

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**YAPAY SİNİR AĞLARI İLE YEMEKHANE GÜNLÜK TALEP
TAHMİNİ**

YÜKSEK LİSANS TEZİ

GÜNAY KILIÇ

DENİZLİ, MAYIS - 2015

T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI



YAPAY SİNİR AĞLARI İLE YEMEKHANE GÜNLÜK TALEP
TAHMINİ

YÜKSEK LİSANS TEZİ

GÜNAY KILIÇ

KABUL VE ONAY SAYFASI

Günay KILIÇ tarafından hazırlanan “YAPAY SİNİR AĞLARI İLE YEMEKHANE GÜNLÜK TALEP TAHMİNİ” adlı tez çalışmasının savunma sınavı 07.05.2015 tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği ile Pamukkale Üniversitesi Fen Bilimleri Enstitüsü BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman

Doç. Dr. Sezai TOKAT



Üye

Doç. Dr. Abdullah Tahsin TOLA



Üye

Doç. Dr. Emre ÇOMAK



Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 24.06.2015 tarih ve 23/17..... sayılı kararıyla onaylanmıştır..



Prof. Dr. Orhan KARABULUT

Fen Bilimleri Enstitüsü Müdürü

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildięini; bu çalıřmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildięini ve alıntı yapılan çalıřmalara atfedildięini beyan ederim.


Günay KILIÇ

ÖZET

YAPAY SİNİR AĞLARI İLE YEMEKHANE GÜNLÜK TALEP TAHMİNİ
YÜKSEK LİSANS TEZİ
GÜNAY KILIÇ
PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: DOÇ. DR. SEZAI TOKAT)
DENİZLİ, MAYIS - 2015

Günümüzde alışveriş merkezi, büyük sanayi kuruluşları ve üniversitelerin sayısının giderek artması ile birlikte yemek hizmeti sunan işletmelere olan ilgi de artmaktadır. Personeline yemek veren kurumlarda o gün kurum yemekhanesinde kaç kişinin yemek yiyeceği zaman ve maliyet açısından önem teşkil etmektedir. Bu açıdan bu sayının doğru olarak tahmin edilmesi kuruma önemli bir fayda sağlayacaktır.

Bu çalışmada Pamukkale Üniversitesi (PAÜ) yemekhanesi verileri kullanılmıştır. PAÜ Pusula bilgi sisteminden veriler alınarak üretilen yemek miktarını etkileyebileceği düşünülen kriterler ortaya çıkarılmıştır.

Oluşturulan veri seti SPSS programında analiz edilerek veriler arasında ilişkiler test edilmiştir. Bu ilişkilere dayanılarak veriler eğitim ve test kümesi olarak iki kısma ayrılmıştır. Eğitim verileri Doğrusal Regresyon, Yapay Sinir Ağları tekniklerinden Çok Katmanlı Yapay Sinir Ağları ve Radyal Tabanlı Fonksiyon Yapay Sinir Ağları ile eğitilmiş ve test edilmiştir. Bu çalışma ile farklı yöntemler kullanılarak günlük yemek miktarı tayininin yapılabileceği gösterilmiştir. En iyi en kötü 38 günlük örnek üzerinde tahmin çalışması PAÜ yemekhanesi beslenme uzmanları ile yapılmıştır. Bu örnekler için tezde tasarlanan yemekhane günlük talep tahmin sistemlerinin genel olarak daha iyi sonuç verdiği gözlenmiştir. Günlük yemek tahmini için Matlab programında GUI tasarlanmıştır.

ANAHTAR KELİMELER: Radyal Tabanlı Fonksiyon Yapay Sinir Ağları, Çok Katmanlı Yapay Sinir Ağları, Çoklu Doğrusal Regresyon, SPSS, Matlab GUI

ABSTRACT

REFECTORY DAILY DEMAND FORECAST USING ARTIFICIAL NEURAL NETWORKS

MSC THESIS

GÜNAY KILIÇ

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE

COMPUTER ENGINEERING

(SUPERVISOR: ASSOC. PROF. DR. SEZAI TOKAT)

DENİZLİ, MAY 2015

Today, as the number of shopping centers, large industrial enterprises and universities are increasing, the interest in the business of providing food service is also increasing. Considering time and cost, it is important for the corporations how many staffs eat food in the refectories and dining halls that give food to its staffs.

In this study, the data of Pamukkale University (PAU) refectory are used. By receiving data from PAU Computer Information System known as Pusula, the criteria which are thought to affect the amount of food cooked are detected.

By analyzing generated data sets with SPSS program, relationship between data is tested. Based on these relationships data are divided into two parts as training and test group. Training data are trained by using Linear Regression, Techniques of Artificial Neural Networks Multi Layer Neural Network and Radial Basis Function Neural Networks and then tested. With this study, it is shown that by using different statistical and artificial intelligence methods daily food amount can be predicted better than experts' decisions. Prediction studies are executed on the best and worst 38 samples with PAU nutrition experts. For these samples it is observed that our systems have better prediction performance. Also, a GUI is designed for daily meal prediction in Matlab program.

KEY WORDS: Radial Basis Function Neural Networks, Multi Layer Neural Network, Multiple Linear Regression, SPSS, Matlab GUI

İÇİNDEKİLER

Sayfa

ÖZET	iv
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	v
TABLO LİSTESİ	vi
SEMBOL LİSTESİ	vii
KISALTMALAR	viii
ÖNSÖZ	ix
1. GİRİŞ	1
1.1 Planlama- Talep Tahmin Yöntemi	1
1.2 Talep Tahmin Yöntemleri	2
1.3 Beslenme ve Yemek Seçimi.....	3
1.3.1 Beslenme	3
1.3.2 Yemek Seçimi	3
1.4 Yemekhane ve Günlük Yemek Takibi	6
1.5 Pamukkale Üniversitesi Yemekhanesi	7
1.6 Kullanılan Yöntemler	9
1.7 Hata Ölçüm Fonksiyonu	10
2. LİTERATÜR ÇALIŞMASI	11
3. YÖNTEM	14
3.1 Yapay Sinir Ağları.....	14
3.1.1 Yapay Sinir Ağlarının Genel Özellikleri ve Kullanım Alanları.....	14
3.1.2 Yapay Sinir Ağları Mimarisi.....	15
3.1.3 Yapay Sinir Ağlarının Sınıflandırılması ve Uygun Ağ Seçimi.....	17
3.1.4 Uygulamada Kullanılan Yöntemler	19
3.1.4.1 Geriye Yayılım Algoritması.....	19
3.1.4.1.1 Momentum ve Öğrenme Katsayılı Algoritma.....	21
3.1.4.1.2 Levenberg-Marquardt Algoritması	22
3.1.4.2 Radyal Tabanlı Fonksiyon Yapay Sinir Ağları	23
3.2 Regresyon Modeli.....	25
3.2.1 En Küçük Kareler Yöntemi.....	26
3.2.2 Çoklu Doğrusal Regresyon Modeli.....	27
3.2.3 Etkileşimli Çoklu Doğrusal Regresyon Modeli	28
4. GÜNLÜK YEMEK TAHMİNİ	29
4.1 Verilerin Hazırlanması	29
4.2 Farklı Yöntemler ile Günlük Yemek Tahmini	35
4.2.1 Çok Katmanlı Yapay Sinir Ağları ile Talep Tahmini	35
4.2.2 Levenberg-Marquardt Algoritması Kullanan Yapay Sinir Ağları ile Talep Tahmini	39
4.2.3 Radyal Tabanlı Fonksiyon Sinir Ağları ile Yemek Talep Tahmini	40
4.2.4 Regresyon Modeli ile Yemek Talep Tahmini	40
4.2.4.1 Çoklu Doğrusal Regresyon Modeli İle Yemek Talep Tahmini	41
4.2.4.2 Etkileşimli Çoklu Doğrusal Regresyon Modeli ile Yemek Tahmini .	41
4.2.5 Tahmin Yöntemlerinin Genel Karşılaştırılması	42

4.2.6 Tasarılan Grafik Kullanıcı Arayüzü	43
4.2.7 En İyi ve En Kötü Örneklerin Uzman Görüşü ile Karşılaştırılması.....	43
5. SONUÇ VE ÖNERİLER.....	47
6. KAYNAKLAR	48
7. ÖZGEÇMİŞ.....	53

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 1.1 : Yemek kuyruğu.....	8
Şekil 3.1 : Yapay sinir ağları hücre mimarisi.....	16
Şekil 3.2 : Yapay sinir ağları genel mimarisi.....	17
Şekil 3.3 : Radyal tabanlı fonksiyon yapay sinir ağları genel mimarisi.....	24
Şekil 4.1 : Veritabanı diyagramı.....	30
Şekil 4.2 : SPSS programında Kolmogorov-Smirnov testi.....	32
Şekil 4.3 : SPSS programında Kruskal-Wallis H testi.....	33
Şekil 4.4 : SPSS’te Korelasyon testi.....	34
Şekil 4.5 : Çok katmanlı ağda katmanlardaki hücre sayısına göre eğitim hatası.....	36
Şekil 4.6 : Çok katmanlı ağda m değişimine göre eğitim hatasının değişimi.....	37
Şekil 4.7 : Çok katmanlı ağda n değerine göre eğitim hatasının değişimi.....	37
Şekil 4.8 : Tatmin edecek eğitim hatasına göre test hatası değişimi.....	38
Şekil 4.9 : LM kullanan ileri beslemeli ağda epoch sayısına göre test hatası değişimi.....	39
Şekil 4.10: RTYSA gizli katmandaki hücre sayısına göre eğitim ve test hatası değişimi.....	40
Şekil 4.11: Çoklu doğrusal regresyon ile test ve tahmini değerler.....	41
Şekil 4.12: Etkileşimli çoklu doğrusal regresyon ile test ve tahmini değerler.....	42
Şekil 4.13: Tasarlanan Grafik Kullanıcı Arayüzü.....	43

TABLO LİSTESİ

	<u>Sayfa</u>
Tablo 1.1 : Faktörlerin gruplanması	4
Tablo 3.1 : Yapılarına göre yapay sinir ağları	18
Tablo 3.2 : Öğrenme yöntemlerine göre yapay sinir ağları.....	18
Tablo 3.3 : YSA uygulama alanları.....	18
Tablo 4.1 : Yemek yemede etkili etken listesi	30
Tablo 4.2 : Yemek listesi.....	31
Tablo 4.3 : Değişkenlerin SPSS programındaki eşlenikleri	31
Tablo 4.4 : Kolmogorov-Smirnov testi sonuçları.....	32
Tablo 4.5 : Kruskal Wallis H testi sonuçları	33
Tablo 4.6 : Spearman Kolerasyon testi sonuçları.....	34
Tablo 4.7 : Kullanılan yöntemlerin test hatalarının karşılaştırılması	42
Tablo 4.8 : En iyi en kötü örneklerin ortalamalarının karşılaştırılması.....	44
Tablo 4.9 : En iyi en kötü örneklerin olduğu yemek verileri.....	45
Tablo 4.10: En iyi en kötü örnekler için tahminler ile gerçek veriler arasındaki fark	46

SEMBOL LİSTESİ

N	: Gözlem sayısı
x_i^s	: s . gözleme ait i . girdi değeri
w_{ji}	: i . girdinin j . yapay sinir hücresi giriş ağırlığı
$\Psi()$: Yapay sinir hücresi aktivasyon fonksiyonu
$E(t)$: t anında geri yayımlı yapay sinir ağının ortalama karesel hatası
$o_j^s(t)$: t . anında s . örnek için ağın j . çıkışına ait tahmin değeri
y_j^s	: s . örneğe ait j . çıkışın gerçek değeri
$e_j^s(t)$: t . anda s . örnek için ağın j . çıkışına ait tahmin hatası
$\Delta w_{ji}(t)$: i ve j katman yapay sinir hücreleri arasındaki ağırlıklardaki değişim
δ_j	: ara veya çıkış katmanındaki herhangi bir j yapay sinir hücresine ait faktör
H	: Hessian matrisi
J	: Jacobian matrisi
I	: Birim matris
μ	: Marquardt parametresi
$\mathbf{g}(t)$: t anında gradyen vektörü
\mathbf{x}^s	: s . gözleme ait giriş vektörü
\mathbf{v}_i	: Radyal tabanlı ağdaki i . yapay sinir hücresi merkez vektörü
S	: Karesel hata
\hat{y}_j^s	: Regresyon denkleminde bağımlı değişken j . tahmin değeri
e_j^s	: Regresyon denkleminde s . örnek için j . tahmin hatası
α, β	: Regresyon katsayıları
\hat{Y}_i	: Tahmin edilen Y_i değeri
$\hat{\alpha}$: Tahmin edilen α değeri
$\hat{\beta}$: Tahmin edilen β değeri
m	: Geri yayılım algoritmasında ağın ağırlıklarını güncellerken kullanılan momentum değeri
n	: Geri yayılım algoritmasında ağın ağırlıklarını güncellerken kullanılan ağın eğitim oranı
p	: bağımsız değişken sayısı

