



Yemekhane için Yapay Zekâ Teknikleri Kullanımı ile Günlük Talep Tahmini

Fatih KILIÇ^{1*}, Murat Reis AKKAYA², Nuran MEMİLİ³

¹Adana Bilim ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Adana, Türkiye

²Adana Bilim ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Gıda Mühendisliği, Adana, Türkiye

³Adana Bilim ve Teknoloji Üniversitesi, Rektörlük, Adana, Türkiye

fkilic@adanabtu.edu.tr, mraakkaya@adanabtu.edu.tr, nmemili@adanabtu.edu.tr

(İlk Geliş Tarihi 22 Şubat 2018 ve Kabul Tarihi 2 Ağustos 2018)

(DOI: 10.31590/ejosat.397549)

Öz

Günümüzde birçok kurum personel yemek hizmetlerini dış alım metoduyla profesyonel yemek şirketlerden temin etmektedir. Bu hizmet karşılığı yemek şirketlerine talep ettikleri yemek miktarı kadar ücret ödemektedirler. Yemeklerin cinsine, çıktığı güne, şirket çalışanlarının davranışlarına ve çalışan sayısına göre günlük tüketim miktarı değişmesine rağmen çoğu kurum kişisel tahminlerle karar vermekte ve israf olmaktadır. Bu çalışmada bir üniversite yemekhane sisteminden alınan veriler WEKA açık kaynak kodlu yazılımı vasıtasıyla Yapay Sinir Ağı, Destek Vektör Makinası ve Regresyon analizi metotları kullanımı ile günlük talep miktarının tahmini yapılmış ve ilgili metotların performans karşılaştırılması sunulmuştur. Yapılan çalışma ile üniversite gibi farklı davranışlara sahip tüketici tipine göre farklı metotların baskın olduğu ve seçilecek metot ile atık yemek miktarının minimize edilebileceği önerilmiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, Destek Vektör Makinası, Talep Tahmini, Regresyon Analizi

Daily Demand Forecast Using Artificial Intelligence Techniques for Refectory

Abstract

Nowadays many organizations outsource food services from a professional catering company. They pay the bill for catering services as the amount their food demand. Despite changing daily consumption amount according to types of the food, day, behaviors of company employees and a number of employees, a decision which is about the amount of food demand is made by the personal judgment in the most organization and thus serviced foods are run to waste. In this study, the data of a university's refectory is obtained and artificial neural networks, support vector machine and linear regression methods in WEKA tool are used to predict the amount of daily food consumption. Also, the performance of the prediction methods is presented in this study. This paper proposes that different methods are dominant according to the type of consumer with different behaviors such as the university has a student, lecturer, and another staff and selected method by artificial intelligence techniques provides that the amount of waste food can be minimized.

Keywords: Artificial Neural Networks, Support Vector Machine, Demand Forecast, Regression analysis

1. GİRİŞ (INTRODUCTION)

Günümüzde küreselleşme, sanayileşme ve teknolojik gelişmeler gibi birçok faktöre bağlı olarak insanların yeme alışkanlıkları ve tercihleri önemli değişikliklere uğramıştır. Çeşitli nedenlerle ev dışında toplu olarak yenilen öğünler alışlagelen

mutfak anlayışının değişmesine neden olmuştur. Bu da toplu tüketilen yemeklerin hazırlanması ve dağıtımını yapan hazır yemek endüstrisinin (Catering) gelişmesini sağlamıştır [1]. Demografik yapı, toplu beslenme işletmelerinin artması, insanların yeme-içmeye ayırdıkları zamanın azalması, insanların gelirlerinin artışı, yemek menülerinin gelişmesi, ev dışında yeme-içmenin yaygınlaşması ve turizm sektörünün gelişmesi hazır

yemek veya toplu beslenme endüstrisinin gelişmesinin temel nedenlerindedir [1].

Gıdalar ilk tarımsal üretimden son tüketimine kadar tüm tedarik zinciri boyunca israf edilmektedir [2]. Dünyada insan tüketimi için üretilen gıdaların yıllık olarak yaklaşık üçte birinin (yaklaşık 1.3 milyar ton) kayıp olduğu bildirilmektedir [3]. Orta ve yüksek gelirli ülkelerde gıdalar insan tüketimi için uygun olsa bile israf edilerek atılmakta ve önemli miktarda gıda israf edilmektedir [4]. Genel olarak gelişmekte olan ve sanayileşmiş ülkelerde kişi başına düşen gıda israfı daha fazladır. Sahra altı Afrika, Güney Afrika ve Güneydoğu Asya'da kişi başına düşen israf miktarı yalnızca 6-11 kg/yıl iken, Avrupa ve Kuzey Amerika'da tüketiciler tarafından kişi başına düşen gıda israfının 95-115 kg/yıl olduğu bildirilmektedir [3].

