

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



YAPAY SİNİR AĞI KULLANARAK
MÜŞTERİ MEMNUNİYETİ ANALİZİ

YÜKSEK LİSANS TEZİ

Yunus Emre ARAÇ

Bilgisayar Mühendisliği Ana Bilim Dalı
Bilgisayar Mühendisliği Programı

AĞUSTOS 2019

**T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



**YAPAY SİNİR AĞI KULLANARAK
MÜŞTERİ MEMNUNİYETİ ANALİZİ**

YÜKSEK LİSANS TEZİ

Yunus Emre ARAÇ

Bilgisayar Mühendisliği Ana Bilim Dalı

Bilgisayar Mühendisliği Programı

Tez Danışmanı: Dr. Öğr. Üyesi AHMET GÜRHANLI

AĞUSTOS 2019



T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜ

Yüksek Lisans Tez Onay Belgesi

Enstitümüz Bilgisayar Mühendisliği Ana Bilim Dalı Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı Y1713.010012 numaralı öğrencisi **Yunus Emre ARAÇ**' ın "YAPAY SİNİR AĞI KULLANILARAK MÜŞTERİ MEMNUNİYETİ ANALİZİ" adlı tez çalışması Enstitümüz Yönetim Kurulunun 02.08.2019 tarih ve 2019/16 sayılı kararıyla oluşturulan jüri tarafından *ay.b.iz.* ile Tezli Yüksek Lisans tezi olarak *kabul* edilmiştir.

Öğretim Üyesi Adı Soyadı

İmzası

Tez Savunma Tarihi : 21/08/2019

1)Tez Danışmanı: Dr. Öğr. Üyesi Ahmet GÖRHANLI

2) Jüri Üyesi : Doç. Dr. Tamer ÇEVİK

3) Jüri Üyesi : Dr. Öğr. Üyesi Ahmet Feyzi ATEŞ

[Handwritten signatures of Ahmet Görhanlı, Tamer Çevik, and Ahmet Feyzi Ateş]

Not: Öğrencinin Tez savunmasında **Başarılı** olması halinde bu form imzalanacaktır. Aksi halde geçersizdir.

YEMİN METNİ

Yüksek lisans tezi olarak sunduğum “**YAPAY SİNİR AĞI KULLANARAK MÜŞTERİ MEMNUNİYETİ ANALİZİ**” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşünecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (21/08/2019)

Yunus Emre ARAÇ

ÖNSÖZ

Bu çalışma, İstanbul Aydın Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi olarak hazırlanan “YAPAY SİNİR AĞI KULLANARAK MÜŞTERİ MEMNUNİYETİ ANALİZİ” isimli tezi içermektedir. Çalışmalarımın her aşamasında bana destek olan başta ailem olmak üzere arkadaşlarım MARIYA KIKNADZE ve GÖKSU GÜNEYDAŞ’a, bilgi ve deneyimleri ile yardımcı olan kendisinden çok şey öğrendiğim, karşılaştığım problemlerde özgün fikirlerinden çokça istifade ettiğim danışmanım Sayın Dr. Öğr. Üyesi AHMET GÜRHANLI’ya teşekkür ederim.

AĞUSTOS 2019

Yunus Emre Araç

İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
ÇİZELGE LİSTESİ	xiii
ŞEKİL LİSTESİ	xv
ÖZET	xvii
ABSTRACT	xix
1.GİRİŞ.....	1
2.LİTERATÜR ÇALIŞMASI	3
3.YAPAY SİNİR AĞI	7
3.1.Yapay Sinir Ağı Nedir?	7
3.2.Biyolojik Sinir Hücresi	8
3.3.Yapay Sinir Ağının Yapısı	9
3.3.1.Girdi değerleri	10
3.3.2.Ağırlıklar	10
3.3.3.Toplama fonksiyonu	11
3.3.4.Aktivasyon fonksiyonu	11
3.3.5.Çıkış değeri	12
3.4.Yapay Sinir Ağının Özellikleri	12
3.5.Yapay Sinir Ağının Avantajları ve Dezavantajları	12
3.6.Yapay Sinir Ağının Kısa Tarihçesi	14
3.7.Yapay Sinir Ağı ile Geleneksel Algoritmaların Karşılaştırılması	15
3.8.Yapay Sinir Ağlarının Sınıflandırılması	17
3.8.1.Yapılarına göre yapay sinir ağları	17
3.8.1.1 İleri beslemeli yapay sinir ağları	17
3.8.1.2 Geri beslemeli yapay sinir ağlar	18
3.8.2.Öğrenme algoritmalarına göre yapay sinir ağları	18
3.8.2.1 Danışmanlı öğrenme yapay sinir ağları	18
3.8.2.2 Danışmansız öğrenme yapay sinir ağları	18
3.8.2.3 Destekleyici öğrenme yapay sinir ağları	19
3.8.3.Öğrenme zamanına göre yapay sinir ağları	19
3.8.3.1 Statik öğrenme yapay sinir ağları	19
3.8.3.2 Dinamik öğrenme yapay sinir ağı	19
4.MÜŞTERİ MEMNUNİYETİ ANALİZİ UYGULAMASI İÇİN YAPAY SİNİR AĞINDAKİ ALGORİTMA VE PARAMETRELERİN BELİRLENMESİ	21
4.1.Kullanılan Veri Seti	23
4.2.Evreler ve Küme Boyutu	24
4.3.Optimize Edici	26
4.4.Başlangıç Modu	29

4.5.Aktivasyon Fonksiyonu	30
4.6.Düşürme Oranı	32
4.7.Sinir Sayısı	33
4.8.Aynı Parametrelerle Gizli Katman Sayısının Arttırılması	35
4.8.1.2'li gizli katman modeli	35
4.8.2.3'lü gizli katman modeli	35
5.DAHA HIZLI VE PERFORMANSLI ÇALIŞMA YÖNTEMLERİ	37
6.GELECEKTE YAPILABİLECEK ÇALIŞMALAR	39
7.SONUÇ	41
KAYNAKLAR	45
ÖZ GEÇMİŞ	47

KISALTMALAR

YSA	: Yapay Sinir Ađı
Vb.	: Ve Benzeri
MCS	: Monte Carlos Similasyonu
FEA	: Finite Elements Analysis
LSF	: Lightweight Steel Frame
HVAC	: Heating, Ventilating and Air Conditioning