KISALTMALAR

PAÜ	: Pamukkale Üniversitesi ve Spor Daire Başkanlığı
ÇDR	: Çoklu Doğrusal Regresyon
EÇDR	: Etkileşimli Çoklu Doğrusal Regresyon
ÇKYSA	: Çok Katmanlı Yapay Sinir Ağları
RTFYSA	: Radyal Tabanlı Fonksiyon Yapay Sinir Ağları
YKP	: Yemekhane Kontrol Programı
SKS	: Sağlık Kültür ve Spor Daire Başkanlığı
RMSE	: Hata Kareler Ortalamasının Karekökü
MSE	: Ortalama Karesel Hata
SVM	: Destek Vektör Makinaları
LM	: Levenberg - Marquardt
LVQ	: Öğrenme Vektör Nicelendirmesi
RTF	: Radyal Tabanlı Fonksiyon
EÇDR	: Etkileşimli Çoklu Doğrusal Regresyon
EKK	: En Küçük Kareler
MSSQL	: Microsoft SQL Server
PBS	: Personel Bilgi Sistemi
RMSE_{ÇKTest}	: ÇKYSA Test Hatası
RMSE_{LMTest}	: LM Kullanan İleri Beslemeli Ağda Test Hatası
RMSE_{RBFTest}	: RTFYSA Test Hatası
RMSE_{ÇDRTest}	: ÇDR Test Hatası
RMSE_{EÇDRTest}	: EÇDR Test Hatası
ÇKTest	: En iyi ve en kötü örneklerde ÇKYSA tahmini
LMTest	: En iyi ve en kötü örneklerde LM tahmini
RBFTest	: En iyi ve en kötü örneklerde RBF tahmini
ÇDRTest	: En iyi ve en kötü örneklerde ÇDR tahmini
EÇDRTest	: En iyi ve en kötü örneklerde EÇDR tahmini
UzmanGörüş	: En iyi ve en kötü örneklerde uzman görüş tahmini
FarkÇKTest	: Gerçek yiyecek sayısı ile ÇKTest arasındaki fark
FarkLMTest	: Gerçek yiyecek sayısı ile LMTest arasındaki fark
FarkRBFTest	: Gerçek yiyecek sayısı ile RBFTest arasındaki fark
FarkÇDRTest	: Gerçek yiyecek sayısı ile ÇDRTest arasındaki fark
FarkEÇDRTest	: Gerçek yiyecek sayısı ile EÇDRTest arasındaki fark
FarkUzmanGörüş	: Gerçek yiyecek sayısı ile UzmanGörüş arasındaki fark
FarkÇKTest_{ortalama}	: Tüm en iyi ve en kötü örneklerin FarkÇKTest ortalamaları
FarkLMTest_{ortalama}	: Tüm en iyi ve en kötü örneklerin FarkLMTest ortalamaları
FarkRBFTest_{ortalama}	: Tüm en iyi ve en kötü örneklerin FarkRBFTest ortalamaları
FarkÇDRTest_{ortalama}	: Tüm en iyi ve en kötü örneklerin FarkÇDRTest ortalamaları
FarkEÇDRTest_{ortalama}	: Tüm en iyi ve en kötü örneklerin FarkEÇDRTest ortalamaları
FarkUzmanGörüş_{ortalama}	: Tüm en iyi ve en kötü örneklerin FarkUzmanGörüş ortalamaları

ÖNSÖZ

Yüksek lisans tez çalışmalarım süresince değerli zamanımı benden esirgemeyen, bilgi ve tecrübesi ile bana yol gösteren değerli danışman hocam Doç. Dr. Sezai TOKAT'a desteklerinden dolayı teşekkürü bir borç bilirim.

Matlab kodlamalarında yardımını esirgemeyen iş arkadaşım Kadir YÜREKTÜRK'e ve veri analizi kısmında bilgilerini benimle paylaşan iş arkadaşım Mehmet Ulaş KOYUNCUOĞLU'na teşekkürlerimi sunarım.

Uzman görüşü almak için görüştüğüm Pamukkale Üniversitesi merkez yemekhanesi beslenme uzmanı Çağla ŞAŞMAZ ve baş aşçı Yalçın BAYER'e ayrıca teşekkür ederim.

Bana her konuda destek olan eşim Bedia Sündüz KILIÇ'a bugünlere gelmemde en büyük pay sahibi olan, dualarını benden esirgemeyen anne ve babama ve neşe kaynağım biricik kızım Zehra'ya teşekkür ederim.

Günay KILIÇ

1. GİRİŞ

1.1 Planlama- Talep Tahmin Yöntemi

Planlama, şimdiki veriler ve gelecekteki muhtemel gelişmelerin ışığı altında belli bir amaca ulaşmada izlenecek yolu gösteren bir süreç olarak tanımlanabilir. Bu yüzden planlama, üretim yönetiminin önemli bir parçasıdır. İleriye yönelik belirsizlikler etkin bir planlamayı güçleştirmektedir. Belirsizliği azaltmak için yapılan her çalışma sağlıklı karar alınmasına önemli katkı sağlar (Üreten 2002).

İşletmeler veya kurumlar günlük yaşam içinde farklı kararlar vermek durumunda kalabilirler. Gelecek döneme ait alınacak kararlar işletmelerin veya kurumların daha fazla kar etmesi ya da üretim ve hizmet faaliyetleri açısından hayatta kalabilmesi için büyük önem taşımaktadır. Geleceğe yönelik kararların doğru alınmaması ise tam tersi sonuçlar doğurabilmektedir. Belirsizliklerin bulunduğu ortamda işletmelerin ve kurumların geleceklerini rastlantılara bırakmak yerine daha önceden planlayabilmesi gerekmektedir. Bu planların uygulanmasında ise geleceğe yönelik bir dizi kararın alınması gerekir. Geleceğe yönelik alınacak kararlarda ileriye yönelik tahmin çalışmaları büyük önem teşkil etmektedir.

İşletmelerin üretim sürecinde karar alınmasındaki rol oynayan faktörlerden en önemlisi, üretilecek mal veya hizmetin gelecekteki satış miktarı yani talebidir. Bir ürün ya da hizmetin talep miktarının belirlenmesi işletmeler açısından çok büyük önem taşımaktadır.

Talep tahmin çalışmalarında elde edilen değerler ile gerçek değerler arasındaki fark büyüdükçe gereğinden fazla üretim gibi olumsuz durumlar ortaya çıkar ve bu maliyetin artmasına neden olur. Dolayısıyla üretim sistemlerinin tasarlanması, planlanması ve işletilmesi ile ilgili kararlarda doğru tahmin başarılı bir ön koşuldur. Bu aşamalar, şu sırada sunulabilir:

1. Bilgilerin Toplanması
2. Tahmin Döneminin Tespiti
3. Tahmin Yönetiminin Seçimi ve Hata Hesabının Yapılması
4. Tahmin Sonuçlarının Geçerliliğinin Araştırılması (Bulut 2006).

Üretim planlaması işletmelerin veya kurumların belli bir dönem içinde üreteceği ürün miktarının belirlenmesi ve kontrol altında tutulmasıdır. Ürün planlamasında da talep yönetimi önemli bir yer teşkil etmektedir. Bir üretim planlamasının ön şartı talep raporudur (Nesine 1996).

1.2 Talep Tahmin Yöntemleri

Talep tahmin yöntemi herhangi bir olasılıklı model altında yer alan basit bir algoritma olabileceği gibi, veriye göre özel bir model de olabilir. Literatürde farklı sınıflandırmalar olsa da yöntemler Nicel ve Nitel olmak üzere iki grupta belirtilebilir.

Nicel yöntemlerde giriş verisi çeşitli zaman aralıklarında yapılan ölçümlerdir. Nitel yöntemlerde ise konu ile ilgili uzman kişilerin bu alandaki gelişmelerin ne yönde olacağı hakkındaki fikirlerdir. Nicel yöntemlerde elde edilen verilerin uzman kişiler tarafından incelenmesi ile iki yönteminde birlikte kullanıldığı yöntemler mevcuttur.

Nitel yöntemlere Delphi Yöntemi, Pazar Araştırması, Uzman Panelleri örnek olarak verilebilir. Nicel Yöntemlere ise Basit Regresyon Analizi, Çoklu Regresyon Analizi (ÇR), Ekonometrik Modeller, Genetik Algoritmalar, Destek Vektör Makineleri, Yapay Sinir Ağları (YSA), Hareketli Ortalamalar Yöntemi, Üstel Düzleştirme Yöntemi gibi yöntemler örnek olarak verilebilir (Karaatlı 2012).

Bu çalışmada nicel yöntemlerden ÇR ve YSA talep tahmini için kullanılmıştır.

1.3 Beslenme ve Yemek Seçimi

1.3.1 Beslenme

Yaşayan bütün canlılar yaşamını devam ettirebilmek için hava, su, yiyecek ve belli vücut ısısına ihtiyaç duyarlar. En önemlileri sırasıyla hava, su ve yiyecektir. İnsanlar vücut büyüklükleri, kilolarına ve vücutlarındaki enerji miktarlarına göre birkaç hafta aç kalabilirler. Beslenme insanlarda farklı anlam ifade eder; bazı insanlar yaşamı devam ettirmek için bir araç olarak görür bazıları için ise yaşama biçimidir. İnsanların farklı görüşleri bulunsa da gerçekte beslenme çok daha karmaşık bir olgudur. Psikolojik durumumuz, sosyal çevremiz, beğenilerimiz ve birçok dış etken beslenme ve yemek seçimi için etkilidir (Url 2015^a).

Beslenmeyi; insan hayatını devam ettirmek, sağlığını korumak, insan bedenini sağlıklı bir şekilde büyümesine olanak sağlamak, vücudun bakımı ve hücrelerin yenilenmesi için yiyeceklerin insan vücudu üzerindeki etkilerini veya insanlar ile yiyecek arasındaki ilişkiyi ele alın çalışmalar olmak üzere iki farklı şekilde açıklamak mümkündür (Lisa ve Lientjie 2002).

1.3.2 Yemek Seçimi

Yemek seçimi gıda bilimcilerin ilgi alanına girmektedir. Bu konu ile ilgili birçok çalışma yapılmıştır ve yapılan çalışmalarda farklı faktörler belirlenmiştir. Bu faktörler sağlık, ruh hali, uygunluk, duygusal özellikler, doğallık, fiyat, kilo kontrolü, bilinirlik ve etik kaygılar olarak sıralanmıştır (Steptoe ve diğ. 1995). Farklı bilim adamları bu faktörlerin bazılarının daha önemli olduğunu öne sürmüştür. Bazı bilim adamlarına göre bu faktörlerden en önemlileri sağlık, duygusal özellikler, uygunluk ve fiyattır (Lindeman ve Vaananen 2000). Bazıları ise lezzet, doku, koku gibi yiyecek ile ilgili duygusal faktörler ve duygusal olmayan sağlık kaygısı, etik kaygılar, ruh hali ve fiyat gibi faktörlerden oluşan bir fonksiyondur (Prescott ve diğ. 2002) şeklinde bir görüş bildirmişlerdir. Literatürdeki çalışmaların hepsini özetleyen görüş yemek seçimlerini etkileyen

faktörleri de gruplamıştır. Bu görüşe göre kişi ile ilgili faktörler (duyusal özellikler ve psikolojik faktörler) yemek ile ilgili faktörler (fiziksel özellikler, kimyasal özellikler ve besin değeri) ekonomik ve sosyal faktörler (fiyat ve erişilebilirlik) olarak belirlenmiştir (Frewer ve diğ. 2001).