Türkiye'de gıda israfının boyutu ve gıda zincirinde yaşanan kayıplar tam olarak bilinmemektedir. Türkiye'de gıda israfına yönelik çalışmalar daha çok son yıllarda ürün bazında yapılmıştır [5]. Pekcan ve ark., (2006)'nın hane halkı düzeyinde yaptığı çalışma temel bir çalışma olarak kabul edilmektedir. Bu çalışmada en fazla israfın satın alma ve hazırlık aşamasında yaşandığı, pişirme-sunum süreçlerinde en yüksek israf edilen ürünlerin taze meyve ve sebze ile tabaktan çöpe kadarki süreçte en fazla israf edilen ürünün ekmeğ olduğunu bildirmişlerdir [6]. Ekmeğin en fazla israf edilen ürün olması ve bunun gerek kamu gerekse de toplumsal olarak fark edilebilir olması bu ürüne olan dikkati de artırmıştır. Toprak Mahsulleri Ofisinin (TMO) "Ekmeğini İsfraf Etme" kampanyası dâhilinde yaptığı araştırmada Türkiye'de her yıl 6 milyon ekmeğin israf edildiği belirtilmektedir [7].

Bu kapsamda gıda israfını en aza indirecek sistemlere ihtiyaç vardır. Bilgi teknolojilerinin gelişimi ile her alanda veri toplama oldukça kolay bir hale gelmiştir. Bu toplanan verilerden yapılan analizler ile israfı azaltan ve memnuniyeti artıran kararlar almak mümkündür.

Üniversiteler, hastaneler ve bünyesinde hizmet alan veya veren kişilere toplu yemek ihtiyacını karşılamakla yükümlü kuruluşlar yemekhanelerde kendi hazırladıkları veya hizmet alımı ile aldıkları yemekleri ücretli veya ücretsiz olarak dağıtmaktadırlar. Çoğunlukla yemek tüketim miktarlarını önceden tahmin etmeleri çok güçtür. Bu sebeple her ne kadar rezervasyon tabanlı çalışan sistemler olsa da menüye göre kişiler yemek ihtiyacını farklı yerlerden karşılayabilmektedir.

2011 yılında Bozkır ve Sezer karar ağacı algoritmalarını kullanarak menüye göre yemek talep miktarı tahmini yapan bir çalışma yapmışlardır. Bu çalışmada Hacettepe üniversitesi yemekhanesi verilerini kullanmış ve çeşitli tüketici tiplerine göre tüketim talep tahmini elde etmiştir. Yaptıkları çalışmada 3 farklı karar ağacı olan CART (Classification And Regression Trees for Machine Learning), CHAID (Chi-square Automatic Interaction Detector) ve Microsoft Decision Trees algoritmaları kullanılmıştır [8]. Bozkır ve Sezer 2013 yılında konu ile ilgili bir yazılım aracı olan "ADEM: An Online Decision Tree Based Menu Demand Prediction Tool for Food Courts" adlı yazılımı geliştirerek başka bir çalışma sunmuşlardır [9].

Bir diğer çalışma da Pamukkale üniversitesi yemekhane verileri kullanılarak 2015 yılında KILIÇ tarafından yüksek lisans

tezi olarak yemek tüketim miktarları tahminini doğrusal regresyon ve yapay sinir ağları teknikleri ile yapmışlardır [10].

Yapılan bu çalışmada bir Üniversite'nin 01.06.2016 – 31.05.2017 tarihleri arasındaki bir yıllık yemek tüketim verileri ve menüleri alınmış ve işlenebilir hale getirilmiştir. Üniversitede yemekhane hizmeti Sağlık Kültür ve Spor Daire Başkanlığı tarafından yapılmaktadır. Bu hizmet başta öğrenciler olmak üzere akademik, idari ve diğer personellere verilmektedir. Ayrıca çalışma yapılan üniversitede 3 adet yerleşke bulunmakta ve bu 3 yerleşke için tahminler yapılması gerekmektedir. Yemek tüketim tahminini yapmak için Yapay Sinir ağları, Destek Vektör Makineleri ve Lineer Regresyon analizi yöntemleri kullanılmış olup, açık kaynak kodlu WEKA yazılım aracından faydalanılmıştır. Ayrıca bu çalışmada ilgili metotlardan elde edilen sonuçların performans karşılaştırması sunulmuştur.

2. VERİLERİN ELDE EDİLMESİ (EXTRACTION OF DATA)

2.1. Üniversitenin Genel Yapısı ve İstatistikî Bilgiler (General Structure of the University and Statistical information)

Üniversite yemekhane tüketim bilgileri Yemekhane Otomasyonu (YO) tarafından kayıt altına alınmaktadır. Mevcut durumda 3 adet yerleşke olup üç yerleşkede de yemekhane hizmeti verilmektedir.

Üniversitede yemek hizmetlerinden faydalanan 5 adet tüketici tipi vardır. Bunlar İdari, Akademik, Öğrenci, Diğer Personel ve Misafir tipleridir. Bu tüketici tiplerine göre ücret bilgileri değişmektedir.

