasyon Fonksiyonu (Activation): softmax
- Düşürme Oranı (Dropout Rate):0.1
- Sinir Sayısı (Neurons): 10

Başta kurulan ağ yapısı incelendiği zaman 6 tane giriş ve gizli katman düğümü var iken son durum da 10 tane giriş ve gizli katman olması daha iyi çalışacak bir sonuca ulaşmamızı sağladı. Son durumda güncellenen yapay sinir ağını aşağıdaki grafikte gösterilmiştir.



Şekil 10: Sonuç Yapay Sinir Ağı Modeli

Diğer parametrelerin verdiği sonuçlar da incelendiğinde farklı parametreler seçilerek bu doğruluk oranının tam tersi şekilde daha da düşmesine sebep olunabilir. Doğrusal olmayan

bir yapı söz konusu olduğu içinde direk olarak herhangi bir değişken seçimi yapabilmenin pek mümkün olmadığı görülmektedir.

GELECEKTE YAPILABİLECEK ÇALIŞMALAR

kullanılabilir bir yapıya getirilebilir bir çalışma da gerçekleştirilebilir.

Literatür taraması ile YSA uygulanarak yapılmış olan çalışmalardan bahsettik. Yaptığımız çalışma kullanılarak ya da YSA uygulanarak neler yapılabileceğinden bahsedebiliriz.

Bu tez çalışması kullanılarak ya da yapay sinir ağı temel alınarak yapılabilecek çalışmaları sıralayacak olursak:

- Yapay sinir ağı model çıkartımı için bir sistem yazılarak gelen veri setine göre yapay sinir ağı modelinin oluşturulması sağlanabilir. Tekrar tekrar sistemi eğitmeye veya yapılan bu çalışmayı her seferinde yaparak zaman kaybetmeden en iyi modeli bularak bu modeli kaydedip bir sonraki çalışmada bu model üzerinden çalışmasını yapabilir.
- Makale de yer alan çalışma direk kullanılarak önceliği müşteri olan banka, market vb. büyük firmalar için ellerindeki müşteri verisini kullanarak ileriye dönük tahminler yapılabilir. Bu sayede hem var olan müşterileri kaybetmeden önlem alınabilecektir hem de yeni gelecek müşteriler için ikna etme alternatifleri bilinecektir.
- Kullanılan fonksiyon yöntemleri için yeni fonksiyonlar ve metotlar geliştirilebilir. Bunların eski sisteme göre artıları ya da eksileri ortaya çıkarılarak birden fazla birbirinden farklı veri setleri kullanılarak sonuçlar elde edilebilir. Bu sonuçların analizi ile bu bulunan yöntemlerin kullanılabilir olup olmadığını ve kullanılabiliriyorsa hangi tarz veri setinde veya yapay sinir ağı modelinde kullanılması daha uygun olunabileceği belirlenebilir.
- Kullanıcı ara yüzü olabilecek şekilde optimize edilerek yapılan çalışmanın son kullanıcı tarafında da yönetilebilir ve

Kaynaklar

- Akin E. (2018). Yapay Sinir Ağları – Artificial Neural Network (ANN).
- Basheer, I. ve Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application.
- Bishop, C. (2006). Pattern Recognition and Machine Learning.
- Chung, H., Lee, S. ve Park, J. (2016). Deep neural network using trainable activation functions
- Courbariaux, M., Hubara, I., Soudry, D., El-Yaniv, D. ve Bengio, Y. (2016). Binarized Neural Networks: Training Neural Networks with Weights and Activations Constrained to +1 or -1.
- Diederik, K. ve Ba, J. (2014). Adam: A method for stochastic optimization.
- Dozat, T. (2016) Incorporating Nesterov momentum into Adam.
- Duchi, J., Hazan, E. ve Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization.
- Khan, J., Wei, J., Ringner, M., Saal, L., Ladanyi, M., Westermann, F., Berthold, F., Schwab, M., Antonescu, C., Peterson, C. ve Meltzer, P. (2001). Classification and diagnostic prediction of cancers using gene expression profiling and artificial neural networks.
- Mei, S. (2018). A Mean Field View of the Landscape of Two-Layer Neural Networks, Proceedings of the National Academy of Sciences.
- PARK, D., ELSHARKAWI, M., MARKS, R., ATLAS, L. ve DAMBORG, M. (1991). ELECTRIC-LOAD FORECASTING USING AN ARTIFICIAL NEURAL NETWORK.
- Rowley, H., Baluja, S. ve Kanade, T. (1998). Neural network-based face detection.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview.
- Silver, D., Huang, A., Maddison, C., Guez, A., Sifre, L., Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search.
- Tieleman, T. ve Hinton, G. (2012). Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. COURSERA: Neural Networks for Machine Learning.
- Yao, X. (1999). Evolving artificial neural networks.
- Zeiler, M. (2012). ADADELTA: An adaptive learning rate method.

Customer Satisfaction Analysis Using Artificial Neural Network

Extended abstract

One of the most important curiosity issues in today's technologies has been to predict the future. Many studies have focused on machine learning, but in nonlinear cases, classical machine learning methods are not enough. Artificial neural networks have entered our lives as a system that allow us to make predictions based on the available data.

All organizations working for the customers need to learn the satisfaction of their customers to gain more customers and keep their existing customers. A linear equation cannot be created for this satisfaction, since not only objective data but also human emotions can be introduced. By analyzing the data well, it is necessary to make the right decisions for new future customers and increase their permanence.

Classical machine learning is inadequate in this kind of practice, but automatically trained neural networks that include non-linear components can give results having high accuracies. Non-linear equations are established by means of artificial neural networks and it is aimed to make the best estimates. In recent years, comparisons and studies have shown that artificial neural networks give better results in nonlinear cases compared to classical machine learning methods. This study shows that better results can be obtained if satisfaction analysis are conducted on customers using deep learning methods.

Due to the fact that human emotions are taken into consideration in artificial neural network, always achieving 100% accuracy is not possible using a trained network. There are many reasons that affect human emotions and these reasons can be unrelated to each other. This decision-making process will also change from situation to situation. Therefore, the study for each data set should be repeated. However, the best artificial neural network model to be created after this study is completed in accordance with a data set model can be used repeatedly for the same kind of data.

Unlike other machine learning methods, the result is unique to its own data set and cannot be defined with any linear equation. Therefore, it is necessary to be able to create an artificial neural network model

which will give the best accuracy ratio by applying the procedures in accordance with each data set model.

Combining these methods using a computer by examining all the possibilities of each combination of different algorithms and parameters is a way to achieve good accuracy values. But in this case a lot of time and powerful systems are needed. So, this study progresses gradually within a short time. After finding the best result for a parameter in one step, it is tried to reach the parameter value which will give the best result depending on this parameter in other steps.

As a result, in this study, we found a result that is closer to the best result in a shorter time in the whole combination and brought a better result to our existing data set.

Keywords: ANN, Artificial Neural Network, Customer Satisfaction