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 3.1: Bazı Toplama Fonksiyonları	11
Çizelge 4.1: Örnek Müşteri Memnuniyet Verisi	24
Çizelge 4.2: Evre Sayısı ve Küme Boyutu için Ortalama Doğruluk Oranı Sonuç Çizelgesi	25
Çizelge 4.3: Evre Sayısı ve Küme Boyutu için Standart Sapma Oranı Sonuç Çizelgesi	25
Çizelge 4.4: Optimizasyon Fonksiyonlarının Formülleri	27
Çizelge 4.5: Optimizasyon Yöntemler için Ortalama Doğruluk Oranı Sonuç Çizelgesi	27
Çizelge 4.6: Farklı Optimizasyon Yöntemleri için Ortalama Doğruluk ve Standart Sapma Oranı Sonuç Çizelgesi	28
Çizelge 4.7: Başlangıç Modu için Ortalama Doğruluk ve Standart Sapma Oranı Sonuç Çizelgesi	29
Çizelge 4.8: Aktivasyon Fonksiyonu Formülleri	31
Çizelge 4.9: Aktivasyon Fonksiyonları için Ortalama Doğruluk ve Standart Sapma Oranı Sonuç Çizelgesi	31
Çizelge 4.10: Düşürme Oranı için Ortalama Doğruluk ve Standart Sapma Oranı Sonuç Çizelgesi	32
Çizelge 4.11: Sınır Sayısı için Ortalama Doğruluk ve Standart Sapma Oranı Sonuç Çizelgesi	33

ŞEKİL LİSTESİ

Sayfa

Şekil 3.1: Yapay Sinir Ağı Hücresi	8
Şekil 3.2: Biyolojik Sinir Hücresi	9
Şekil 3.3: Yapay Sinir Ağı Blok Yapısı	10
Şekil 3.4: Yapay Sinir Ağı ile Geleneksel Algoritmaların Karşılaştırılması	17
Şekil 3.5: Yapay Sinir Ağlarının Sınıflandırılması	18
Şekil 4.1: Başlangıç Yapay Sinir Ağı Modeli	22
Şekil 4.2: Evre Sayısı ve Küme Boyutu için Ortalama Doğruluk Oranı Sonuç Grafiği	25
Şekil 4.3: Evre Sayısı ve Küme Boyutu için Standart Sapma Oranı Sonuç Grafiği	26
Şekil 4.4: Farklı Optimizasyon Yöntemleri için Ortalama Doğruluk Oranı Sonuç Grafiği	28
Şekil 4.5: Farklı Optimizasyon Yöntemleri için Ortalama Doğruluk Sonuç Grafiği	29
Şekil 4.6: Başlangıç Modu için Ortalama Doğruluk Sonuç Grafiği	30
Şekil 4.7: Aktivasyon Fonksiyonları için Ortalama Doğruluk Sonuç Grafiği	32
Şekil 4.8: Düşürme Oranı için Ortalama Doğruluk Sonuç Grafiği	33
Şekil 4.9: Sinir Sayısı için Ortalama Doğruluk Sonuç Grafiği	34
Şekil 7.1: Sonuç Yapay Sinir Ağı Modeli	43

YAPAY SINIR AĞI KULLANARAK MÜŞTERİ MEMNUNİYETİ ANALİZİ

ÖZET

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

CUSTOMER SATISFACTION ANALYSIS USING ARTIFICIAL NEURAL NETWORK

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 allows 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. In this paper, situations encountered in this application which is using an artificial.

Keywords: ANN, Artificial Neural Network, Customer Satisfaction

1. GİRİŞ

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 deęillerdir. Son yıllarda dięer 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 deęerleri arasında doğrusal bir bağlantı kurulamamasından dolayı dięer çoęu 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.

2. LİTERATÜR ÇALIŞMASI

Bu alanda birçok çalışma yapılmaktadır. En önemli çalışmalar incelendiği zaman birçoğunda aslında klasik makine öğrenmesi yöntemlerinin zorlandığı kısım olan insan duyu 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 birçoğunun 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).

Bu makale Yapay Sinir Ağı (YSA) modellerinin yapısal güvenilirlik analizinde geliştirilmesi ve kullanımı hakkında bir anket sunmaktadır. Anket, farklı YSA türlerini, tipik olarak kullanılan yapısal güvenilirlik değerlendirme yöntemlerini, YSA eğitim seti iyileştirmesi için önerilen teknikleri ve ayrıca YSA yaklaşımlarının yapısal tasarım ve optimizasyon problemlerine bazı uygulamalarını tanımlar. Daha sonra YSA modelleri, dikey giriş dikey bükülme momenti ile indüklenen tek eksenli sıkıştırma yüklerine maruz kalan tek eksenli sıkıştırma yüklerine maruz kalan bir gemi sertleştirilmiş panelinin güvenilirlik analizinde kullanılır; bunun için çökme mukavemeti doğrusal olmayan sonlu elemanlar analizi (FEA) ile elde edilir. Kabul edilen yaklaşımlar, uyarlamalı YSA modellerinin kullanımını, doğrudan limit durumu fonksiyonunu Monte Carlo simülasyonu (MCS), birinci dereceden güvenilirlik

yöntemleri ve MCS ile önem dereceli örnekleme (IS) ile güvenilirlik değerlendirmesi için kullanmak üzere birleştirmektedir. Farklı güvenilirlik yöntemleriyle ilgili tahminlerin YSA tabanlı LSF'lerle ve FEA ile bağlantılı klasik LSF değerlendirmesinin kapsamlı bir karşılaştırması sağlanmıştır (Chojaczyk, 2015).

Güneş radyasyonu verileri güneş enerjisi arařtırmalarında önemli bir rol oynamaktadır. Bu veriler meteorolojik bir istasyonun bulunmamasından dolayı ilgilenilen konum için mevcut deęil. Bu nedenle, güneş radyasyonu, çeşitli güneş radyasyonu tahmin modelleri kullanılarak bu konumlar için doęru bir şekilde tahmin edilmelidir. Bu çalışmanın amacı, literatürde güneş radyasyonu tahmini için uygun yöntemleri belirlemek ve araştırma boşluklarını tanımlamak için Yapay Sinir Aęı (YSA) bazlı teknikleri gözden geçirmektir. Çalışma Yapay Sinir Aęı tekniklerinin geleneksel yöntemlerle karşılaştırıldığında güneş ışınlarını daha doęru tahmin ettiğini gösteriyor. ANN modellerinin tahmin doęruluęunun girdi parametresine baęlı olduęu bulundu. Kombinasyonlar, eğitim algoritması ve mimari yapılandırmaları. Bu çalışmada, YSA teknięine dayalı metodolojilerdeki ileri araştırma alanları da tanımlanmıştır (Yadav, 2014).