Yemekhanelerden faydalanan öğrenci sayıları: Üniversiteye devam eden 930 adet toplam lisans öğrencisi mevcuttur. Bunların yaklaşık 360'ı 3 no'lu yerleşkede yer alan binada hazırlık ve mütercim tercümanlık eğitimi almaktadır. Yaklaşık 412 adet öğrenci 1 no'lu yerleşkede olup, yaklaşık 158 adet öğrenci de 2 no'lu yerleşkede eğitim görmektedir. Bu öğrenciler kendi yerleşkesindeki yemekhanelerden faydalanmaktadır.

Yemekhanelerden faydalanan personel sayıları: Yaklaşık 280 adet akademik personel, 206 adet idari personel, 63 adet temizlik ve 45 adet güvenlik personeli yemek hizmetinden faydalanmaktadır.

Üniversite 2012 yılında kurulduğundan dolayı henüz doymuş personel ve öğrenci sayısına ulaşmamıştır. Bu sebeple diğer üniversitelerden farklı olarak israfın oluşmaması için öğrenci ve personellere tanımlı olan kartlara ücret karşılığı tüketim günleri ön ödemeli olarak yüklenmektedir. Ön yükleme yaptırmayan personel veya öğrenciler yemek istediğinde misafir olarak değerlendirilip günlük tüketim fişi almaktadır. Bu günlük tüketim fişi de sistemde kayıt altına alınmaktadır.

YO'dan 01.06.2016 ile 31.05.2017 tarihleri arasındaki yemek tüketim bilgileri alınmıştır. Bu tarihler arasındaki genel istatistikî bilgiler Tablo 1'de verilmiştir. Genel tüketim bilgilerinde ilgili tarihler arasında yaklaşık 45.080 adet yemek tüketilmiş, en fazla yemek yenen günde 349 adet yemek tüketilmiştir.

Tablo 1. Yaklaşık Genel Tüketici Bilgileri
(Approximate General Consumer Information)

Parametre	Değer
Toplam Tüketim	45.080
En Çok Yemek Yenen Gün	21.02.2017
En Çok Yemek Yenen Adet / Gün	349
En Az Yemek Yenen Gün	07-06.06.2016
En Az Yemek Yenen Adet / Gün	42
Ortalama Yemek Tüketim Miktarı	187
Toplam Kayıt Sayısı	241

En az tüketim miktarı 42 adet (40'dan daha az olan yemek yeme adetleri elemine edilmiştir sistemde sapmalara neden olmaktadır, toplamda 247 günlük yemek kayıtlarından sadece 6 günü göz ardı edilmiştir, bu günlerde toplam yemek tüketim miktarı 167'dir), ortalama tüketim ise yaklaşık 187 adettir.

2.2. Tüketici Davranışları ve Verilerin İşlenmesi (Consumer Behaviors and Data Processing)

Yemek tüketim miktarını etkileyen kişisel ve çevresel faktörler bulunmaktadır. Bölgesel olarak yemek tüketim tercihleri büyük oranda değişmektedir. Örneğin Japonya'da büyük oranda balık tüketimi mevcutken [11], ülkemizde balık tüketimi Japonya'daki kadar yüksek değildir. Adana ve çevresinde kırmızı et ve acılı yemek çeşitleri fazla tüketilirken, Karadeniz bölgesinde balık ve sebze yemek tüketimi Adana bölgesinden farklılık göstermektedir. Bu sebeple sunulan yemek çeşitliliği bir işletmede yemeğe olan talebi doğrudan etkilemektedir. Bir diğer konu ise ülkemizde Ramazan aylarında öğlen yemeği tüketimi büyük oranda diğer aylara göre değişkenlik göstermektedir. Ayrıca bir eğitim kurumu üzerinde çalışma yaptığımız için tatil, sınav dönemleri yemek tüketimini etkilemektedir.

Bu konuya benzer bir çalışma olan Pamukkale üniversitesi için KILIÇ tarafından yapılan [10]'nolu çalışmada kıstas olarak; (1) Ana Yemek, (2) Yan Yemek, (3) Çorba, (4) Tatlı Salata Meyve, (5) Dönem, (6) Ramazan ayı, (7) Maaş Dönemi, (8) Mevsim, (9) Çeşit, (10) Toplam Personel, (11) İzinli Personel olarak belirlenmiştir. Diğer bir çalışmayı yapan Bozkır ve Sezer yaptıkları çalışmada kıstasları: (1) Ayın Gün 1-31, (2) Ay, (3) Haftanın Günü Pazartesi-Pazar, (4) Tatil, (5) Kalori, (6) Yemek1, (7) Yemek2, (8) Yemek3, (9) Yemek4 olarak belirlemiştir [8].