Yukarıda anlatılan çevresel, kişisel ve yemek ile alakalı faktörler Tablo 1.1’de gösterilmiştir (Özdemir 2010).

Tablo 1.1: Faktörlerin gruplanması

Grup	Faktör
Kişi	Sağlık
	Ruh hali / Psikoloji
	Duyusal algılama (tat, koku, vb.)
	Kilo kontrolü / Diyet
	Etik kaygılar
	Kültürel, etnik, felsefi ve çevresel kaygılar
	Damak tadı
	Beslenme kaygıları
	Kişilik
	Deneyim
Yemek	Fiyat
	Doğallık
	Besin Değeri
	Gıda güvenirliliği
	Marka
	Lezzet
	Koku
	Bilinirlik
	Uygunluk
	Doyuruculuk
Çevre	Kültür
	Yiyecek eğilimleri
	Zaman
	Ekonomik-Sosyal faktörler

Yukarıda yazılan faktörlerin bazıları aşağıda açıklanmıştır.

Bireysel Enerji ve Besin İhtiyaçları: Farklı yaş grubundaki, farklı cinsiyetteki ve farklı mesleklerdeki kişilere göre bireysel besin ihtiyaçları farklılık gösterebilir. Örneğin hamile bir bayan düşük yapmamak için folik asit içeren besinler yemek zorunda olduğu gibi spor yapan bir sporcunun fiziksel aktiviteleri yapabilmesi için daha çok enerji içeren besinler tüketmesi gerekmektedir.

Sağlık Endişeleri: Örneğin Laktoz intoleransı olan bireyler süt ve süt ürünlerini sindirmede sıkıntı yaşadıkları için diğer kalsiyum bulunan ürünleri tüketmeleri gerekmektedir.

Kültürel ve Dini faktörler: Müslümanların domuz eti yememesi veya vejetaryenlerin et yememeleri örnek verilebilir.

Tercihler: Herkes aynı yemeği sevmez ama bazı yemekler diğerlerine göre daha popülerdir. Yiyeceklerin tadı, kokusu ve görüntüsü insanlar üzerinde farklı etkiler bırakabilir.

Çevresel Kaygılar: Genetiği değişmiş organizmalar başka organizmaya geçerken yeni organizmanın genetiğinin değişmesine sebep olabilir. Bu yüzden insanlar genetiği değişmiş organizmaları tercih etmeyip aksine organik olarak adlandırılan doğal ürünleri tercih edebilirler.

Reklamlar: Televizyon, İnternet, radyo, afiş gibi yerlerde gözüken reklamlar insanların tercihlerini etkilemektedir.

Bilgi Kaynakları: Kamu spotları ve Sağlık Bakanlığı kişileri sağlıklı besinler yeme konusunda yönlendirebilirler (Url 2015^a).

Yukarıda sayılan yiyecek tercihleri doğrudan bireyin ilgili yiyeceğe olan ilgisini belirleyen faktörlerdir. Yemek listesini hazırlayacak olan kurum bu tercihleri dikkate alarak yemek listesini hazırlamak zorundadır. Fakat bunun yanında yemek listesinin hazırlanmasını etkileyecek diğer hususlar da aşağıdaki gibi listelenebilir:

Sosyal Kaygılar: Gelişmiş ülkelerde masrafların azaltılması devlet politikası olarak önemli bir sosyal kaygı olabilir.

Maliyet: Düşük bütçeli kişiler için önemli bir etkidir. Genellikle dışarıda yemek yemek daha masraflı olmaktadır.

Gıda Bulunabilirliği: Çileğin yazın yetiştiği gibi çoğu yiyecek sezonunda yetişir. Mevsimi dışında bir yiyeceği almak maliyeti arttırabilir. Sebzeler derin donduruculara atılarak kışın yenilebilmektedir.

Yemek Tercihini ve Sayısını Etkileyen Dış Faktörler: Üniversite için düşünüldüğünde ders dönemleri, sınav dönemleri, toplam personel sayısı, izinli personel sayısı, mevsim ve maaş dönemi yemekhaneye gelme tercihlerini etkileyen dış faktörlerdir.

Bu çalışmada bireylerin oluşturduğu eğitim kurumu olan üniversitelerde toplam personel sayısını etkileyen dış faktörler ve bireysel yemek tercihlerini etkileyecek faktörler birlikte ele alınmıştır. Bu dış faktörlerin etkisi incelenerek daha sonraki yemek listeleri ile çıkarılması gereken yemek arasında bir eşleştirme yapılmaya çalışılmıştır. Çünkü üniversitede bulunan toplam personel sayısını arttıran veya azaltan bu sebeplerin dolaylı olarak da yemek yiyen personel sayısını arttıracığı veya azaltacağı düşünülmektedir.

1.4 Yemekhane ve Günlük Yemek Takibi

Türk Dil Kurumu sitesinde yemekhane: “okul, fabrika vb. kuruluşlarda yemek yenilen büyük salon” olarak tanımlanmıştır (Url 2015^b). Kurumların bünyesinde yemeklerin ve personellerin çeşidine göre bir veya birden fazla yemekhane ve mutfağın bulunduğu binalar vardır. Bu binalar da yemekhane olarak adlandırılabilir.

Kurumlarda yemek takibinin amacı personelin yediği yemek sayısını tespit etmek, öğünleri düzenlemek, yemekhane girişlerini hak edişlere göre düzenlemek, kurum dışından kişilerin yemek yemesine izin vermemek, kişilerin durumlarına göre yemek ücretlerini düzenlemek gibi sıralanabilir. Bu takipleri insan gücü kullanmadan doğru bir şekilde hızlıca yapabilmek için Yemekhane Kontrol Programları (YKP) üretilmiştir. Yemekhane geçiş noktalarına kurulan turnikelerden geçen kişilerin bilgileri akıllı kart okuyucular, parmak izi okuyucular, yüz tanıma sistemleri gibi sistemler sayesinde alınıp veri tabanına kaydedilmektedir. Kaydedilen veriler ile ilgili raporlar alınabilir ve alınan veriler yorumlanıp gerekli çıkarımlar yapılabilmektedir. YKP ana amacı kontrol olsa da elde edilen verilerden çıkarımlar yapılarak tahminler üretilebilir.

1.5 Pamukkale Üniversitesi Yemekhanesi

PAÜ Kınıklı yerleşkesinde Tıp Fakültesi, İktisadi ve İdari Birimler Fakültesi, Mühendislik Fakültesi, Eğitim Fakültesi, Fen Edebiyat Fakültesi, Denizli Sağlık Hizmetleri Meslek Yüksek Okulu, Denizli Sağlık Yüksek Okulu, Fen Bilimleri Enstitüsü, Sosyal Bilimler Enstitüsü gibi akademik birimler bulunmaktadır. Akademik birimlerin yanı sıra Rektörlük, Genel Sekreterlik, Daire Başkanlıkları gibi idari birimler, Kamu Hizmeti ve Güvenlik Hizmetleri Müdürlüğü gibi müdürlüklerden ve PAÜ bünyesinde bulunan merkezlerden birçoğu yine Kınıklı kampüsünde bulunmaktadır.

PAÜ Kınıklı kampüsünde okuyan öğrenci ve çalışan personellere günlük yemek ihtiyacını karşılayacak sabah çorbası, öğle yemeği, akşam yemeği, hızlı yemek ve kafeterya hizmetleri PAÜ Sağlık Kültür ve Spor Daire Başkanlığı Beslenme Hizmetleri Şube Müdürlüğü (SKS) tarafından sunulmaktadır. SKS tarafından işletilen merkez yemekhanesinde 450 kişilik beyaz salon, 900 kişilik kırmızı salon, 700 kişilik yeşil salon, 220 kişilik turuncu salon bulunmaktadır. Merkez yemekhane dışında Kınıklı kampüsü morfoloji binasında bulunan mor salonun kapasitesi ise 700 kişiliktir. Beyaz, kırmızı, yeşil ve mor salonda tabldot yemek, turuncu salonda ise alakart servis vardır. Ay kafe, beyaz kafe, PAÜ kafede ise kafeterya hizmetleri ve hızlı yemekler servisi vardır (Url 2015^c). Bazı günler kuyruklar oluşmakta bazı günler ise sayıda ciddi düşüşler yaşandığı gözlemlenmektedir. 26.06.2014 tarihinde 12:47'de çekilen Şekil 1.1:'deki fotoğrafta ana yemeğin ızgara köfte olduğu gün kırmızı salondaki kuyruk görülmektedir.



Şekil 1.1: Yemek kuyruğu

Yemekhanelerde tabldot yemeği tercih etmeyen öğrenci veya personeller kafeleri tercih edebilmektedir. Kafeler ve yemekhaneler SKS tarafından işletildiğinden kafelerde ve yemekhanelerde yenilebilecek yemek miktarını önceden tahmin etmek zaman ve masraf açısından tasarruf ettirecektir. Yemek miktarlarının önceden tahmin edilmesi için daha önce yenilen yemeklerin sayısı ve yemekhanelerin veya kafelerin tercih edilmesindeki diğer etkenlerin ortaya çıkarılması gerekmektedir.

PAÜ 2009 yılında normal kimlik kartlarından akıllı kimlik kartlarına geçiş yapmıştır. Akıllı kartlarına para yüklemesi yapan personeller ve öğrenciler kimlik kartları ile yemekhanelerde ve kafelerde yemek yiyebilmektedirler. Özel bir bilişim firmasından satın alınan bu hizmet sayesinde gün bazında yemek yiyen öğrenci ve personel sayısı veri tabanına kaydedilmektedir.

Yemekhanenin ve kafeteryanın tercih edilmesinde daha önce bahsedilen beslenme ve yemek seçimini etkileyecek etkenlerin neler olabileceği düşünülmüş ve 11 ayrı etken tanımlanmıştır. Bu etkenlerin neler olduğu ve yemek yiyen personel sayısı üzerinde etkisi Deney bölümünde verilerin hazırlanılması kısmında detaylı şekilde anlatılacaktır.

1.6 Kullanılan Yöntemler

Bu kısımda çalışmada talep tahmini için kullanılan yöntemlerden kısaca bahsedilmiştir. Bu yöntemler ileride detaylı bir şekilde anlatılacaktır.

YSA insan beynine benzer bir yapıda çalışan bilgisayar sistemleridir. YSA örnek verilere göre kendi deneyimlerini oluşturup benzer konuda benzer kararlar verebilir (Öztemel 2006). YSA giriş parametreleri ile çıkış parametreleri arasında ilişki kurma yeteneği sayesinde günlük hayatın birçok alanında başarılı şekilde kullanılmaktadır (Filiz 2013). YSA ile yapılan çalışmalarda doğru ağ çeşidinin seçimi problemin çözümünde çok önem teşkil eder. YSA içerdiği yapay sinir hücrelerinin birbirine bağlantı şekline göre ileri ve geri beslemeli olarak sınıflandırılır. İleri beslemeli ağlarda yapay sinir hücreleri girişten çıkışa doğru düzenli katmanlar şeklindedir ve bir katmandan sadece kendinden sonraki katmanlara bağlantı bulunmaktadır. Geri beslemeli yapay sinir ağlarında ise yapay sinir hücresinin çıktısı kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir yapay sinir hücresine girdi olabilir. Bu çalışmada ele alınan talep tahmin problemi için ileri beslemeli YSA türlerinin yeterli olacağı düşünülmüş ve bu yapıda olan Radyal Tabanlı Fonksiyon Yapay Sinir Ağları (RTFYSA) ve Çok Katmanlı Yapay Sinir Ağları (ÇKYSA) kullanılmıştır.