Bina elektrik kullanımının kısa vadeli yük tahminleri, elektrik fiyatlandırmasının en yüksek enerji tüketimine göre dinamik olarak belirlendięi bir ortamda elektrik kullanım şekli ve bina enerji tüketiminin yönetimi üzerindeki anormallik tespiti için büyük önem taşımaktadır. Bu çalışmada, 15 dakikalık çözünürlükte binaların gün boyu elektrik kullanımı için veri odaklı bir tahmin modeli sunuyoruz. Deęişken önem analizi kullanarak, anahtar deęişkenleri seçtik: gün tipi göstergesi, günün saati, HVAC ayarlı sıcaklık programı, dış ortam kuru sıcaklık ampulü ve dış mekan nemlilięi, elektrik tüketimi için en önemli öngörücü olarak. Bu çalışma, Bayesian düzenleme algoritmasına sahip Yapay Sinir Aęı (YSA) modelini temel alan kısa vadeli bir bina enerji kullanımı tahmin modeli önermekte ve zaman gecikmesi, gizli nöron sayısı ve eğitim verisi gibi aę tasarım parametrelerinin model üzerinde nasıl bir etki yarattığını incelemektedir. yetenek ve genellik. Sonuçlar, adaptif eğitim yöntemlerine sahip önerilen modelin, 15 dakikalık zaman aralıklarında elektrik tüketimini ve günlük binaların en yüksek elektrik kullanımını, ticari bir bina kompleksinin bir test durumunda oldukça iyi bir şekilde tahmin edebildiğini göstermektedir (Yao, 1999).

3. YAPAY SİNİR AĞI

3.1 Yapay Sinir Ağı Nedir?

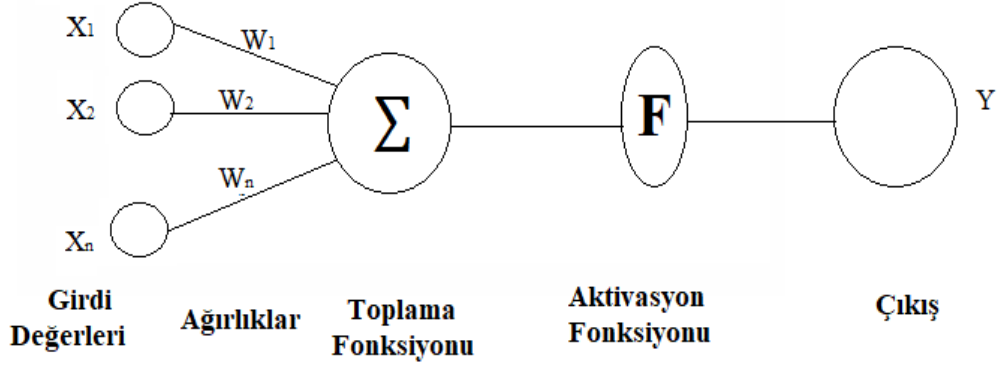
Yapay Sinir Ağları, beynin sinir yapısına dayanan nispeten ham elektronik modellerdir. Yapay sinir ağı kendi kendine öğrenme özelliğine sahip sistemlerdir. Beyin temel olarak deneyimden öğrenir. Mevcut bilgisayarların kapsamı dışındaki bazı sorunların küçük enerji tasarruflu paketler tarafından çözülebildiğinin kanıtı doğaldır. Bu beyin modellemesi ayrıca makine çözümleri geliştirmek için daha az teknik bir yol vaat ediyor. Bilgi işlem için bu yeni yaklaşım aynı zamanda sistem aşırı yüklemesi sırasında daha geleneksel emsallerinden daha zarif bir bozulma sağlar.

Bu biyolojik olarak ilham almış hesaplama yöntemlerinin bilgisayar endüstrisindeki bir sonraki önemli gelişme olduğu düşünülmektedir. Basit hayvan beyinleri bile, şu anda bilgisayarlar için imkânsız olan işlevlere sahiptir. Bilgisayarlar, defter tutmak veya karmaşık matematik yapmak gibi şeyleri çok iyi yutuyor. Ancak bilgisayarlar, geçmiş kalıpları geleceğin eylemlerine daha da genelleştirmekten çok daha az basit kalıpları bile tanımakta zorlanıyor.

Şimdi, biyolojik araştırmalardaki gelişmeler, doğal düşünce mekanizmasının ilk anlayışını vaat ediyor. Bu araştırma, beyinlerin bilgiyi kalıp olarak sakladığını göstermektedir. Bu kalıpların bazıları çok karmaşıktır ve bireysel yüzleri farklı açılardan tanıyabilmemize izin verir. Bilgiyi kalıp olarak saklama, bu kalıpları kullanma ve sonra problemleri çözmeye işleminde bilgi işlemde yeni bir alan var. Daha önce de belirtildiği gibi, bu alan geleneksel programlamayı kullanmaz, ancak büyük ölçüde paralel ağların oluşturulmasını ve bu ağların belirli problemlerin çözümü için eğitilmesini içerir. Bu alan aynı zamanda geleneksel bilgisayarlardan çok farklı kelimeler kullanır, davranır, tepki verir, kendi kendini organize eder, öğrenir, genelleştirir ve unuttur.

Teknik açıdan bakacak olursak yapay sinir ağının görevi, girdi seti olarak kendisine verilen bilgilere karşılık bir çıktı üretebilmektir. Bunun yapılabilmesi için ağa veri

setinin belirli bir kısmı kullanılarak eğitilir. Sonra ağ bu örnekler sayesinde genelleme yapabilecek ve karar verebilecek seviyeye gelir. Daha sonra bu yöntem sayesinde çıktıları oluşturur.




Şekil 3.1: Yapay Sinir Ağı Hücresi

YSA'ları bir kara kutu gibi tanımlanabilir. Çünkü bir hiyerarşik yapı kullanılarak giriş değerlerinden bir çıkış değerleri üretilir. Bu işlemin gerçekleştiği kara kutu dediğimiz kısmın matematiksel olarak tam bir karşılığı bulunmamaktadır.

3.2 Biyolojik Sinir Hücresi

Biyolojik sinir hücresi; bir gövde, bir akson, çok sayıda dendrit ve sinaps olmak üzere dört bölümden oluşmaktadır. Dendritler gelen sinyalleri sinir hücresi çekirdeğine iletir. Çekirdek gelen sinyallerin hepsini toplayarak aksona iletir. Akson toplanan bu sinyallerin hepsini işler ve sonrasında işlenen bu sinyalleri sinapslara gönderir. Sinapsler ise kendilerine iletilen işlenmiş sinyalleri diğer sinir hücrelerine iletir. Gerçek biyolojik sinir hücreleri örnek alınarak yapay sinir ağı hücreleri oluşturulmuştur.



Şekil 3.2: Biyolojik Sinir Hücresi

3.3 Yapay Sinir Ağının Yapısı

Yapay sinir ağları yapısal olarak biyolojik sinir ağlarına benzemektedir. Yapay nöronlarda kendi aralarında bağ kurarak yapay sinir ağlarını oluşturmaktadır. Bu yapay sinir ağları da veri girişi, veri işleme ve veri çıkışı şeklinde çalışmaktadır. Bir yapay sinir ağı beş bölümden oluşmaktadır. Bunlar:

- Girdi Değerleri
- Ağırlıklar
- Toplama Fonksiyonu
- Aktivasyon Fonksiyonu
- Çıkış Değeri



Şekil 3.3: Yapay Sinir Ağ Yapısı Blok Gösterimi

3.3.1 Girdi değerleri

Girdi değerini biyolojik sinir ağında dendritler tarafından toplanan veriler olarak tanımlayabiliriz. Bu değerler dış dünyadan gelebileceği gibi aynı zaman da bir nöronun diğerine aktarılan bir veri de olabilmektedir.