Yapılan bu çalışmada yemek tüketim miktarını etkileyen kıstaslar; (1) Ana Yemek, (2) Yan Yemek, (3) Çorba, (4) Ramazan, (5) Dönem Tatili, (6) Sınav Tatili, (7) Gün, (8) Akademik Personel Sayısı, (9) İdari Personel Sayısı, (10) Yerleşke 1 Öğrenci Sayısı, (11) Yerleşke 2 Öğrenci Sayısı, (12) Yerleşke 3 Öğrenci Sayısı, (13) Diğer Personel Sayısı, (14) Sınav Haftası olarak belirlenmiştir.

Tablo 2 de ocak ayının ilk haftası verilen yemek listesi görülmektedir. Öğle yemeklerinde 4 ayrı çeşit yemek sunulmaktadır. Bunlar ana yemek, yan yemek, çorba ve içecek (salata, Turşu vb.).

Tablo 2. Ocak Ayı 1. Hafta Yemek Listesi
(January 1st Week Menu List)

Pzt	Sal	Çar	Per	Cum
2 Ocak	3 Ocak	4 Ocak	5 Ocak	6 Ocak

Kuru Fasulye	Yayla Çorba	Mahluta Çorba	Kremalı Sebze Çorba	Mercimek Çorba
Pirinç Pilavı	Karışık Kızartma	Fırın But	Dizi Köfte	Fırında Zeytinyağlı Pirasa
Halka Tatlı	Spagetti Makarna	Pirinç Pilavı	Bulgur Pilavı	Peynirli Makarna
Yoğurt	Şalgam	Ayran	Ayran	Karışık Turşu

Yemek listeleri incelendiğinde birçok yemeğin farklı isimde fakat benzer olduğu görülmektedir. Yemek isimleri farklı olduğu için uzman sistemlerin performansını düşürmektedir. Bu sebeple yapılan çalışmada benzer gruptaki yemekler gruplanarak yemek tüketim tahmininin daha doğru yapılmasına olanak sağlanmıştır. Bu kapsamda ana yemeklerin grup bilgilerinden bazıları Tablo 3'de listelenmiştir. Aynı şekilde yan yemek ve çorbalar da gruplanmıştır. Bu gruplama sonucunda 111 adet farklı isimdeki ana yemek 41'e, 27 adet çorba 13'e, 43 adet yan yemek 9 adet olarak gruplanmıştır.

Tablo 3. Ana Yemek Grupları
(Main Dish Groups)

Ana Yemek Grup Adı	Gruplanan Yemekler
Balık	Balık, Balık Kızartma
Bamya	Bamya
Beykoz Köfte	Beykoz Köfte
Bezelye	Bezelye, Etlı Bezelye, Kıymalı Bezelye
Dolma	Biber Dolma, Dolma, Etlı Biber Dolma, Karışık Dolma, Karışık Kuru Dolma, Kıymalı Dolma, Kuru Dolma
Et Sote	Et Sote
Fırında Patatesli Köfte	Fırında Patatesli Köfte
Güveç	Etlı Güveç, Güveç, Patlıcan Güveç
Ispanak	Ispanak Kavurma, Yumurtalı Ispanak
...	...
...	...

3. METERYAL VE METOT (MATERIAL AND METHOD)


Bu çalışmada yemek tüketim miktarını tahmin etmek için ileri beslemeli çok katmanlı yapay sinir ağları, destek vektör makineleri ve lineer regresyon analizi kullanılmıştır. Bu metotlar için veri madenciliği amacıyla geliştirilmiş açık kaynak kodlu WEKA yazılım aracından faydalanılmıştır.

3.1. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları tahmin ve deneysel öğrenme problemlerinde sıklıkla kullanılmaktadır. Yapay sinir ağları supervised learning ve unsupervised learning olarak modellenebilirler. Bir sinir ağı giriş ve çıkışlar arası ilişkileri yakalayan ve gösteren güçlü bir modelleme aracıdır [12]. Bir sinir ağı insan beyni ve sinir hücrelerinden esinlenilmiştir. En büyük

özelliğinden biri öğrenme yoluyla bilgi edinmesi ve bu bilgileri sinir hücrelerini birbirine bağlayan bağlantılar üzerinde ağırlıklar kaydetmesidir [12], [13]. Böylece bir yapay sinir ağı daha önce karşılaşmadığı durumlarda bile sonuç üretmeyi başarabilir.

Basit bir yapay sinir ağı Şekil 1’deki gibi modellenir. Bu sinir ağı girdiler, ağırlıklar, toplam fonksiyonu, birleşme fonksiyonu, aktivasyon fonksiyonu ve çıkıştan oluşmaktadır [14], [15].