Regresyon iki veya daha fazla değişken arasında ilişkinin bulunup bulunmadığını test etmek ve değişkenler arasındaki ilişkiyi doğrusal veya eğrisel denklemlerle ifade etmek için kullanılan yöntemlerden biridir (Öztürkcan 2009). Bu çalışmada doğrusal regresyon (DR) kullanılmıştır ve belirlenen değişkenler regresyon modelinde çoklu doğrusal regresyon (ÇDR) ve etkileşimli doğrusal regresyon (EÇDR) modeliyle test edilmiştir.

YSA ve Regresyon modellerinde PAÜ personellerinden tabldot yemek yiyen personelin sayısı üzerinde etkili olabileceği düşünülen etkenler giriş parametreleri, yemek sayısı ise çıkış parametresi olarak tanımlanmıştır. YSA ve Regresyon yöntemleri ile tahminleme yapılmadan önce verilerin aralarında istatistiksel olarak ilişkili olup olmadığı Statistical Package for the Social Sciences (SPSS) programı ile test edilmiştir. Veri seti SPSS programında uygun veri

formatlarıyla tanımlanmış aralarındaki ilişki istatistiksel yöntemlerle test edilmiştir. Test sonuçları çalışmanın deney bölümünde bulunmaktadır.

1.7 Hata Ölçüm Fonksiyonu

Bu çalışmada YSA ve DR ile tasarlanan sistemlerin hata ölçümlerinde hata kareler ortalamasının karekökü (Root Mean Square Error - RMSE) kullanılmıştır. RMSE hesaplanması (1.1) de vardır (Takma 2012).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_{g,i} - X_{m,i})^2}{N}} \quad (1.1)$$

Burada;

X_g : Tahminleme yapılan sistemin gerçek değerleri

X_m : Modelin tahmin ettiği değerleri

N : Gözlem sayısını ifade etmektedir.

2. LİTERATÜR ÇALIŞMASI

Bu bölümde YSA ve Regresyon modeliyle daha önce yapılan çalışmalar incelenmiş ve çalışmaların sonuçları yazılmıştır.

ÇKYSA kullanılan bu çalışmada (Karahana 2011) Malatya ili kuru kayısı talep tahmini çalışması yapılmıştır. Kuru kayısı talep miktarını etkileyecek bağımsız değişkenler geçmişteki talep miktarına ait tarih bilgileri, Amerikan doları aylık kur bilgileri, aylık ortalama ürün satış fiyatı, satış yapılan pazar sayısı ve mevsimsel etkiler tanımlanmış ve ağa giriş verileri olarak sunulmuştur. Ağın çıkış verisi ise ilgili tarihte kuru kayısı talep miktarı olarak belirtilmiştir. 2004-2011 yılları arası 84 aylık veri alınmış rastgele seçilen 70 aylık veri eğitim ve kalan 14 aylık veri test için kullanılmıştır. Hata ölçüm fonksiyonu olarak RMSE kullanılmıştır. 2011 yılının ilk 6 ayı tahmin edilmiştir.

Türkiye'deki bakanlık belgeli konaklama işletmelerindeki dış turizm talebi ile oluşan doluluk oranı tahmin edilmiştir (Çuhadar ve Kayacan 2005). Kültür bakanlığından alınan 1990-2002 yılları arasındaki 144 aylık veri kullanılmıştır. Verilerin %80 i eğitim %20 si test için kullanılmıştır. Doluluk oranı tahmini için bakanlık belgesi tesislerin aylık sayısı, aylık yatak sayısı, yabancı turistlerin aylık sayısı, aylık toplam geceleme sayısı, turistlerin ortalama kalış süresi olmak üzere beş adet giriş verisi kullanılmıştır. Çalışmada ÇKYSA kullanılmıştır. Yapılan çalışmada RMSE =1,9 olarak bulunmuş modelin gerçeğe çok yakın tahminler ürettiği belirtilmiştir.

Elektrik Enerji Sistemlerinde tüketilecek elektrik enerji miktarı tahmini yapılmıştır (Pınarbaşı 2009). Çalışmada iki katmanlı ÇKYSA ve ÇDR kullanılmıştır ve sonuçlar gerçek değerler ile karşılaştırılmıştır. Türkiye İstatistik Kurumu, Devlet Planlama Teşkilatı, Türkiye Elektrik İletim A. Ş. verileri kullanılmıştır. 1980 sonrası elektrik enerji verileri kullanılmış 1980 – 2008 arası eğitim için kullanılmış 2009-2012 arası tahmin edilmeye çalışılmıştır.

Otomobil Satış Tahmini yapan çalışmada (Karaatlı 2011) otomobil satışını etkileyen değişkenler gayri safi yurt içi hâsıla, döviz kuru fiyatları, tüketici güven

endeksi, yatırım harcamaları, tüketim harcamaları ve zaman olarak belirlenmiştir. Yapay sinir ağıları herhangi bir ön varsayıma ihtiyaç duymadığı halde bu çalışmada Durwin-Watson testi yapılarak hata terimlerinin otokolere olup olmadığı incelenmiştir. Test istatistiği 2,428 ile 1,5 -2,5 Aralığında çıkmış ve hata terimlerinin rassal olduğunu görülmüştür. Böylece yapılan tahminin güvenilir bir tahmin olduğu söylenmektedir. Çalışmada 54 aylık veri kullanılmış, verilerin %80'i öğrenme, %20'si test verisi olarak belirlenmiştir. Ölçümlere göre RMSE=0,00572 olarak bulunmuştur. Bu çalışmada yapılan otomobil satış tahminlerinin gerçeğe yakın şekilde yapılabileceği söylenmektedir.

Las Vegas'taki bir kumarhanenin büfesi için talep tahmini yapılmıştır (Hu ve diğ. 2008). 1 Haziran 2000 ile 31 Ocak 2002 tarihleri arasındaki veriler kullanılmıştır. Büfedeki müşteri sayısı oranı, dolu oda sayısı, özel gün kutlamasının olup olmaması, haftanın hangi gününde olduğu bilgisi tahminlemede giriş verisi olarak kullanılmıştır. Birçok tahminleme çalışmasında olduğu gibi bu problem bu çalışmada da zaman serisi problemi olarak alınmış ve yapılan 8 farklı çalışmanın 6 tanesi zaman serisi problemi olarak ele alınmış ve çözüm sunulmaya çalışılmıştır. Kalan iki yöntemde ise regresyon ve log lineer regresyon yöntemleri uygulanmış sonuçlar karşılaştırılmıştır. Hata fonksiyonu olarak ortalama mutlak hatanın yüzdesi ve karesel hatanın karekökünün yüzdesi kullanılmıştır.

Kongrelerdeki öğle yemekleri talep tahmini yapan (Blecher 2004) çalışmada araştırmacı farklı matematiksel yöntemler ile tahmin çalışması yapmıştır. Bunlar tüm yenilen gerçek değerlerin ortalaması, en son talep, haftanın aynı günü yenilen son 3 günlük ortalama, son 5 günün ortalaması, son 5 haftanın aynı günün en yüksek ve en küçük değerlerinin çıkartılıp 3 e bölünmesi, ortalama karesel hata (MSE) değerini en küçük yapacak Alpha değeri olarak belirlenmiştir. Bu beş yöntem ile yemeği talep miktarını tahmin edilmeye çalışmış ve MSE ile Ortalama Mutlak Sapma değerleri karşılaştırılmıştır.

Yapay Sinir Ağları ve Destek Vektör Makinaları (SVM) kullanarak İstanbul Borsası'ndaki veriler ile yapılan çalışmada (Kara ve diğ. 2011) 1997-2007 yılları arasındaki 100 farklı index verileri kullanılmıştır. Her 2 model içinde 10 farklı giriş verisi kullanılmış sonuçları karşılaştırılmıştır. Sonuç olarak YSA ile yapılan modelin SVM ile yapılan modelden daha iyi olduğu ortaya konulmuştur.

Yapay Sinir Ağları ile yapılan tahmin çalışmalarını bir arada toplamak amacı ile çalışma yapılmıştır (Zhang ve Patuwo 1998). Yapılan çalışmaları ağ mimarileri, veri tipleri, giriş hücre sayısı, gizli katman hücre sayısı, çıkış hücre sayısı, transfer fonksiyonu, eğitim algoritması, normalizasyon fonksiyonu, performans fonksiyonlarına göre gruplanıp karşılaştırmıştır. Sonuçların klasik istatistiksel yöntemlere göre değerlendirmeleri her bir çalışma için araştırılıp tablo halinde verilmiştir. Araştırmada çalışmalarda verilen %90 - %10, %80 - %20, %70 – %30 eğitim – test kümesi olarak ayrıldığı belirtilmiştir.

Bir başka makalede Soya fasulyesinden yapılan ürün çeşitlerinin (Soya fasulyesi, soya unu, soya yağı) ilk ve son fiyatları, her bir ürün çeşidinin kayıpları ve soya fasulyesi ve soya fasulyesi ürünleri arasındaki fiyat farkı giriş verisi olarak kullanılmıştır. Her bir ürün için kar payları hesaplanmaya çalışılmıştır. YSA tekniklerinden RTFYSA ve Levenberg-Marquardt (LM) algoritması kullanan ÇKYSA kullanılmıştır. İki farklı yöntemin sonuçları karşılaştırılmıştır (Wilesa ve Enkeb 2014).

Araç yakıt tüketimi tahmininin radyal tabanlı yapay sinir ağları ile tahmin edildiği çalışmada (Wu ve Liu 2012) aracın tüketim değerlerini sürüş modu, aracın motor tipi, aracın ağırlığı, araç tipi, aktarım şekli olarak düşünülmüş oluşturulan yapay sinir ağlarına giriş verisi olarak verilmiştir. Verilerin tamamı, yarısı, üçte biri eğitim kümesi olarak düşünülmüş RTFYSA ve Geri Beslemeli Yapay Sinir Ağları ile ayrı ayrı eğitilmiş sonuç verileri karşılaştırılmıştır. Sinir ağlarının tahmindeki başarıları yanında hesaplama süreleri de karşılaştırılmıştır. Sonuç olarak RTFYSA ile hem daha hızlı hem de daha gerçekçi tahminler elde edildiği vurgulanmıştır.

Gıda hizmeti verilen kurumları inceleyen çalışmada (Engstrom ve Carlsson-Kanyama 2009) kurumların gıda kayıpları incelenmiştir. İsveç'te yapılan çalışmada iki okul ve iki restoran mutfağı incelenmiş ve kayıplar 5 farklı şekilde sınıflandırılmıştır. Çalışma sonucunda %11 - %13 arasında tabakta yemek bırakmak en büyük kayıp ile birinci sırada çıkmıştır. Yemeklerin kişilerin beğenisine göre tahminin gıda kayıplarını engelleyebileceği söylenebilir.

3. YÖNTEM

3.1 Yapay Sinir Ağları

YSA bir programcının geleneksel yeteneklerine ihtiyaç duymadan kendi kendine öğrenebilen bilgisayar sistemleridir. Öğrenmenin yanı sıra ezberleme ve veriler arasında ilişki kurma yeteneğine sahiptir. Bu yetenekler geleneksel yöntemlerde oldukça zordur ya da imkânsızdır. Bu nedenle, YSA geleneksel yöntemlerle hesaplanması zor olan olaylar için geliştirilmiştir denilebilir.

YSA insan beyninin öğrenerek yeni bilgiler türetebilme yeteneğine benzer bir mantık ile çalışan bilgisayar sistemleridir. İnsan beyninden esinlendiği için insan beynindeki sinir hücrelerine benzer yapay sinir hücreleri vardır ve YSA bu hücrelerin birbirine bağlanması ile oluşur (Elmas 2003),(Öztemel 2006).

3.1.1 Yapay Sinir Ağlarının Genel Özellikleri ve Kullanım Alanları

YSA'nın kullanılan ağ modeline göre bazı farklı özellikleri ortaya çıksa da her durumda geçerli temel özellikleri aşağıdaki gibi sıralanabilir.