3.3.2 Ağırlıklar

Bu bölümde giriş değerlerinden gelen veriler hücre çekirdeğine aktarılmadan ağırlık değerleri ile çarpılmaktadır. Bu sayede girdi değerlerinin çıkış değerlerine etkisini ayarlamaktadır. Ağırlık değerleri pozitif, negatif ve sıfır değerleri olabilmektedir. Eğer ağırlık değeri sıfır verilen bir girdi değeri var ise bu değerın çıkışa herhangi bir etkisi olmayacaktır.

3.3.3 Toplama fonksiyonu

Bu kısımda ağırlık değerleri ile çarpılan giriş değerleri nöronlara aktarılmadan önce toplayarak o nörona gidecek olan toplan giriş değerini hesaplamaktadır. Girdi değerlerini X ve ağırlık değerlerini W olarak adlandıracak olursak N tane girdiyi bu fonksiyona göre aşağıdaki gibi tanımlayabiliriz.

$$= \sum_{k=1}^N X_k W_k$$

Toplama fonksiyonu yerine kullanılabilir bazı fonksiyon çeşitleri de vardır. Bu fonksiyon çeşitlerinin en sık kullanılan bir kısmını aşağıdaki çizelge de yer almaktadır.

Çizelge 3.1: Bazı Toplama Fonksiyonları

Fonksiyon	Formül
Toplam	$= \sum_{k=1}^N X_k W_k$
Çarpım	$= \prod_{k=1}^N X_k W_k$
Maksimum	$= \text{Max}(X_k W_k)$
Minimum	$= \text{Min}(X_k W_k)$
Çoğunluk	$= \sum_{k=1}^N \text{Sgn}(X_k W_k)$
Kümülatif Toplam	$= \text{Net}(\text{Eski}) + \sum_{k=1}^N X_k W_k$

3.3.4 Aktivasyon fonksiyonu

Toplama fonksiyonundan çıkan toplam giriş değerlerini nörondan çıkacak olan çıkış değerlerine dönüştürebilmek için aktivasyon fonksiyonları kullanılmaktadır. Burada kullanılacak aktivasyon fonksiyonu doğrusal olmayan bir fonksiyon seçilmelidir. Bunun fonksiyon seçimi ise YSA'ların genel bir özelliği olan "Doğrusal Olmama" özelliğinden gelmektedir. Eğer geri beslemeli bir yapay sinir ağı kullanılacak ise burada türevi alınabilecek bir aktivasyon fonksiyonu seçilmelidir. Bunun sebebi ise bu sinir ağında aktivasyon fonksiyonunun türevi de kullanıldığı için hesaplama işleminin yavaşlamasını engellemektir.

3.3.5 Çıkış değeri

Bu aşamada aktivasyon fonksiyonuna gönderilen değerlerin sonucuyla oluşan değerlerdir. Burada oluşan değerler isteğe göre dış dünyaya verilebilir ya da tekrardan yeni bir nörona aktarılarak bu süreç tekrarlanabilir.

3.4 Yapay Sinir Ağının Özellikleri

Yapay sinir ağları birçok alanda başarılı çözümler sağlamıştır. Bu başarıları sağlarken birçok özelliğinden faydalanılmaktadır. Bu özellikler sıralanacak olunursa:

- Yapay sinir ağı kullanılmaya başlanılmadan önce eğitilmesi ve test edilmesi gerekmektedir. Yapılmış olan örnekleri incelediğimiz zaman veri setlerinin test ve eğitim verisi olmak üzere iki parçaya ayrılmaktadır. Yapılan eğitimin kabul edilebilmesi için ayrılan eğitim kümesi ile ağı eğitilir ve ağın bütün örneklerle yüksek oranda doğru cevaplar vermeye başlamış olmalıdır. Daha önceden eğitim kümesinde yer almayan verilerden oluşan test kümesi verileri, YSA tarafından kabul edilebilir bir seviyede doğru cevaplar veriyorsa yapay sinir ağının performansı iyi kabul edilmektedir ve kullanıma alınır.
- YSA ağında bir hata meydana geldiği zaman tüm ağ birden bire bozulma yaşamaz bozulma derecesine göre kademe kademe bozulma gerçekleşir.
- Hata toleransı yüksektir.
- Eksik bilgi ile de çalışmasına devam edebilir.
- Sadece veri setleri üzerinde değil görüntü, ses vb. setler üzerinde de çalışabilir ve bunlar arasında sınıflandırma ve ilişkilendirme yapabilir.
- Dağınık belleğe sahip olmakla birlikte bilgi tüm ağı gezmektedir.
- Sistem çalıştırıldığı sırada test ve eğitim veri setinde yer almayan farklı bir veri hakkında yorumlama yaparak sonuç verebilir.
- Her bir YSA giriş ve çıkış değerlerine göre eğitilir.

3.5 Yapay Sinir Ağının 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 gerçekleştirebilmesi 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.

3.6 Yapay Sinir Ağının Kısa Tarihçesi

İlk yapay sinir ağı bilim adamı Walter Pitts ve bir nörolog olan Warren McCulloch tarafından elektrik devreleri kullanarak insan beyninin hesaplama yapma yeteneğinden esinlenilerek 1943 yılında başlamıştır.

Hebb tarafından geliştirilen 1949 yılında “Davranış Organizasyonu” adlı kitabında konu edindiği öğrenme ile ilgili temel teori kuralı Hebbian öğrenme kuralı olarak anlandırılmaktadır. Geliştirilen bu kural YSA’nın bağlantı sayısı değiştirildiğinde öğrenmenin olabileceği fark edilmiştir (Öztemel, 2006).

1954 yılında Rassel ağlar ve Adaptif tepki üretme terimlerini ortaya koyan Farley ve Clark 1958 yılında bu kavram Rosenblatt ve 1961 yılında ise Cainiello tarafından geliştirilmiştir (Kargı V, 2015).

Tanıma amacıyla geliştirilen ve eğitilebilen tek katmanlı, tek çıkışa hakim olan bir yapay sinir ağı 1958 yılında Rosenblatt tarafında geliştirilerek “Perceptron” adı verilmiştir. Bu yapı daha da geliştirilerek çok katmanlı sinir ağlarının temelini oluşturan devrim niteliğinde ki bir çalışma olarak kabul edilmektedir (Yücesoy M, 2011).