Şekil 1. Yapay Sinir Hücresi [14]
(Artificial Neuron)

Girdiler sonucumuzu etkileyen veya etkileşim olma olasılığı olan kıstaslardır. Ağırlıklar ise girdilerin çıktı üzerindeki etkileme oranları olarak tanımlayabiliriz. Bu ağırlık değerleri öğrenme algoritmaları tarafından çıktıları bilinen girdi değerleri kullanılarak hesaplanabilir. Toplama fonksiyonu için (1) nolu eşitlik kullanılır. Aktivasyon fonksiyonu (1)’nolu eşitlikten elde edilen sonucu kullanarak seri setine göre sonuç elde eder. Bu çalışmada Sigmoid fonksiyonu tercih edilmiştir.


$$net = \sum_{i=1}^n (w_i * x_i) + b \quad (1)$$

Yapay sinir ağları birçok farklı şekilde modellenebilir. Bu çalışmada 3 katmanlı ileri beslemeli yapay sinir ağı modeli kullanılmıştır. Bu yapay sinir ağının genel yapısı şekil 2’de gösterilmektedir [16]. Bu sinir ağı giriş, gizli katman ve çıkış katmanından oluşmaktadır [15]. Yapay sinir ağlarından bir diğer konu kullanılan öğrenme yöntemidir. Çalışmada en çok bilinen öğrenme metodu olan geri yayılım algoritması kullanılmıştır. Geri yayılım algoritması özetle geriye doğru hesaplanan çıkış değer ile gerçekte olması gereken çıkış değerlerinin arasındaki hataların geriye doğru düzeltilmesi için snap ağırlıklarının tekrardan hesaplanmasını sağlar [12].



Şekil 2. Yapay Sinir Ağı Modeli [16]
(The Artificial Neural Network Model)

Şekil 3’de günlük yemek tahmini için 14 adet giriş katmanında, 10 adet gizli katmanda ve 1 adet çıkış katmanında nöron bulunan bir yapay sinir ağı görülmektedir.



Şekil 3. Günlük Yemek Tahmini Yapay Sinir Ağı Modeli
(Daily Demand Forecast Artificial Neural Network Model)

3.2. Lineer Regresyon Analizi (Linear Regression Analysis)

Lineer regresyon analizi bağımlı bir değişken ile bir yada daha fazla bağımsız değişken arasında bulunan ilişkileri modelleme metodudur [17]. Yemek tahmininde diğer kullanılan metotlar ile karşılaştırmak için Lineer regresyon modeli kullanılmış olup bu çalışmada elde edilen sonuçlar verilmiştir.

3.3. Destek Vektör Makineleri (Support Vector Machine)

Destek Vektör Makinesi (DVM) modelleri sınıflandırma ve regresyon problemlerinin çözümünde kullanılmaktadır. Vladimir Vapnik ve arkadaşları tarafından DVM 1992 yılında önerilmiş olup günümüzdeki şeklini 1995 yılında Corinna Cortes ve Vladimir Vapnik yapmıştır [18], [19], [20]. DVM sınırlı sayıda öğrenme örüntüsü üzerinden iyi bir genelleme düzeyi elde etmek amacıyla yapısal risk minimizasyonu (YRM) tümevarım prensibini uygulayan bir öğrenme makinesidir [21].

3.4. WEKA (WEKA)

Veri madenciliği konusunda güçlü bir araç olan WEKA açık kaynak kodlu bir program olup, WEKA adını Waikato Environment for Knowledge Analysis cümlesinde ki her bir kelimenin baş harflerinden almıştır [22]. Weka içerisinde MultiLayerPerceptron, LinearRegression ve SMOReg modülleri kullanımı ile hazırlanan yemek datasından günlük tüketim miktarı tahmin değerleri elde edilmiştir.

4. BULGULAR (FINDINGS)

Yapılan çalışmada Sağlık Kültür ve Spor Daire Başkanlığının işlettiği yemekhane sisteminden 241 adet günlük tüketim verileri alınmış analiz için veriler işlenmiştir. Veriler iki farklı şekilde test ve eğitim verisi olarak gruplandırılıp her bir model için ayrı ayrı denenmiştir. Birinci model %30 test %70 Eğitim verisi olarak sınıflanmış, diğer öğrenme ve test verisi seçimi için WEKA’nın Cross-Validation folds 10 metodu seçilmiştir. Tablo 4 ve Tablo 5’de diğer parametreler ve model adları verilerek tahmin modelleri geliştirilmiştir.