- YSA'nın kullanıma alınması için eğitilmesi ve test edilmesi gerekmektedir. Mevcut örnekler eğitim ve test kümesi olarak iki ayrı sete ayrılır. Ayrılan setlerden eğitim kümesi ile ağ eğitilir ve ağ bütün örneklere doğru cevaplar vermeye başladıysa eğitim işi tamamlanmış olarak kabul edilir. Ağ daha önce hiç görmediği test kümesindeki verilere kabul edilebilir bir ölçüde doğru cevaplar veriyorsa ağın performansı iyi kabul edilir ve kullanıma alınır.
- Görülmemiş örnekler hakkında bilgi üretebilir.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler. Bir şeklin eksik kalan kısmını tamamlayabilirler.

- Eksik bilgi ile çalışabilirler.
- Hata toleransına sahiptir.
- Dereceli bozulma gösterirler. Bir hata ortaya çıkınca ağ büyük bir hata ile birden bozulmaz.
- Dağıtık belleğe sahiptir. Bilgi tüm ağa yayılmış durumdadır.
- Sadece nümerik bilgi ile çalışırlar. Sembolik ifadelerin sayısal karşılıklarının olması gerekmektedir (Öztemel 2006).

YSA bu üstün özellikleri ile sınıflandırma, ilişkilendirme veya örüntü işleme, sinyal filtreleme, veri sıkıştırma, örüntü tanıma, doğrusal olmayan sinyal işleme, doğrusal olmayan sistem modelleme, optimizasyon vb. fonksiyonları yerine getirmektedir

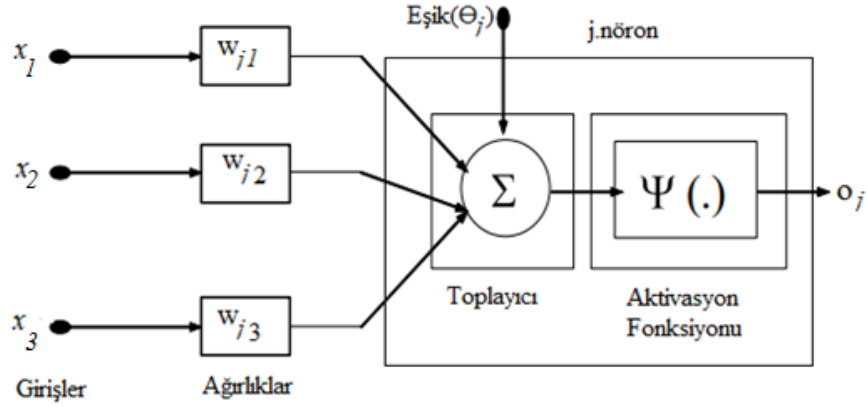
YSA doğrusal formda olmasa bile tek veya çoklu giriş parametreleri ile tek veya çoklu çıkış parametreleri arasında ilişki kurabilme yeteneğine sahiptir. Bu yetenek sayesinde mühendislik, imalat, tıp, tıbbi görüntü işleme, tıbbi tanı koyma, biyomedikal uygulamalarda, tarımsal alanda, askeri alan gibi birçok alanda kullanılmaktadır (Filiz 2013).

YSA'nın kullanıldığı alanlar veri madenciliği, optik karakter tanıma ve çek okuma, banka kredisi müracaatları değerlendirme, ürünün pazardaki performansını tahmin etme, kredi kartı hileleri saptama, zeki araçlar ve robotlar için rota tahmini, güvenlik sistemlerinde ses ve parmak izi tanıma, robot hareket mekanizmaları kontrolü, mekanik parça ömrü tahmini, kalite kontrolü, iş çizelgesi ve iş sıralaması, iletişim kanallarındaki trafik yoğunluğunu kontrolü, radar ve sonar sinyalleri sınıflandırma, üretim planlama ve çizelgeleme, kan hücreleri reaksiyonları ve kan analizi sınıflandırma, kanserin saptanması ve kalp krizlerinin tedavisi, beyin modellemesi çalışması, el yazısı ve imza tanıma, ürün üretimi ve satış tahmini olarak belirtilebilir (Öztemel 2006),(Elmas 2003).

3.1.2 Yapay Sinir Ağları Mimarisi

Daha önce belirtildiği gibi YSA yapay sinir hücrelerinden oluşur. Bir yapay sinir hücresi yapı olarak biyolojik sinir hücrelerinden esinlenerek

oluşturulmuştur. Biyolojik sinir hücresi girdi sinyallerini alan kısım (dentrit), girdi sinyallerini işleyen kısım (çekirdek) , girdi sinyallerini çıktı sinyaline çeviren kısım (akson) , diğer sinir hücreleri arasında iletim yapan kısım (bağlantı) olmak üzere dört elemandan oluşmuştur. Yapay sinir hücresinin yapısı da Şekil 3.1’de görüldüğü üzere bu dört yapıya benzer bir yapı ortaya koymaktadır (Başaran 2007).




Şekil 3.1: Yapay sinir ağları hücre mimarisi

Şekil 3.1’de girdiler x_i ($i=1,2, \dots ,n$) ve i . girdinin j . yapay sinir hücresi giriş ağırlığı w_{ji} ile gösterilmiştir. En basit yapıda girdi değerleri ve ağırlıklarının çarpımı toplanmakta ve bir aktivasyon fonksiyonuna gönderilerek sonuç üretilmektedir.

McCullogh ve Pitts tarafından 1943 yılında tanımlanan bu yapı bir biyolojik sinir hücresinin genel matematiksel yapısı olarak adlandırılabilir (Başaran 2007). Bu yapıda aktivasyon fonksiyonu olarak birim adım fonksiyonu, toplama fonksiyonu olarak lineer fonksiyon seçilmiştir. Ağırlıklı toplamların belli bir eşik değerin altında veya üstünde olma durumuna göre çıktı iki ihtimal arasından seçilmektedir. Yapay sinir hücrelerinde uygulama konusuna ve veri setine göre farklı toplama ve aktivasyon fonksiyonu kullanılabilir. Örneğin aktivasyon fonksiyonu olarak hiperbolik tanjant, sigmoid vb. fonksiyonlar ve toplama fonksiyonu olarak maksimum, minimum, ortalama vb. fonksiyonlar kullanılabilir (Başaran 2007).

Yapay sinir hücreleri birbirlerine bağlanarak yapay sinir ağını oluşturur. İleri beslemeli bir ağda genel olarak giriş, gizli ve çıkış katmanları olarak üç katman

vardır. Gizli katman sayısı istenirse artırılabilir. Üç katmanlı; giriş katmanı 6 yapay sinir hücresinden gizli katmanı 3 yapay sinir hücresinden çıkış katmanı 2 yapay sinir hücresinden oluşan örnek ağ Şekil 3.2'deki gibidir. Giriş katmanı; verilerin ağı girildiği katmandır. Veriler işlenmeden bir sonraki gizli katmana aktarılır. Gizli katman; bu katman ve katmandaki yapay sinir hücre sayısı ve probleme göre değişebilir, bu katman giriş katmanındaki veriyi uygun fonksiyonla işleyerek bir sonraki katmana ulaştırmakla görevlidir. Çıkış katmanı; gizli katmandan alınan veri ağı kullandığı fonksiyonda işlenerek çıktıyı oluşturur. Çıkış katmanındaki yapay sinir hücre sayısı ağı girişteki veri kümesinin çıkış sayısı kadardır.



Şekil 3.2: Yapay sinir ağları genel mimarisi

3.1.3 Yapay Sinir Ağlarının Sınıflandırılması ve Uygun Ağ Seçimi

YSA'lar öğrenme yöntemleri ve yapılarına göre sınıflandırılabilirler (Elmas 2003), (Khare 2007). Yapılarına göre sınıflandırılması Tablo 3.1'de öğrenme yöntemlerine göre sınıflandırılması ise Tablo 3.2'de gösterilmektedir.

Tablo 3.1: Yapılarına göre yapay sinir ağları

İleri Beslemeli Ağlar	Tek Katmanlı Ağlar Çok Katmanlı Ağlar Radyal Tabanlı Fonksiyon Sinir Ağları
Geri Beslemeli Ağlar	Rekabetçi Ağlar Kohenen Ağı Hopfield Ağı ART Modeli

Tablo 3.2: Öğrenme yöntemlerine göre yapay sinir ağları

Danışmalı Öğrenme	Danışmalı Öğrenme Perceptron Çok Katmanlı Perceptron Geri Yayılım Ağı Daha Yüksek Düzeyli Sinir Ağı İşlevsel Bağ Ağı
Danışmasız Öğrenme	Hopfield Ağı Olasılıksal Sinir Ağı Uyarlanır Rezonans Ağı Öz örgütlemeli Harita Ağı Boltzmann Makinesi Hamming Ağı Geri yayma İçine Öz örgütlemeli Harita Ağı İki Yönlü Çağrışım Belleği Yığın Ağı Karşı Yayma Ağı Öğrenme Vektör Nicelendirmesi (LVQ) Rekabetçi Öğrenme Ağları

Tablo 3.3: YSA uygulama alanları

Kullanım Amacı	Ağ türü	Ağın kullanımı
Tahmin	ÇKA	Ağın girdilerinden bir çıktı değeri tahmin edilmesi
Sınıflandırma	LVQ ART Olasılık Sinir Ağları	Girdilerin hangi sınıfa ait olduklarının belirlenmesi
Veri ilişkilendirme	Hopfield Boltzmann Makinesi İki Yönlü Çağrışım Belleği	Girdilerin içindeki hatalı bilgilerin bulunması ve eksik bilgilerin tamamlanması

Hangi tip problemin çözümünde hangi tip ağıın kullanılacağını bilmek uygulamada başarılı sonuçlar elde etmek için önemlidir. Bazı durumlarda yanlış ağ seçimi yüzünden zaman kaybı yaşanmakta ve YSA'nın başarısız sonuçlar verdiği söylenmektedir. Bu doğru bir yaklaşım değildir. Doğru ağ modeli, doğru örnek seti ve doğru bir öğrenme algoritması kullanılarak çözülemeyecek problem yok denecek kadar azdır (Öztemel 2006). Ağların başarılı oldukları alanlar Tablo 3.3'te verilmiştir.

3.1.4 Uygulamada Kullanılan Yöntemler

3.1.4.1 Geriye Yayılım Algoritması

İlk olarak Werbos tarafından düzenlenmiş ve sonra Parker, Rummelhart ve McClland tarafından geliştirilmiştir. Anlaşılması kolay olması ve matematiksel ispatı olduğundan dolayı en çok tercih edilen öğretilme algoritmasıdır. Bu algoritmada hatalar geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geriye yayılım ismini almıştır. Geriye yayılım öğrenme kuralı ağ çıkışındaki mevcut hatalara göre her bir tabakadaki ağırlıkları yeniden hesaplamaktadır (Karaatlı 2012). Geriye yayılım algoritması 7 adımla özetlenebilir.

- 1- Ağ ağırlıklarının başlangıç değerlerini hazırla.
- 2- İlk eğitim vektörünü ağa uygula.
- 3- Çıkış elde etmek için ağı kullan.
- 4- Gerçek çıkışla ağın çıkışlarını kullanarak bir hata sinyali oluştur.
- 5- Hata sinyalini ağa uygula
- 6- Eğim düşüm algoritması ile toplam hatayı düşürecek şekilde ağ ağırlıklarını değiştir.
- 7- Hata oranı kabul edilebilecek bir seviyeye düşene kadar ağa giriş vektörlerini uygulamaya devam et (Khare 2007).

Bir geriye yayılım algoritmasının kullanıldığı ileri beslemeli bir ağda gereğinden daha az yapay sinir hücresi kullanılmış ise verilere göre daha az hassas çıkış elde edilir. Çok sayıda yapay sinir hücresi kullanılırsa yeni tip verilerin

işlenmesi zor olur. İleri beslemeli geriye yayımlı bir ağda aradaki katmanlar atlanarak bir sonraki ağa geçilemez. Veri ilk olarak giriş katmanına uygulandıktan sonra çıkış katmanına kadar çeşitli işlemlere tabi tutulur. Bu işlemler sonucunda oluşan çıktı ile gerçekte olması gereken çıktı arasındaki fark her bir düğüm için bir hata işareti olarak hesaplanır. Toplam hata her düğüm hatanın belli bir oranını bulunduracak şekilde ara katmandaki düğümlere doğru geriye aktarılır. Bu şekilde giriş katmanına kadar düğümler hatanın belli bir oranına sahip olur. Elde edilen oranlara göre bağlantı ağırlıkları yeniden düzenlenir.