Widrow ve Hoff tarafından 1959 yılında geliştirilen Adaptive Linear Nueron modeli YSA’nın mühendislik uygulamalarında kullanılmasına başlanmasında atılan ilk adım olmuştur. ADALINE modelinin çok katmanlı bir hali olarak MADALINE 1970’li yılların sonunda çıkmıştır (Öztemel, 2016). MADALINE modeli daha sonralar da telefon hatlarında meydana gelen yankıları ortadan kaldırmak için kullanılmıştır.

1960 yıllarında algılayıcıların doğrusal olmayan problemlere çözüm sağlayamadıklarını “Perceptrons” adlı kitaplarında ortaya koyan matematikçi Minsky ve Papert yapay sinir ağının XOR problemini çözemediğini kanıtladılar. Bundan dolayı yapay sinir ağlarına olan güven azalarak yatırımlar da kesilmiştir.

Bu süreç 1982 yılına kadar devam etmiştir ve tekli algılayıcılarla çözülemeyen XOR problemlerini Hopfield çok katmanlı algılayıcıları kullanarak çözmeyi başarmıştır. Bu gelişme ile birlikte YSA’ya olan güven tekrar geri gelmiştir.

1986 yılına gelindiğinde Rumelhart arkadaşları ile birlikte yapay sinir ağında yaygın olarak kullanılan geriye yayılma algoritmasını geliştirmişlerdir. Geriye yayılım algoritması ile tek katmanlı ağların çözmeyi başaramadığı XOR problemlerini çözmeyi başarmışlardır.

1988 tarihinde Broomhead ve Lowe tarafından geliştirilen RDF (Radyal tabanlı fonksiyonlar) modeli çok katmanlı algılayıcılara alternatif bir ağ olmuştur. Filtreleme ve veri sıkıştırma problemlerinin çözümünde daha sık kullanılmaktadır.

1990’da Olasılıksal Sinir Ağlarını (Probabilistic Nueal Network - PNN) geliştiren Spetch, radyal tabanlı fonksiyonların daha gelişmiş olarak çıkmıştır. 1991 yılında ise bunun da daha gelişmiş olan RNN (Genelleştirilmiş Regresyon Ağlarını) geliştirmiştir.

İlerleyen sürelerde yapay sinir ağlarını mühendislik ve fen alanları başta olmak üzere finans, tıp, fizik, ekonomi vb. birçok sektörde uygulanmaya başlanmış ve uygulanmaya da devam etmektedir.

3.7 Yapay Sinir Ağı ile Geleneksel Algoritmaların Karşılaştırılması

Yapay sinir ağları ile geleneksel algoritmalar arasında büyük farklar vardır. Bu farklar kimi zaman avantaj sağlarken kimi zaman da tam tersi şekilde dezavantaj sağlamaktadır. Bundan dolayı ihtiyaç doğrultusunda yapay sinir ağının mı yoksa geleneksel algoritmaların mı kullanılacağına iyi karar verilmesi gerekmektedir.

Aşağıdaki şekilde yapay sinir ağı ile geleneksel algoritmaların karşılaştırılması sonucu birbirinden farklı olan özellikleri sıralanmıştır. Bu şekildeki farklılıklar göz önünde bulundurularak yapılacak olan çalışmada hangi yöntemin kullanılacağına karar verilmelidir.

Yapay sinir ađı

Öđrenme esasına bađlı olarak giriř ve ıkıř bilgileri verilerek kurallar oluřturulur.

Öđrenme iřlemi toplu, eř zamansız ve öđrenmeden sonra paraleldir.

Bellek ayrılmıř ve ađa paraleldir.

Hata toleransı vardır.

Yavař ve donanım bađımlıdır.

Deneyimden yararlanır.

Geleneksel Algoritmalar

ıkıřlar giriř deđerlerine kurulan kuralların uygulanması ile oluřturulur.

Öđrenme iřlemi merkezi, eř zamanlı ve ardıřıldır.

Bellek paketlenmiř ve hazır bilgi depolanmıřtır.

Hata toleransı yoktur.

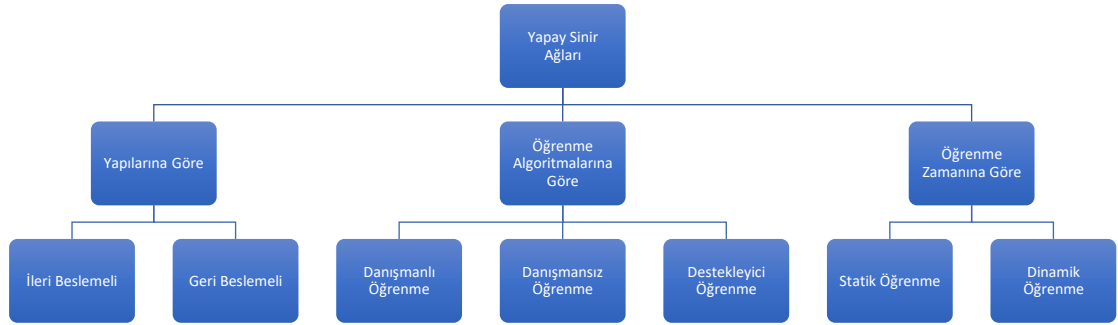
Nispeten hızlıdır.

Bilgiler ve algoritmalar kesindir.

řekil 3.4: Yapay Sinir Ađı ile Geleneksel Algoritmaların Karřılařtırılması

3.8 Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları birbirlerine işleyiş olarak benzer olsalar da herhangi bir işleyiş ve tasarım standardı bulunmamaktadır. Nöron ağırlıklarının düzenlenesi için yapılan hesaplama işlemi çeşidine, dizilmesi ve zamanına göre YSA'lar üç ayrı kategoriye ayrırabiliriz.



Şekil 3.5: Yapay Sinir Ağlarının Sınıflandırılması

3.8.1 Yapılarına göre yapay sinir ağları

Yapay sinir ağları nöronlarının birbirlerine bağlantı şekillerine göre ikiye ayrılmaktadır.

3.8.1.1 İleri beslemeli yapay sinir ağları

İleri beslemeli ağlardaki tüm nöronların yapısı girişten çıkışa doğru düzenli katmanlar şeklindedir. Bir katmandan sadece kendinden sonraki katmana bağ bulundurmaktadır. Yapay sinir ağına gelen bilgi ilk başta giriş katmanına daha sonra ara katmanlara en sonda çıkış katmanına giderek bu süreci tamamladıktan sonra yapay sinir ağından çıkar.

3.8.1.2 Geri beslemeli yapay sinir ađlar

Geri beslemeli yapay sinir ađları ileri beslemeli yapay sinir ađlarındaki gibi sadece kendinden sonraki gelen ara katmanlara deđil kendinden önceki hatta kendi katmanında yer alan herhangi bir nörona da bilgi aktarabilmektedir. Bu yapısından dolayı geri beslemeli yapay sinir ađları doğrusal olmayan bir davranış sergilemektedir.