Tablo 4. ANN için giriş parametreleri
(Input Parameters for ANN)

Model Adı	Test/Eğitim Veri Seçimi	Learning Rate	Transfer Fonksiyonu	Momentum	Gizli Katmandaki Nöron Sayısı	Öğrenme Döngü Sayısı
ANN11	30% / 70%	0.01	Sigmoid	0.1	18	10.000
ANN21	30% / 70%	0.01	Sigmoid	0.1	14	10.000
ANN31	30% / 70%	0.01	Sigmoid	0.1	10	10.000
ANN41	30% / 70%	0.01	Sigmoid	0.1	6	10.000
ANN12	Cross-val. Folds 10	0.01	Sigmoid	0.1	18	10.000
ANN22	Cross-val. Folds 10	0.01	Sigmoid	0.1	14	10.000
ANN32	Cross-val. Folds 10	0.01	Sigmoid	0.1	10	10.000
ANN42	Cross-val. Folds 10	0.01	Sigmoid	0.1	6	10.000

Tablo 5. DVM ve Lineer regresyon için parametreleri
(Input Parameters for DVM and Linear Regression)

Model	Test/Eğitim Veri Seçimi	Kullanılan Motod
DVM1	30% / 70%	SMOReg
DVM2	Cross-val. Folds 10	SMOReg
LR1	30% / 70%	LinearRegression
LR2	Cross-val. Folds 10	LinearRegression

Elde edilen sonuçların performans karşılaştırılması için en çok tercih edilen ortalama mutlak yüzde hata (MAPE, Mean Absolute Percentage Error), kök hata kareler ortalaması (RMSE, Root mean square error), bağıl mutlak hata (RAE, Relative absolute error) ve kök bağıl hata kareleri (RRSE, Root relative squared error) parametreleri kullanılmıştır. MAPE için (2), RMSE için (3), RAE için (4) ve RRSE için (5)'nolu eşitlik kullanılmaktadır.

$$MAPE = \frac{\sum_1^N |\hat{\theta}_i - \theta_i|}{N} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_1^N (\hat{\theta}_i - \theta_i)^2}{N}} \quad (3)$$

$$RAE = \frac{\sum_1^N |\hat{\theta}_i - \theta_i|}{\sum_1^N |\theta_i - \theta_i|} \quad (4)$$

$$RRSE = \sqrt{\frac{\sum_1^N (\hat{\theta}_i - \theta_i)^2}{\sum_1^N (\theta_i - \theta_i)^2}} \quad (5)$$

Tablo 6'da tahmin modellerinden elde edilen sonuçları içermektedir. Yapılan testlerde baskın bir model ön plana çıkmamıştır. Fakat ANN42 (Gizli katmanda 6 nöron içeren model) toplam veri için en iyi MAPE ve RMSE değerine sahiptir.

Yerleşke 3 için DVM2 modeli en iyi MAPE değerine sahipken, LR2 modeli en iyi RMSE değerine sahiptir. Diğer yandan Yerleşke 2'de ise LR2 modeli en iyi MAPE ve RMSE değerlerine sahiptir. Yerleşke 1 için DVM1 en iyi MAPE değerine sahipken ANN42 en iyi RMSE değerine sahiptir. Ayrıca Tablo 6'da test edilen verilen için tahmin değerleri ile gerçek değerler arasındaki maksimum ve minimum farklar verilmiştir. Genel itibari ile minimum değerler 0'a yakındır. Maksimum farklara bakıldığında genel toplam için DVM1 en iyi değere sahipken yerleşke 1 için ANN32 en iyi değere sahip olup yerleşke 2 için ANN31, yerleşke 3 için LR1 modeli en iyi değerlere sahiptir.

Sonuçlar genel olarak değerlendirildiğinde yerleşkelerdeki tüketici profillerinin de farklı olduğu göze çarpmaktadır. Yerleşke 1 de Mühendislik bölümleri ağırlıklı olarak bulunurken, yerleşke 2 de ise sosyal bölümler daha çok bulunmaktadır. Diğer yandan yerleşke 3'de ise hazırlık öğrencileri dil eğitimi almaktadır. Bunun yanında yerleşke 2 merkezi bir konumda olması nedeni ile çevresinde çeşitli yemek alternatifleri bulundurmaktadır. Bundan dolayı farklı modellerin farklı yerleşkelerde farklı performanslar gösterdiği düşünülmektedir. Genel itibari ile bakıldığında ANN'de gizli katmandaki nöron sayısının fazlalığı performansı arttırmamıştır.

Tablo 6. Tahmin modellerinin kullanımı ile edilen sonuçlar
(Results obtained with using forecasting models)