İleri beslemede ilk giriş katmanı verileri direk gizli katmana aktarır. Gizli katman ise kendi giriş değerini ağırlıklandırarak bir sonraki katmana ya da birden fazla katman bulunmuyorsa direk çıkış katmanına aktarır. Katmanlar arasındaki ağırlıklar başlangıçta çok küçük değerler olarak seçilir (Başaran 2007).

İleri beslemeli ağların öğrenme algoritmaları performans fonksiyonunu minimize etmek için performans fonksiyonunun gradyenini kullanırlar. Geriye yayılım algoritmasında da en basit geriye yayılım algoritması olan eğim düşüm (gradient descent) algoritması kullanılır (Yurdakul 2009). Çıkış katmanında çıkış değeri hesaplanarak mevcut hata minimize edilir. Hata kabul edilebilir sınırlar içinde ise ağ denemeye alınabilir (Başaran 2007).

Standart geriye yayılım algoritması birçok problem için yavaş kalmaktadır. Bu yüzden alternatif olarak daha hızlı algoritmalar geliştirilmiştir. Bunlar deneme yanılma teknikleri kullanan algoritmalar ve standart sayısal optimizasyon yöntemleri kullanan algoritmalar olarak iki gruba ayrılırlar. Deneme yanılma yöntemi kullanan algoritmalar momentum terimli, öğrenme hızı değişen, esnek algoritmalar, standart sayısal optimizasyon tekniği kullananlar ise eşlenik gradyen, Newton, Gauss-Newton ve Levenberg–Marquardt (LM) öğrenme algoritmasıdır (Doğan 2010).

Bu çalışmada da çoğu ileri beslemeli ağda kullanıldığı gibi performans fonksiyonu olarak MSE kullanılmıştır. MSE formül 3.1 den bulunabilir.

$$E(t) = E_{ort}(t) = \frac{1}{N} \sum_1^N \frac{1}{2} \sum_{j \in C} (e_j^s(t))^2 \quad (3.1)$$

Burada e_j hata işareti, C ise ağın çıkış katmanındaki yapay sinir hücrelerinin tümüdür. $o_j^s(t)$ t . anda s . örnek için ağın j . çıkışına ait tahmin değeri, y_j^s s . örneğe ait j . çıkışın gerçek değeri olmak üzere t . anda s . örnek için ağın j . çıkışına ait tahmin hatası

$$e_j^s(t) = o_j^s(t) - y_j^s \quad (3.2)$$

şeklinde elde edilir.

3.1.4.1.1 Momentum ve Öğrenme Katsayılı Algoritma

Momentum katsayısı (m) ve öğrenme katsayısı (n) kullanan geriye yayılım algoritmasının matematiksel olarak aşağıdaki şekilde açıklanmaya çalışılmıştır.

Algoritma ile i ve j katman yapay sinir hücreleri arasındaki ağırlıklardaki $\Delta w_{ji}(t)$ değişim formül 3.3' den hesaplanır.

$$\Delta w_{ji}(t) = n\delta_j x_i + m\Delta w_{ji}(t-1) \quad (3.3)$$

Eşitlikte n öğrenme katsayısı, m momentum katsayısı ve δ_j ara veya çıkış katmanındaki herhangi bir j yapay sinir hücresine ait faktördür. Eğer yapay sinir hücresi çıkış katmanında ise bu faktör eşitlik 3.4'teki gibi verilir.

$$\delta_j = \frac{\partial E}{\partial net_j} (o_j^s(t) - y_j^s) \quad (3.4)$$

Eşitlik 3.4'te $net_j = \sum x_j w_{ji}$. Ara katmanlardaki yapay sinir hücreleri için ise bu faktör eşitlik 3.5'teki gibi verilir.

$$\delta_j = \left(\frac{\partial E}{\partial net_j} \right) \sum w_{qi} \delta_q \quad (3.5)$$

Ara katmanlarda herhangi bir hedef çıkış olmadığından eşitlik 3.4 yerine eşitlik 3.5 kullanılır. Bu duruma bağlı olarak çıkış katmanından başlayarak δ_j

faktörü bütün katmanlardaki hücreler için hesaplanır. Formül 3.1 sayesinde bütün bağlantılardaki ağırlıklar hesaplanıp güncellenmiş olur.

Başarılı bir eğitim için n , m değerlerinin uygun değerler seçilmesi çok önem teşkil etmektedir. Bu katsayılar için uygun değerlerin seçilmesi deneysel olarak bulunabilir. Bu değerler problemlere göre değişebilir. Karmaşık problemlerde bu değerlerin küçük seçilmesi gerekmektedir (Sarioğlu ve diğ. 2003).

Öğrenme katsayısının ağ performansı üzerinde önemli etkisi vardır. n bağlantı ağırlıklarının değişim oranını belirler ve 0-1 arasında bir değer alır. n değerinin küçük seçilmesi ağın yavaş öğrenmesine büyük seçilmesi ise kararsızlık durumunun oluşmamasına neden olmaktadır.

Hesaplamalarda, m katsayısı ise ağın daha hızlı toparlanmasına yardım eden bir faktör olarak belirtilebilir. Bu sayede yerel minimum değerler bulunur ve ağın salınımı engellenir. m katsayısı da de 0-1 arasında bir değer alır. m değerinin yüksek seçilmesi ağın öğrenme hızını arttıracığından genelde yüksek seçilir. m 'nin ağın eğitimindeki adım sayısı ve toplam ağ hatasının düşmesinde olumlu etkileri vardır (Elmas 2003).

3.1.4.1.2 Levenberg-Marquardt Algoritması

Öğrenme algoritmaları önceki algoritmaların iyi yönlerini geliştirmeye çalışıp kötü yönlerini azaltarak kendilerinden önce ortaya çıkan algoritmaların alternatifi olmaya çalışmışlardır.

Eşlenik eğim düşünme algoritmasına alternatif olarak sunulan Newton yöntemlerinde temel amaç performans fonksiyonunun ağırlıklarına göre ikinci dereceden türevlerden oluşan Hessian matrisini (\mathbf{H}) (3.6) elde etmektir (Karaatlı 2012).

$$\mathbf{H}(t) = \frac{\partial^2 E(t)}{\partial \mathbf{w}^2(t-1)} \quad (3.6)$$

Levenberg Marquardt algoritması ağırlıkların hesaplanması Hessian matrisi ile hesaplandığında yavaş olduğu için Hessian matrisinin yaklaşık değeri şu şekilde bulunabilir:

$$\mathbf{H}(n) = \mathbf{J}^T(t)\mathbf{J}(t) + \mu\mathbf{I} \quad (3.7)$$

I: Birim matris
 μ : Marquardt parametresi.
J: Jakobian Matrisi

J ağ hatalarının ağırlıklarına göre birinci türevlerinden oluşan bir matristir ve şu şekilde hesaplanabilir:

$$\mathbf{J}(t) = \frac{\partial \mathbf{e}(t)}{\partial \mathbf{w}(t-1)} \quad (3.8)$$

Bu durumda gradyen vektörü (3.9) ile bulunabilir.

$$\mathbf{g}(t) = \mathbf{J}^T(t)\mathbf{e}(t) \quad (3.9)$$

Ağdaki sinir hücreleri arasındaki yeni bağlantı ağırlıkları aşağıdaki formülden hesaplanabilir:

$$\mathbf{w}(t+1) = \mathbf{w}(t) - [\mathbf{J}^T(t)\mathbf{J}(t) + \mu\mathbf{I}]^{-1}\mathbf{J}^T(t)\mathbf{e}(t) \quad (3.10)$$

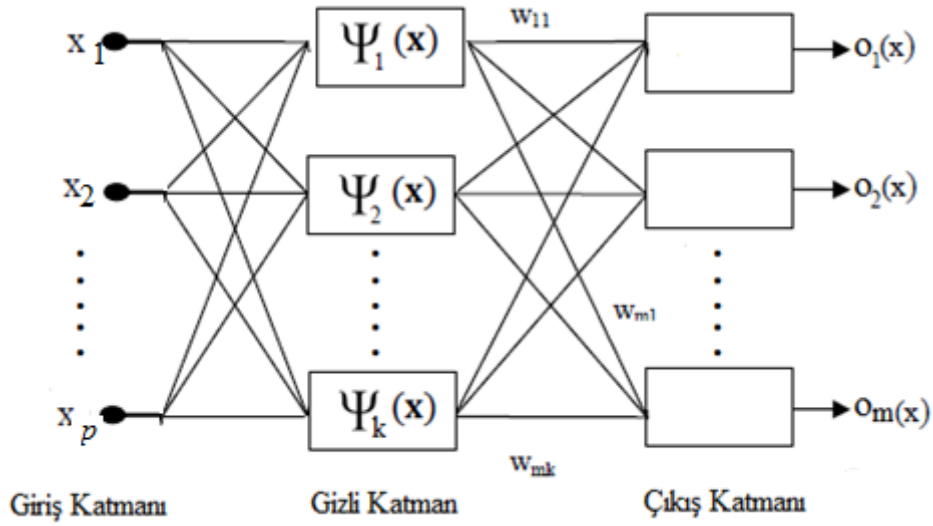
Yeni bağlantı ağırlıkları hesabında kullanılan μ skaler bir değişkendir. μ başlangıçta çok küçük bir değer olarak seçilir ve uygun değer bulunana kadar yeni ağırlık değeri eskisinden küçük ise 10 kat arttırılır büyük ise 10 kat azaltılır. Bu sayı sıfır olunca yöntem Newton yöntemi ile aynı çalışır. Bu algoritma diğer geri yayımlı algoritmalarından daha hızlıdır (Yurdakul 2009).

3.1.4.2 Radyal Tabanlı Fonksiyon Yapay Sinir Ağları

Günümüzde bilgisayarlar bilim ve mühendislik uygulamalarında yaygın kullanılmaktadır. Bu uygulamalarda daha etkili çözümler elde edilebilmesi için matematiksel fonksiyonlarının bilgisayar programlarında kullanılması daha önemli hale gelmiştir. Bir matematiksel fonksiyon birden fazla değişken veya parametreye bağımlı, birden fazla veri ile tanımlanmış ve dağınık yapıya sahip ise

bu fonksiyon Radyal Tabanlı Fonksiyon (RTF) yaklaşımına uygundur. RTF ilk olarak çok değişkenli gerçek bir interpolasyon çözümünde ortaya çıkmıştır (Buhmann 2009).

RTFYSA çok boyutlu uzayda eğri uydurma yaklaşımıdır. RTFYSA'nın eğitimi çok boyutlu uzayda verilere uygun en iyi yüzeyi bulma problemi olarak adlandırılabilir. RTFYSA giriş, gizli ve çıkış katmanı olmak üzere üç katmandan oluşan ileri beslemeli ağlardır. Giriş katmanı kaynak yapay sinir hücrelerinden oluşur. Radyal tabanlı fonksiyon yapay sinir ağları genel mimarisi Şekil 3.3'te vardır.



Şekil 3.3: Radyal tabanlı fonksiyon yapay sinir ağları genel mimarisi

Gizli katman yapay sinir hücre sayısı değiştirilebilen ve aktivasyon fonksiyonu olarak RTF kullanan gizli katmandır. Çıkış katmanı ise giriş değerlerine göre ağırlık çıkışının üretildiği kısımdır. Giriş katmanından gizli katmana doğrusal olmayan, gizli katmandan çıkış katmanına doğrusal dönüşüm söz konusudur (Okkan ve Dalkılıç 2012).