3.8.2 Öğrenme algoritmalarına göre yapay sinir ađları

Yapay sinir ađlarında giriş verilerinden çıkış verilerinin üretilmesini sağlayan yöntem ađın öğrenmesidir. Bu öğrenme işlemi içinde birden fazla yöntem bulunmaktadır. Yapay sinir ađları öğrenme algoritma yöntemlerine göre üçe ayrılır.

3.8.2.1 Danışmanlı öğrenme yapay sinir ađları

Danışmanlı öğrenme yapay sinir ađı yapılarında sisteme öğretme işlemi yapılacağı zaman giriş bilgileri ile birlikte çıkış bilgileri de sisteme verilir. Yapay sinir ađı giriş deđerleri için verilen çıkış deđerlerini oluşturabilmek için nöronlar arasındaki ađırlık deđerlerini kendi günceller. Ađın çıktısında yer alan deđerler ile olması gereken deđer arasındaki hata hesaplanarak hata payına göre ađdaki ađırlık deđerleri güncellenmektedir.

Hata oranı hesaplama işlemi tüm veri girişleri için alınan sonuçlar tamamlandıktan sonra yapılarak her bir nörona düşen hata oranları belirlenir ve her nöron kendi hata oranına göre kendi ađırlık deđerini güncellemektedir.

3.8.2.2 Danışmansız öğrenme yapay sinir ađları

Danışmansız öğrenme yapay sinir ađlarında danışmanlı öğrenme yapay sinir ađlarına göre sistem eğitilirken giriş verileri ile birlikte bu verilerin çıkış deđerleri de sisteme verilmemektedir. Girişte verilen bilgilere göre yapay sinir ađı her bir veri örneğini kendi arasında sınıflandıracak şekilde kendi kurallarını oluşturur. Yapay sinir ađı bağlantı ađırlıklarını aynı özellikte olan dokuları kendi aralarında ayırabilecek şekilde düzenleyerek öğrenme işlemini tamamlamaktadır.

3.8.2.3 Destekleyici öğrenme yapay sinir ağıları

Destekleyici öğrenme yapay sinir ağılarında öğrenme yaklaşımı sırasında ağın her iterasyonu sonucunda elde ettiği sonucun iyi veya kötü olup olmadığına dair bilgi vermektedir. Bu bilgilere göre ağ kendini yeniden düzenler. Ağ bu sayede herhangi bir girdi dizisi ile hem öğrenmektedir hem de sonuç çıkararak işlemine devam etmektedir.

3.8.3 Öğrenme zamanına göre yapay sinir ağıları

Yapay sinir ağıları öğrenme zamanına göre ikiye ayrılmaktadır.

3.8.3.1 Statik öğrenme yapay sinir ağıları

Statik öğrenme yapay sinir ağılarında sistem kullanılmadan önce eğitilmektedir. Eğitimi tamamladıktan sonra ağ istenilen şekilde kullanılabilir. Yapay sinir ağı eğitimi tamamladıktan sonra istenildiği şekilde kullanılabilir ve bu sırada ağın üzerinde ki hiçbir ağırlık değerinde değişiklik yapılmaz.

3.8.3.2 Dinamik öğrenme yapay sinir ağı

Dinamik öğrenme yapay sinir ağında ise ağı çalıştığı süre boyunca öğrenmesini ön görerek tasarlanmıştır. Bu yapay sinir ağında eğitim işlemi tamamlandıktan sonra ki her çalıştırmada da çıkan sonucun onaylanması ile bu veri ve sonucu da ağırlıkların değişmesini etkileyerek sürece devam etmektedir.


4. MÜŞTERİ MEMNUNİYETİ ANALİZİ UYGULAMASI İÇİN YAPAY SİNİR AĞINDAKİ ALGORİTMA VE PARAMETRELERİN BELİRLENMESİ

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 6'da yer alan yapay sinir ağı modeli kullanılmıştır.



Şekil 4.1: 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)

4.1 Kullanılan Veri Seti

Bu çalışmada kullanılan örnek veri seti her bir müşteri için 14 tane bilginin yer aldığı ve toplamda 10.000 tane müşteri bilgisinden oluşmaktadır. Müşterilerin yer alan bilgileri aşağıdaki gibi sıralayabiliriz.

- Satır numarası
- Müşteri kimliği
- Soyadı
- Kredi notu
- Coğrafyası
- Cinsiyet
- Yaş
- Görev süresi
- Bakiyesi
- Kullandığı ürün sayısı
- Kredi kartı var mı
- Aktif bir üye mi
- Tahmini maaş
- Bankadan ayrıldı mı

Bu özelliklerden Satır numarası, Müşteri kimliği ve Soyadı bilgilerini veri setimizi sisteme yükler iken sonuca etki etmeyeceği için veri setimizi ayarlarken bu kolonları almayacak şekilde kullanmamız gerekecektir.

Bu durumda yüklediğimiz veri setinden Kredi notu, Coğrafya, Cinsiyet, Yaş, Görev süresi, Bakiyesi, Kullandığı ürün sayısı, Kredi kartı var mı, Aktif bir üye mi, ve Tahmini maaş bilgilerini sistemimizi eğitirken kullanacağız. Bankadan ayrıldı mı bilgisi ise bu bilgiler ile elde etmemiz gereken sonuç değeri olacaktır.

Veri setinde yer alan ilk yirmi müşteri bilgisi çizelge 4.1 de verilmiştir.

Çizelge 4.1: Örnek Müşteri Memnuniyet Verisi

1	15634602	Hargrave	619	France	Female	42	2	0	1	1	1	101348.88	1
2	15647311	Hill	608	Spain	Female	41	1	83807.86	1	0	1	112542.58	0
3	15619304	Onio	502	France	Female	42	8	159660.8	3	1	0	113931.57	1
4	15701354	Boni	699	France	Female	39	1	0	2	0	0	93826.63	0
5	15737888	Mitchell	850	Spain	Female	43	2	125510.82	1	1	1	79084.1	0
6	15574012	Chu	645	Spain	Male	44	8	113755.78	2	1	0	149756.71	1
7	15592531	Bartlett	822	France	Male	50	7	0	2	1	1	10062.8	0
8	15656148	Obinna	376	Germany	Female	29	4	115046.74	4	1	0	119346.88	1
9	15792365	Heydi	501	France	Male	44	4	142051.07	2	0	1	74940.5	0
10	15592389	Holl	684	France	Male	27	2	134603.88	1	1	1	71725.73	0
11	15767821	Bearce	528	France	Male	31	6	102016.72	2	0	0	80181.12	0
12	15737173	Andrews	497	Spain	Male	24	3	0	2	1	0	76390.01	0
13	15632264	Kay	476	France	Female	34	10	0	2	1	0	26260.98	0
14	15691483	Chin	549	France	Female	25	5	0	2	0	0	190857.79	0
15	15600882	Scott	635	Spain	Female	35	7	0	2	1	1	65951.65	0
16	15643966	Goforth	616	Germany	Male	45	3	143129.41	2	0	1	64327.26	0
17	15737452	Romeo	653	Germany	Male	58	1	132602.88	1	1	0	5097.67	1
18	15788218	Henderson	549	Spain	Female	24	9	0	2	1	1	14406.41	0
19	15661507	Muldrow	587	Spain	Male	45	6	0	1	0	0	158684.81	0
20	15568982	Hao	726	France	Female	24	6	0	2	1	1	54724.03	0

4.2 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:

Çizelge 4.2: Evre Sayısı ve Küme Boyutu için Ortalama Doğruluk Oranı Sonuç Çizelgesi

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

Standart sapma oranı için:

Çizelge 4.3: Evre Sayısı ve Küme Boyutu için Standart Sapma Oranı Sonuç Çizelgesi

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 4.3: 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.