Analiz Modeli	Toplam			Yerleşke 1			Yerleşke 2			Yerleşke 3		
	MAPE RAE	RMSE RRSE	MİN. MAK.	MAPE RAE	RMSE RRSE	MİN. MAK.	MAPE RAE	RMSE RRSE	MİN. MAK.	MAPE RAE	RMSE RRSE	MİN. MAK.
LR1	40.79 61.73%	49.94 63.81%	1.90 106.42	18.97 57.84%	25.72 63.06%	0.07 84.28	10.44 79.71%	13.36 79.24%	0.24 36.88	21.61 74.14%	28.01 81.15%	0.09 53.83
LR2	36.52 55.29%	44.94 57.69%	0.13 120.79	18.31 56.03%	24.10 58.55%	0.27 85.76	9.10 77.27%	11.96 78.18%	0.02 39.46	21.25.75 69.10%	27.53 77.25%	0.02 66.67
ANN11	37.17 56.25%	45.42 58.03%	1.37 107.97	20.14 61.39%	27.82 68.21%	0.31 83.39	11.02 84.15%	14.07 83.48%	0.21 37.35	30.19 103.55%	42.37 122.74%	0.04 170.17
ANN21	37.23 56.34%	46.61 59.54%	0.07 112.22	23.14 70.55%	30.00 73.56%	0.13 78.38	10.69 81.61%	13.73 81.42%	0.18 37.09	27.58 94.61%	37.74 109.31%	0.02 119.19
ANN31	39.51 59.79%	49.73 63.54%	0.04 122.85	23.57 71.88%	32.95 80.77%	0.10 105.88	10.96 83.71%	14.50 86.02%	0.36 36.65	30.80 105.66%	47.74 138.28%	0.50 192.70
ANN41	42.23 63.91%	50.73 64.81%	1.61 117.45	20.85 63.56%	27.36 67.07%	1.19 73.69	11.39 86.95%	14.25 84.54%	0.04 38.82	24.27 83.25%	32.77 94.94%	0.32 103.59
ANN12	38.18 57.81%	47.77 61.32%	0.12 117.01	19.01 58.17%	24.68 59.98%	0.19 82.41	10.38 88.10%	13.41 87.67%	0 41.46	23.99 78.01%	34.65 97.25%	0.13 135.05
ANN22	37.36 56.57%	46.82 60.11%	0.12 126.71	19.58 59.90%	25.29 61.45%	0.15 87.60	10.45 88.69%	13.51 88.34%	0 40.29	23.62 76.81%	34.21 96.02%	0.16 140.34
ANN32	36.58 55.40%	45.66 58.61%	0.01 114.62	18.45 56.45%	23.63 57.43%	0.02 73.25	9.86 83.69%	13.01 85.08%	0.06 38.72	24.92 81.06%	36.76 103.18%	0.02 153.70
ANN42	35.56 53.84%	43.67 56.06%	0.03 115.62	18.58 56.85%	23.59 57.33%	0.02 75.50	9.66 81.98%	12.79 83.66%	0.13 47.13	23.83 77.50%	34.85 97.81%	0.04 146.25
DVM1	40.55 61.38%	51.11 65.29%	0.28 102.63	17.97 54.80%	24.73 60.64%	0.06 91.53	10.63 81.14%	13.53 80.27%	0.75 37.58	21.94 75.27%	28.50 82.55%	0.10 57.82
DVM2	36.17 54.77%	45.40 58.28%	0.14 125.63	18.83 57.63%	24.85 60.39%	0.15 93.25	9.29 78.83%	12.07 78.94%	0.06 38.37	20.53 66.77%	28.06 78.75%	0.13 69.64

5. SONUÇ VE ÖNERİLER (CONCLUSION AND SUGGESTIONS)

Günümüzde nüfus artışı ile birlikte gıda ürünlerinin efektif kullanımı önemli bir hale gelmiştir. Endüstriyel dönüşümler ile birlikte işyerlerinde yemek tüketimi ihtiyacı her geçen gün artmaktadır. Bu yemek hizmetinin ihtiyaç miktarı kadar servis edilmesi hem tüketici hem de işletmeciler açısından önemlidir. İşletmeci açısından yemek israfı ve maliyeti azalırken, tüketici tarafından da en hızlı ve ucuz şekilde yemek ihtiyacı karşılanmaktadır. Üniversitelerde yemek ücretleri devlet desteğinden dolayı dışarıya göre oldukça düşüktür. Buna rağmen menü ve kullanıcı davranışlarından dolayı günlük tüketim miktarı değişmektedir. Bu çalışmada bir üniversitenin yemekhane sisteminden elde edilen veriler kullanılarak yapay sinir ağları, destek vektör makinesi ve lineer regresyon modeli ile bu veriler analiz edilmiş ve günlük tüketim miktarı tahmin edilmiştir. Yapılan bu çalışmada makine öğrenme sistemlerinin yemek tahmini üzerinde sonuçlar elde edilebileceği gösterilmiş. Farklı profil ve ölçekteki yerleşkeler için metotların performansları sunulmuştur. Sonraki çalışmalar için bir karşılaştırma verisi olup daha büyük ölçekli işletmeler için farklı metotlar geliştirilerek bu çalışma genişletilebilir.

6. TEŞEKKÜR (ACKNOWLEDGEMENTS)

Bu çalışma Adana Bilim ve Teknoloji üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 16103020'nolu proje kapsamında desteklenmiştir. Ayrıca yemekhane sistemden verilerin alınması kapsamında yardımlarından dolayı Adana Bilim ve Teknoloji Üniversitesi Sağlık Kültür ve Daire Başkanlığı birimine teşekkür ederiz.