RTFYSA çalışma ilkesi; Giriş katmanındaki giriş değerlerine göre ara katmanda uygun genişlik ve merkez değerlerine sahip RTF belirlemek, belirlenen RTF'lerin çıktılarının uygun ağırlık değerleriyle doğrusal birleşimlerini oluşturup giriş değerleriyle çıkış değerleri arasındaki ilişkiyi belirleme olarak adlandırılabilir. RTFYSA çıktısı; giriş vektörü ile ara katmandaki merkezler arasındaki uzaklığın genelde Öklid mesafesi ile ölçülerek aktivasyon

fonksiyonundan geçirilerek bir çıktı elde edilmesi ve bu çıktının ara katman ile çıkış katmanı arasındaki ağırlıkla çarpılması ve bu çarpımların toplanması ile oluşur (Çetinkaya 2011). Bu toplamın denklemi formül (3.11) olarak gösterilmiştir.

$$o_j^s(t) = \sum_{i=1}^k w_{ji} \Psi_i(\|\mathbf{x}^s - \mathbf{v}_i\|) \quad (3.11)$$

Burada,

- \mathbf{x}^s : s . gözleme ait giriş vektörü
- w_{ji} : i . giriş ile j . radyal tabanlı fonksiyon yapay sinir hücresi arasındaki ağırlık
- \mathbf{v}_i : Radyal tabanlı ağdaki i . yapay sinir hücresi merkez vektörü
- $\Psi_i()$: Gizli katmandaki i . aktivasyon fonksiyonu

Gizli katmanda genel olarak aktivasyon fonksiyonu olarak Gaussian fonksiyonu kullanılmaktadır.

RTFYSA eğitimi iki aşamadan oluşmaktadır. İlk aşama olan gizli katmandaki merkez vektörlerin ve yayılım parametrelerinin bulunması için farklı yöntemler kullanılmaktadır. Bu yöntemler öz örgütlemeli merkez seçimi, eğitimcili seçim veya rastgele seçim yöntemlerinden biri olabilir. İkinci aşama olan gizli katman ile çıkış katmanı arasındaki ağırlıkları ayarlamak için ise En küçük ortalama kareler metodu, özyineli en küçük kareler metodu, orthogonal ortalama kareler metodu, en dik iniş metodu, hızlı yayılım algoritması, sözde ters metodu gibi farklı yöntemler kullanılmaktadır (Montazar ve diğ. 2008).

3.2 Regresyon Modeli

Değişken niceliklerin bulunduğu sistemlerde bazı değişkenlerin diğerleri üzerinde etkisinin incelenmesi gerekmektedir. Bu değişkenler arasındaki ilişki matematiksel modeller ile ifade edilmeye çalışılmaktadır. İki ya da daha fazla değişken arasında bir ilişkinin bulunup bulunmadığını test eden ve bunu doğrusal veya eğrisel olarak ifade eden denklemlere regresyon modeli denir (Öztürkcan 2009).

Regresyonda deęişkenlerin baęımlı deęişken ve baęımsız deęişken olarak iki gruba ayrılması bir zorunluluktur. Baęımlı deęişken, baęımsız deęişken tarafından açıklanmaya çalışılan deęişkendir. Regresyonda baęımlı deęişken y ve baęımsız deęişken de x ile gösterilir. x ile y arasındaki doğrusal ilişki $y=\alpha+\beta x$ olarak ifade edilir. Bu formül ile i . gözleme ait X_i deęeri için gerçek Y_i deęeri ile tahmin edilen \hat{y}_i deęeri aynı deęildir. Bu yüzden iki deęişken arasındaki formül (3.12) olarak verilebilir.

$$y_j^s = \hat{y}_j^s + e_j^s \quad (j=1, 2, 3, \dots, N) \quad (3.12)$$

$$\hat{y}_j^s = \alpha + \beta x_j^s$$

Formül 3.9'da;

\hat{y}_j^s : s . örnek için baęımlı deęişkenin j . tahmin deęeri
 e_j^s : s . örnek için j . tahmin hatası
 α, β : Regresyon katsayıları

Formül 3.12'de regresyon modelinin amaçlarından biri y_i ile x_i arasındaki ilişkiyi ortaya çıkarmaktır. Modelde yukarıdaki formüldeki gibi doğrusal bir ilişki öngörülüyorsa ilk amaç regresyon katsayıları olan α ve β 'yi bulmaktır.

3.2.1 En Küçük Kareler Yöntemi

Regresyon denkleminde katsayıların tanımının tamamlanması yani tahmin edilen katsayıların ve deęişkenlerin gerçek katsayılara en yakın şekilde hesaplanabilmesi için geliştirilen, literatürde en sık kullanılan yöntem En Küçük Kareler (EKK) yöntemidir. Başka bir deyişle EKK hata payı e 'yi minimum yapan yöntemdir. (3.13)' teki formülden bulunabilir.

$$S = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.13)$$

Bu fonksiyonun minimum olabilmesi için α ve β parametrelerine göre kısmi türevlerinin alınması ve bunların 0'a eşitlenmesi gerekir. Kısmi türevler alındıktan sonra (3.14) ve (3.15)' teki denklemler elde edilir.

$$\sum y_i = \alpha N + \beta \sum x_i \quad (3.14)$$

$$\sum x_i y_i = \alpha \sum x_i + \beta \sum x_i^2 \quad (3.15)$$

Bu denklemlere ‘normal denklemler’ denir. Normal denklemler yardımıyla α ve β deęerleri bulunduktan sonra $y = \alpha + \beta x$ denkleminde yerine yazılarak, istenen regresyon denklemleri elde edilmiř olur.

3.2.2 Çoklu Doğrusal Regresyon Modeli

Ekonomi ve iřletmecilik alanındaki herhangi bir baęımlı deęiřkeni tek baęımsız deęiřkenle açıklamak mümkün deęildir. Bir baęımlı deęiřkeni etkileyen iki veya daha fazla baęımsız deęiřken bulunduęu, baęımlı ve baęımsız deęiřkenler arasındaki iliřkilerini doğrusal bir modelle açıklanmaya çalışıldıęı ve bu baęımsız deęiřkenlerin etki düzeylerini belirlemek için yararlanılan yöntem ÇDR denir (Özdamar 2004).

ÇDR’ da iki temel amaç bulunduęu söylenebilir.

1. Baęımlı deęiřkenin baęımsız deęiřkenlerden hangisi ya da hangilerinin deęiřiminden daha çok etkiledięini bulmak.

2. Baęımlı deęiřkeni etkiledięi belirlenen baęımsız deęiřkenler yardımıyla baęımlı deęiřken deęerini tahmin edebilmek (Alpar 2003).

ÇDR’ da baęımlı deęiřken basit regresyondaki gibi Y ile gösterilir fakat baęımsız deęiřkenler x_1, x_2, \dots, x_p ile gösterilir. ÇDR formülü (3.16)’teki gibi olur.

$$y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_p x_{pi} + e_i \quad (i=1, 2, 3, \dots, N) \quad (j=1, 2, 3, \dots, p) \quad (3.16)$$

Burada:

x_{1i}, \dots, x_{pi} : Baęımsız deęiřkenlerin i . gözlem deęerini,
 β_0 : Regresyon doğrusunun y eksenini kestięi noktanın orijine

olan uzaklıęını,

β_1, \dots, β_p : Regresyon katsayısı olup bağımsız değişkendeki bir birimlik değişime karşılık bağımlı değişkende kendi birimi cinsinden meydana gelen ortalama değişim miktarlarını,

p : bağımsız değişken sayısını,

Bütün tahmini \hat{y} değerlerini hesaplayacak formül (3.17)'deki şekilde oluşur.

$$\hat{y} = \beta_0 \mathbf{1}_{N \times 1} + \beta_1 \mathbf{x}_1 + \beta_2 \mathbf{x}_2 + \dots + \beta_p \mathbf{x}_p \quad (3.17)$$

Burada \hat{y} tahmin edilen y değerleri vektörünü ifade etmektedir. (3.17)'deki formülün değişkenler matris şeklinde gösterimi şekildeki gibidir.

$$\mathbf{y} = \begin{bmatrix} y^1 \\ y^2 \\ \vdots \\ y^N \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & x_1^1 & \dots & x_p^1 \\ 1 & x_1^2 & \dots & x_p^2 \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ 1 & x_1^N & \dots & x_p^N \end{bmatrix}, \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_1 \\ \cdot \\ \cdot \\ \beta_p \end{bmatrix}, \mathbf{e} = \begin{bmatrix} e^1 \\ e^2 \\ \vdots \\ e^N \end{bmatrix} \quad (3.18)$$

(3.18)'deki parametre tahmini değerleri ($\hat{\boldsymbol{\beta}}$) 3.19'deki formül ile hesaplanabilir (Yıldırım 2010).

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \quad (3.19)$$

3.2.3 Etkileşimli Çoklu Doğrusal Regresyon Modeli

Etkileşimli Çoklu Doğrusal Regresyon Modelinde (EÇDR) Y bağımlı değişkene bir bağımsız değişkenin tek başına değil aynı anda başka bir bağımsız değişken ile birlikte daha farklı etkisinin olup olmadığını inceler.

Örnek olarak iki bağımsız değişkenli bir EÇDR formülü (3.20)'deki gibi oluşur.

$$Y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1 x_2 + e_i \quad (3.20)$$

4. GÜNLÜK YEMEK TAHMİNİ

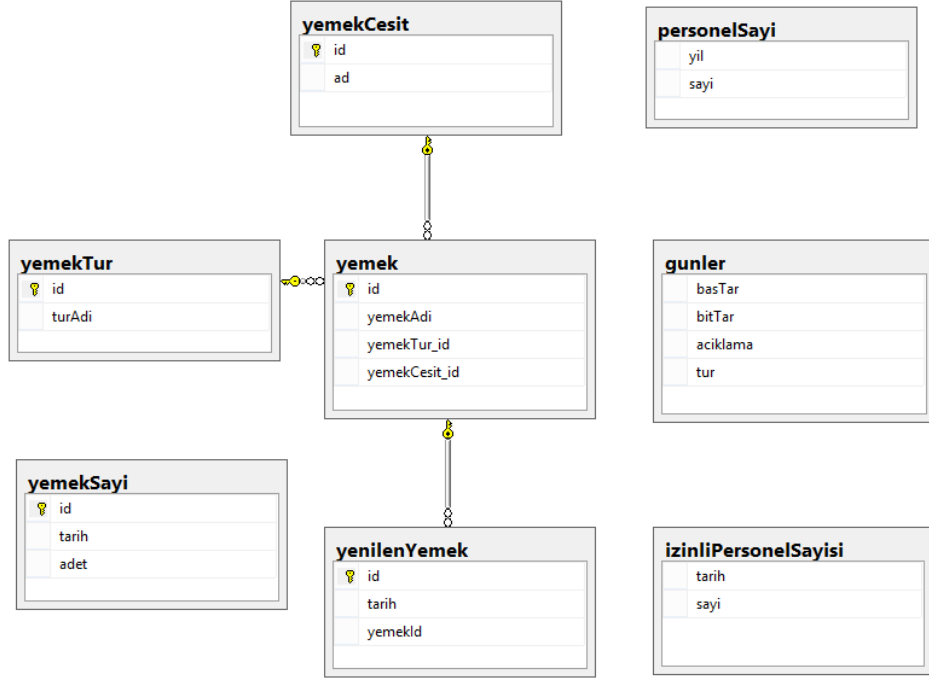
4.1 Verilerin Hazırlanması

PAÜ akıllı kimlik kartları veritabanı, PAÜ yemekhanesinde yenilen ve PAÜ web sitesinden yayınlanan yemek listesi, PAÜ Personel Bilgi Sistemi (PBS) verileri, PAÜ akademik takvimi ve Türkiye Cumhuriyeti Başbakanlık Diyanet İşleri Başkanlığı takvimi kullanılarak oluşturulmuştur. Verilerin ilişkisel olarak sorgulanıp hazırlanabilmesi için veritabanı yönetim sistemi olarak Microsoft SQL Server (MSSQL) seçilmiştir.