4.3 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), 'Adadelat' (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 çizelge 4.4'te özetlenmiştir.


Çizelge 4.4: Optimizasyon Fonksiyonlarının Formülleri

Optimizer	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 (Adadelata)	$\Delta x_t = -\frac{\eta}{\text{RMS}[g]_t} g_t$
Adaptive Moment Estimation (Adam)	$w^{(t+1)} \leftarrow w^{(t)} - \eta \frac{\tilde{m}_w}{\sqrt{\hat{v}_w + \epsilon}}$
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 Çizelge 4.6 ve Şekil 10'da verilmiştir.

Çizelge 4.5: Optimizasyon Yöntemler için Ortalama Doğruluk Oranı Sonuç Çizelgesi

Optimizer	Ortalama Doğruluk Oranı	Standart Sapma Oranı
SGD	0.796	0.003
RMSprop	0.839	0.011
Adagrad	0.814	0.015
Adadelata	0.850	0.009
Adam	0.830	0.003
Adamax	0.837	0.009
Nadam	0.843	0.007




Şekil 4.4: 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.

Çizelge 4.6: Farklı Optimizasyon Yöntemleri için Ortalama Doğruluk ve Standart Sapma Oran Sonuç Çizelgesi

Optimizasyon Yöntemi	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 4.5 Farklı Optimizasyon Yöntemleri için Ortalama Doğruluk Sonuç Grafiği
Bu durumdan da görüleceği üzere parametre değişkenleri arasında bir doğrusal yapıdan bahsedilememektedir.

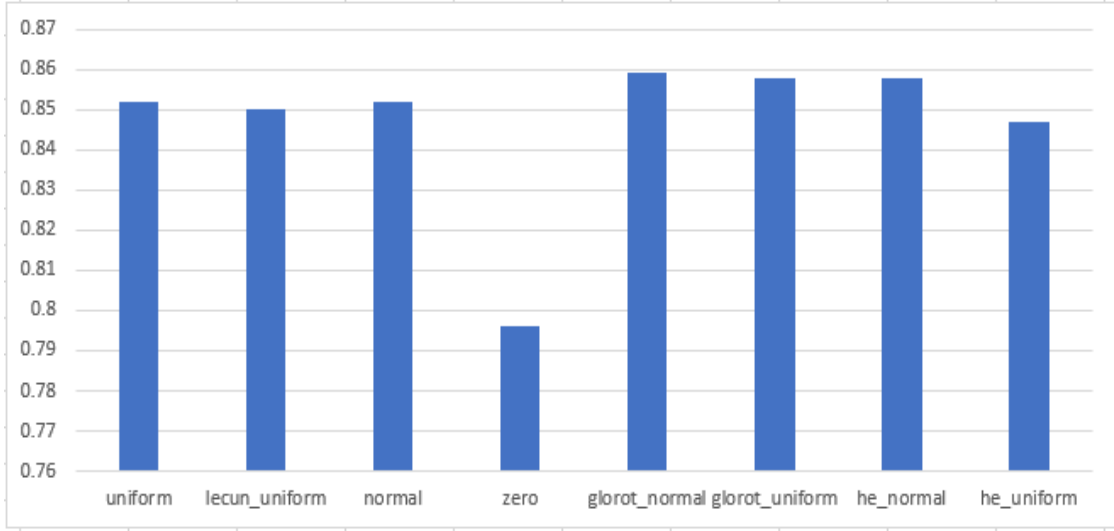
4.4 Başlangıç Modu

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.

Çizelge 4.7: Başlangıç Modu için Ortalama Doğruluk ve Standart Sapma Oran Sonuç Çizelgesi

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 4.6: 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.

4.5 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 Çizelge 4.8'de verilmiştir.

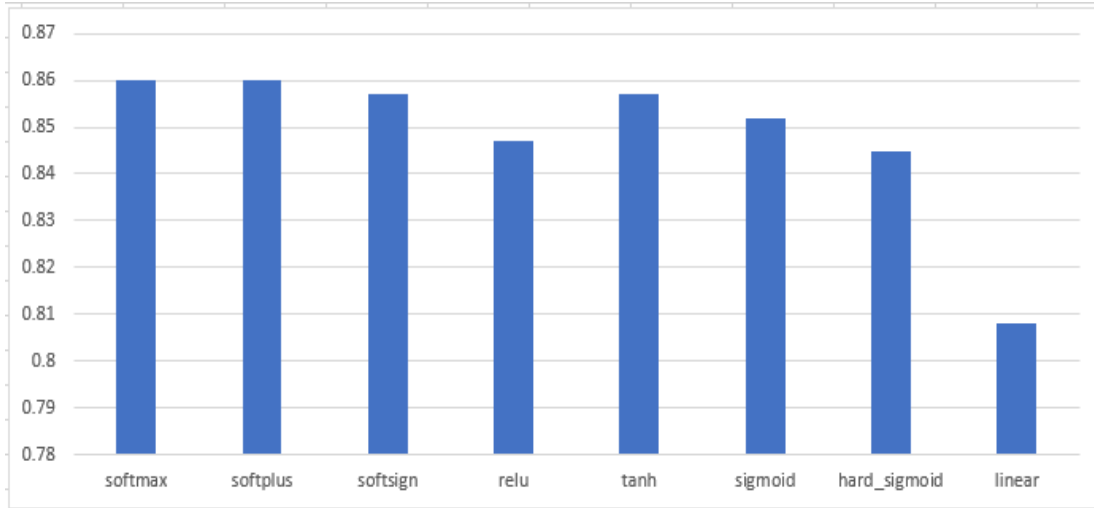
Çizelge 4.8: Aktivasyon Fonksiyonu Formülleri

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	$\varsigma_\alpha(x) = \frac{1}{1 + e^{-\alpha x}} = \frac{\tanh(\alpha x/2) + 1}{2}$
hard_sigmoid	$\max(0, \min(1, x))$

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

Çizelge 4.9: Aktivasyon Fonksiyonları için Ortalama Doğruluk ve Standart Sapma Oran Sonuç Çizelgesi

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 4.7: Aktivasyon Fonksiyonları için Ortalama Doğruluk Sonuç Grafiği


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

4.6 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.