KAYNAKLAR (REFERENCES)

- [1] M. Tayar, C. Hecer, Hazır Yemek Sistemleri, 2. Baskı, DORA Basım-Yayın Dağıtım Ltd. Şti. Bursa, 2016.
- [2] J. Parfitt, M. Barthel, S. Macnaughton, "Food waste within food supply chain: quantification and potential for change to 2050", Phil. Trans. R. Soc., vol. 365, pp. 3065-3081, 2010.
- [3] J. Gustavsson, C. Cedeberg, U. Sonesson, "Global food losses and food waste", Food and Agriculture Organisation of the United Nations, Roma, 2011.
- [4] N. Artık, T. Şireli, M. Türkyılmaz, "Gıda israfı, açlık sorunu ve sürdürülebilir gıda projeksiyonları", Ankara Halk Ekmek ve Un Fabrikası A.Ş. Ekmek Dergisi, s. 111-125, 2016.
- [5] C.Ö. Dölekoğlu, S. Gün, F.H. Giray, "Yoksulluk ve Gıda İsrafı Sarmalı", XI. Ulusal Tarım Ekonomisi Kongresi, Samsun, 3-5 Eylül 2014.
- [6] G. Pekcan, E. Köksal, Ö. Küçükerdönmez, H. Özel, "Household Food Wastage in Turkey". Statistics Division, Working Paper Series, No: ESS/ESSA/006e, FAO, 2006.
- [7] TMO. 2013. "Türkiye'de Ekmek İsrafı Araştırması". Toprak Mahsulleri Ofisi Genel Müdürlüğü, Ankara.

- [8] Bozkir, A.S. ve Sezer, E., Predicting food demand in food courts by decision tree approaches, *Procedia Computer Science*, 3, pp.759-763., 2011. Doi: 10.1016/j.procs.2010.12.125
- [9] Bozkir, A.S ve Sezer, E., ADEM: An Online Decision Tree Based Menu Demand Prediction Tool for Food Courts, 2013, 4th International Conference on Food Engineering and Biotechnology IPCBEE vol.50 (2013) (2013) IACSIT Press, Singapore DOI: 10.7763/IPCBEE. 2013. V50. 3
- [10] G. Kılıç, Yapay sinir ağları ile yemekhane günlük talep tahmini, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, 2015.
- [11] H. Ergün, *Su Ürünleri Tüketimi ve Tanıtımı, SÜMAE YUNUS Araştırma Bülteni*, 9:2, Haziran 2009.
- [12] S. S. Baboo, I.K. Shereef, 2010, "An Efficient Weather Forecasting System using Artificial Neural Network", *International Journal of Environmental Science and Development*, Vol. 1, No. 4, 2010
- [13] O. ŞENKAL, , "Solar Radiation Modeling for Turkey Using Atmospheric Parameters with Artificial Neural Networks", *Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 31(2), ss. 179-185, 2016
- [14] O. Kaynar, S. Taştan, F. Demirkoparan, "Yapay Sinir Ağları ile Doğalgaz Tüketim Tahmini", *Atatürk Ü. İİBF Dergisi*, 10. *Ekonometri ve İstatistik Sempozyumu Özel Sayısı*, 2011.
- [15] S. Benkachcha, J. Benhra, El Hassani.H, "Causal Method and Time Series Forecasting model based on Artificial Neural Network", *International Journal of Computer Applications (0975 – 8887) Volume 75– No.7, 2013*
- [16] H. Özkişi, M. Topaloğlu, "Fotovoltaik Hücrenin Verimliliğinin Yapay Sinir Ağı ile Tahmini", *Bilişim Teknolojileri Dergisi*, Cilt:10, Sayı:3, 2017
- [17] Ş. U. ULADİ, A. İ. ULADİ, "Osmaniye İli Genelinde Konut Özellikleri ile Konut Fiyatları Arasındaki İlişkinin Belirlenmesi", *International Journal of Academic Value Studies*, Vol: 3, Issue: 16, pp. 475-480, 2017.
- [18] M.T. Bilişik, "Destek Vektör Makinesi, Çoklu Regresyon ve Doğrusal Olmayan Programlama ile Prekendecilik Sektöründe Gelir Yöntemi İçin Dinamik Fiyatlandırma", *XI. Üretim Araştırmaları Sempozyumu*, 23-24 Haziran 2011
- [19] V. Vapnik, "The Nature of Statistical Learning Theory", *Newyork: Springer. 1995.*
- [20] V. Vapnik, "Statistical Learning Theory. Newyork", *John Wiley & Sons, 1998.*
- [21] F. Başer, A. Apaydın, "Sınıflandırma Amaçlı Destek Vektör Makinelerinin Lojistik Regresyon ile Karşılaştırması", *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi B-Teorik Bilimler*, Cilt: 3 Sayı: 2 - 2015 Sayfa: 53 – 65, 2015
- [22] WEKA, <https://www.cs.waikato.ac.nz/ml/index.html>, 27.11.2017