Çizelge 4.10: Düşürme Oranı için Ortalama Doğruluk ve Standart Sapma Oran Sonuç Çizelgesi

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 4.8: Düşürme Oranı için Ortalama Doğruluk Sonuç Grafiği


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

4.7 Sınır 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.

Çizelge 4.11: Sınır Sayısı için Ortalama Doğruluk ve Standart Sapma Oran Sonuç Çizelgesi

Sınırlar	Ortalama Doğruluk Oranı	Standart Sapma Oranı
1	0.796	0.003
5	0.851	0.013
10	0.860	0.0010
15	0.860	0.0007
20	0.858	0.001
25	0.860	0.0001
30	0.852	0.008



Şekil 4.9: 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 arttırabilir 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.

4.8 Aynı Parametrelerle Gizli Katman Sayısının Arttırılması

Çalışma yapılırken var olan model ve veri seti için daha iyi sonuçlar alınabilmesini sağlamak için parametrelerinin en iyi seçimlerinin nasıl yapılacağından ve bu tercihlerin sonuçları nasıl etkilediğinden bahsettik. Bundan dolayı modeldeki var olan katman sayısı üzerinde herhangi bir değişiklik yapılmadı.

Model üzerinde bulunan gizli katman sayısını arttırarak aynı parametre ve veri seti ile aşağıdaki sonuçlar elde edilmiştir.

4.8.1 2’li gizli katman modeli

Var olan yapay sinir ağı modelimizde gizli katman sayısını ikiye çıkarıldığı zaman son on denemede aşağıdaki başarı oranları sağlanmış oldu.

- 0.86
- 0.858
- 0.859
- 0.8575
- 0.8585
- 0.8595
- 0.862
- 0.86
- 0.8595
- 0.857

Bu sonuçların ortalama değeri de 0.8591 olarak bulunmaktadır.

4.8.2 3’lü gizli katman modeli

Var olan yapay sinir ağı modelimizde gizli katman sayısını üçe çıkarıldığı zaman son on denemede aşağıdaki başarı oranları sağlanmış oldu.

- 0.7975
- 0.7975
- 0.7975
- 0.7975
- 0.7975
- 0.7975

- 0.7975
- 0.7975
- 0.7975
- 0.7975

Bu sonuçlardan da görüldüğü üzere başarı oranı değişmemektedir ve başarı oranı 0.7975 olarak gelmektedir.

Bu sonuçlardan yola çıkılacak olunursa gizli katmanın tek katmandan oluşması daha iyi sonuç verdiğini görmekteyiz.

5. DAHA HIZLI VE PERFORMANSLI ÇALIŞMA YÖNTEMLERİ

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.

6. GELECEKTE YAPILABİLECEK ÇALIŞMALAR

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 kullanılabilir bir yapıya getirilebilir bir çalışma da gerçekleştirilebilir.

7. 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. Bu sonuçların ortalama değerine de 0.86385 olarak ulaşmaktayız.

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
- Gizli Katman Sayısı : 1

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 7.1: 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 yapabilmeyen pek mümkün olmadığı görülmektedir.

KAYNAKLAR

- [1]. **Basheer, I. ve Hajmeer, M. (2000).** Artificial neural networks: fundamentals, computing, design, and application.
- [2]. **Bishop, C. (2006).** Pattern Recognition and Machine Learning.
- [3]. **Chung, H., Lee, S. ve Park, J. (2016).** Deep neural network using trainable activation functions
- [4]. **Chae, Y.T., Horesh, R., Hwang, Y., Lee, Y.M. (2016).** Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings
- [5]. **Chojaczyk, A.A., Teixeira, A.P., Neves, Luís C., Cardoso, J.B. and Soares, C. Guedes. (2015).** Review and application of Artificial Neural Networks models in reliability analysis of steel structures. Structural Safety, 52 (A). pp. 78-89. ISSN 0167-4730.
- [6]. **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.
- [7]. **Diederik, K. ve Ba, J. (2014).** Adam: A method for stochastic optimization.
- [8]. **Dozat, T. (2016).** Incorporating Nesterov momentum into Adam.
- [9]. **Duchi, J., Hazan, E. ve Singer, Y. (2011).** Adaptive subgradient methods for online learning and stochastic optimization.
- [10]. **Kargı, V. (2015).** Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama, Ekin Yayınevi
- [11]. **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.
- [12]. **Mei, S. (2018).** A Mean Field View of the Landscape of Two-Layer Neural Networks, Proceedings of the National Academy of Sciences.
- [13]. **Öztemel, Ercan (2006).** Yapay Sinir Ağları. İstanbul: Papatya Yayıncılık
- [14]. **Park, D., Elsharkawi, M., Marks, R., Atlas, L. ve Damborg, M. (1991).** Electric-Load Forecasting Using An Artificial Neural Network.
- [15]. **Rowley, H., Baluja, S. ve Kanade, T. (1998).** Neural network-based face detection.
- [16]. **Schmidhuber, J. (2015).** Deep learning in neural networks: An overview.
- [17]. **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.

- [18]. **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.
- [19]. **Yaday, A. K., Chandel, S. S., (2014)**. Solar radiation prediction using Artificial Neural Network techniques: A review.
- [20]. **Yao, X. (1999)**. Evolving artificial neural networks.
- [21]. **Yücesoy, M. (2011)**. Temizlik Sektöründe Yapay Sinir Ağları ile Talep Tahmini, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- [22]. **Zeiler, M. (2012)**. ADADELTA: An adaptive learning rate method.

İNTERNET KAYNAKLARI

- [1]. **Akin E. (2018)**. Yapay Sinir Ağları – Artificial Neural Network (ANN). Alındığı Tarih : 18.03.2019, Adres: <http://cagriemreakin.com/veri-bilimi/deep-learning/ann.html>

ÖZ GEÇMİŞ



Ad -Soyad: Yunus Emre Araç

Doğum Tarihi ve Yeri: 1991, Diyarbakır

E-Posta: yunusemrearac@hotmail.com

ÖĞRENİM DURUMU:

- **Lisans:** 2015, İnönü Üniversitesi, Bilgisayar Mühendisliği
- **Yüksek Lisans:** Devam etmektedir, İstanbul Aydın Üniversitesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİMLER:

- **06.2012 – 07.2012:** Dsmart – Staj
- **07.2012 – 08.2012:** Microsoft – Staj
- **02.2014 – 02.2015:** Ceviz Bilgi Teknolojileri – Yazılım Geliştirici
- **06.2015 – 09. 2016:** Simternet Teknoloji – Yazılım Geliştirici
- **09.2016 - Devam :** Nuevo Softwarehouse - Kıdemli Yazılım Geliştirici