MSSQL de oluşturulan veri tabanında *yemek* adında tablo oluşturulmuştur. PAÜ web sitesinde günlük yayınlanan yemek isimlerindeki mükerrer kayıtlar düzeltilerek yemek tablosuna aktarılmıştır. Yemek türlerinin (ana yemek, yan yemek vb.) tutulduğu *yemekTur* tablosu ve yemek çeşitlerinin belirlenebileceği (et, sebze vb.) *yemekCesit* tabloları oluşturulmuştur ve oluşturulan *yemek* tablosuyla ilişkilendirilmiştir. Günlük yenilen yemekler için *yenilenYemek* tablosu oluşturularak yemek tablosuyla ilişkilendirilmiştir.

PBS den yıl bazında toplam personel sayıları alınıp *personelSayi*, *yemek* yenilen günlerdeki toplam izinli personel sayıları *izinliPersonelSayisi* tabloları oluşturulmuştur. İlgili yılların PAÜ akademik takvimleri ve ilgili yılların diyanet takvimi kullanılarak tarih bazında (tatil, sınav, ramazan ayı vb.) verilerin tutulduğu *günler* tablosu oluşturulmuştur.

Akıllı kart veri tabanından yemek sayıları alınıp hangi gün kaç yemek yenildiğini tutan *yemekSayi* tablosu oluşturulmuştur. MSSQL de oluşturulan veri tabanının diyagramı **Şekil 4.1**'deki gibidir.



Şekil 4.1: Veritabanı diyagramı

Kişilerin yemek yemesinde etkili olarak 11 etken düşünülmüş ve aşağıdaki Tablo 4.1’de açıklanmıştır.

Tablo 4.1: Yemek yemede etkili etken listesi

Ekten Adı	Açıklama
Ana Yemek	Yemekhanede çıkan ana yemek (Mevsim Türü, Kuru Fasulye, Güveç vb.)
Yan Yemek	Yemekhanede çıkan yan yemek (Bulgur Pilavı, Pirinç Pilavı, Makarna vb.)
Çorba	Yemekhanede çıkan çorba (Domates, Mercimek, Ezogelin vb.)
Tatlı Salata Meyve	Yemekhanede çıkan ana yemek, yan yemek ve çorba harici çeşit (Yoğurt, Salata, Sütlaç vb.)
Dönem	O tarihte üniversitenin tatil, sınav, ders döneminde olması.
Ramazan Ayı	O tarihin ramazan ayına denk gelmesi.
Maaş Dönemi	Devlet memurları maaşlarını her ayın 15 inde almaktadır. Maaş dönemi olarak her ayın 15 ile 25 arası düşünülmüştür.
Mevsim	Yıl içinde yaşanan mevsimler (Kış, İlkbahar, Sonbahar, Yaz)
Çeşit	Ana yemeğin çeşidi (et, sebze, karışık)
Toplam Personel	O tarihteki PAÜ de görev yapan idari ve akademik personel sayısı. Yılsonu alınan toplam personel sayısı o yılın her günü için aynı kabul edilmiş ve PAÜ toplam personel sayısı PAÜ Kınıklı kampüsündeki personel sayısı olarak kullanılmıştır.
İzinli Personel	Herhangi bir sebep ile izinli olan personel sayısı.

Kişiler yemekhanedeki yemeği tercih ederken yukarıdaki tablodaki etkenlerin olumlu ya da olumsuz etkisi olabileceği düşünülmüş veri tabanında ilgili sorgular yazılarak Tablo 4.2'deki liste oluşturulmuştur.

Tablo 4.2: Yemek listesi

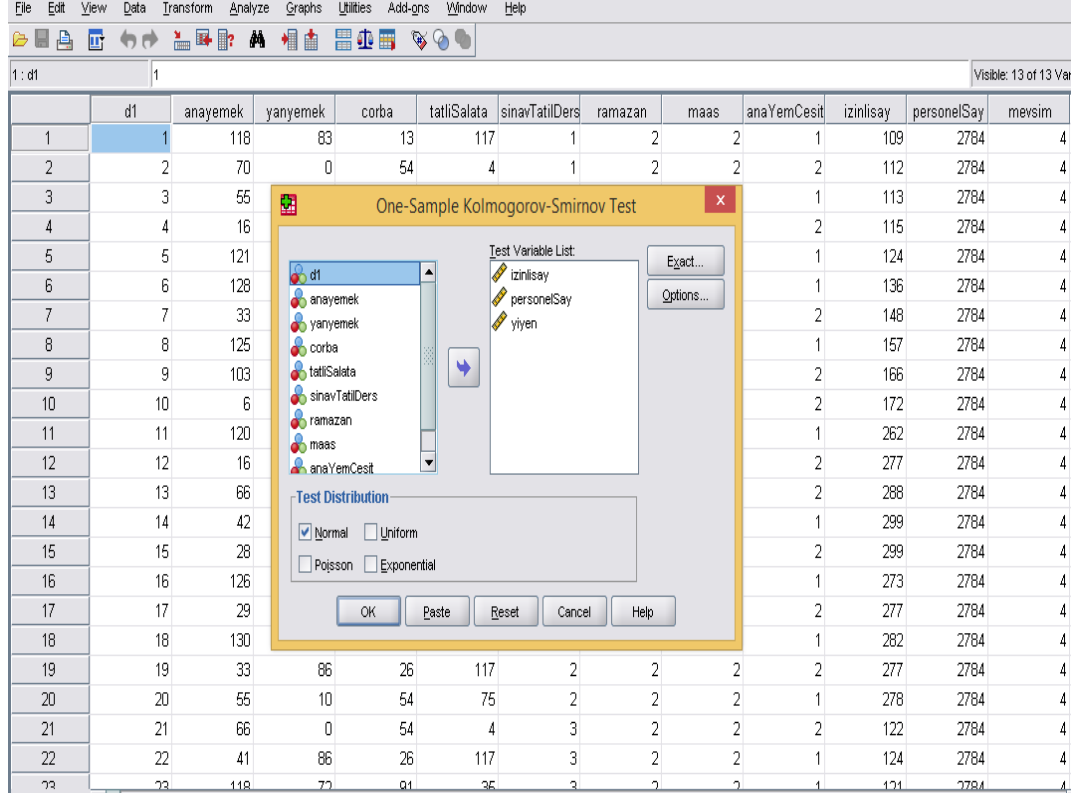
Tarih	Ana Yemek	Yan Yemek	Çorba	Tatlı Salata Meyve	Dönem	Ramazan Ayı	Maaş Dönemi	Mevsim	Çeşit	Toplam Personel	İznil Personel	Yemlen Yemek
11.01.2010	ZEYTİN YAĞLI TAZE FASÜLYE	SOSLU MAKARNA	DOMATES ÇORBA	YOĞURT	sinav dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	109	304
12.01.2010	PILAVÖSTÜ TAVUK DÖNER	SOSLU MAKARNA	MERCİMEK ÇORBA	AYRAN	sinav dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	112	391
13.01.2010	MEVSİM TÜRLÜ	BULGUR PILAVI	ŞEHİRİYE ÇORBA	SUPANGLE	sinav dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	113	342
14.01.2010	ELBASAN TAVA	PIRINÇ PILAVI	EZOGELİN ÇORBA	SALATA	sinav dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	115	418
15.01.2010	ZEYTİNYAĞLI BARBUNYA	SPAGETİ	SEBZE ÇORBA	CACIK	sinav dönemi	Ramazan Değil	Maaş Dönemi	Kış	sebze	2784	124	207
18.01.2010	ZEYTİNYAĞLI NOHUT	BULGUR PILAVI	EZOGELİN ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	Kış	sebze	2784	136	270
19.01.2010	IZGARA KÖFTE	PIRINÇ PILAVI	ŞEHİRİYE ÇORBA	SALATA	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	Kış	et	2784	148	373
20.01.2010	ZEYTİNYAĞLI KEREVİZ	ŞEHİRİYELİ GÜVEÇ	DOMATES ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	Kış	sebze	2784	157	236
21.01.2010	TAVUK KAVURMA	SPAGETİ	SEBZE ÇORBA	ELMA	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	Kış	et	2784	166	323
22.01.2010	BEZELYELİ KEBAP	BULGUR PILAVI	MERCİMEK ÇORBA	SÜTLAC	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	Kış	et	2784	172	268
25.01.2010	ZEYTİNYAĞLI BAMYA	SPAGETİ	ŞEHİRİYE ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	Kış	sebze	2784	262	165
26.01.2010	ELBASAN TAVA	BULGUR PILAVI	YAYLA ÇORBA	ELMA	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	277	274
27.01.2010	PILAVÖSTÜ DÖNER	SOSLU MAKARNA	MERCİMEK ÇORBA	AYRAN	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	288	288
28.01.2010	KARNİBAHAR KIZARTMA	SOSLU MAKARNA	EZOGELİN ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	299	275
29.01.2010	FRİN TAVUK	PIRINÇ PILAVI	SEBZE ÇORBA	LOKMA TATLISI	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	299	283
01.02.2010	ZEYTİNYAĞLI KURU FASÜLYE	PIRINÇ PILAVI	DOMATES ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	273	263
02.02.2010	GÜVEÇ	BULGUR PILAVI	ŞEHİRİYE ÇORBA	SALATA	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	277	299
03.02.2010	ZEYTİNYAĞLI PIRASA	ŞEHİRİYELİ GÜVEÇ	YAYLA ÇORBA	PORTAKAL	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	282	210
04.02.2010	IZGARA KÖFTE	SPAGETİ	EZOGELİN ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	277	344
05.02.2010	MEVSİM TÜRLÜ	BULGUR PILAVI	MERCİMEK ÇORBA	REVANI	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	278	247
08.02.2010	PILAVÖSTÜ DÖNER	SOSLU MAKARNA	MERCİMEK ÇORBA	AYRAN	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	122	408
09.02.2010	KARIŞIK KIZARTMA	SPAGETİ	EZOGELİN ÇORBA	YOĞURT	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	124	385
10.02.2010	ZEYTİN YAĞLI TAZE FASÜLYE	PIRINÇ PILAVI	ŞEHİRİYE ÇORBA	IRMIK HELVA	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	121	321
11.02.2010	PATATES OTURTMA	BULGUR PILAVI	HAVUÇ ÇORBA	CACIK	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	118	333
12.02.2010	TAVUK KAVURMA	MAKARNA	DOMATES ÇORBA	TULUMBA TATLISI	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	122	378
15.02.2010	ZEYTİNYAĞLI NOHUT	BULGUR PILAVI	DOMATES ÇORBA	TURŞU	ders dönemi	Ramazan Değil	Maaş Dönemi	Kış	sebze	2784	106	272
16.02.2010	ROSTO KÖFTE	MAKARNA	MERCİMEK ÇORBA	BROKOLİ SALATASI	ders dönemi	Ramazan Değil	Maaş Dönemi	Kış	et	2784	104	390
17.02.2010	BEZELYELİ KEBAP	PIRINÇ PILAVI	EZOGELİN ÇORBA	PORTAKAL	ders dönemi	Ramazan Değil	Maaş Dönemi	Kış	et	2784	107	348
18.02.2010	MEVSİM TÜRLÜ	SPAGETİ	ŞEHİRİYE ÇORBA	KALBURABASTI	ders dönemi	Ramazan Değil	Maaş Dönemi	Kış	sebze	2784	110	319

İstatistiksel testler parametrik testler ve parametrik olmayan testler olmak üzere ikiye ayrılır. Eldeki bir veri setine, bu testlerden hangisinin uygun olduğunu belirlemek için normallik testi yapılmalıdır. Eğer veriler normal dağılıma sahip ise parametrik testler, veriler normal dağılıma sahip değil ise parametrik olmayan testler uygun olacaktır. Verilerin istatistiksel analizleri için SPSS paket programının 16.0 versiyonu kullanılmıştır. Oluşturulan Excel Tablo 4.3'teki her bir etken SPSS programında bir değişken olarak tanımlanmış ve sayısal bir karşılıkla ifade edilmiştir.

Tablo 4.3: Değişkenlerin SPSS programındaki eşlenikleri

Excel Tablosundaki Değişken	SPSS programındaki değişken adı
Ana Yemek	anayemek
Yan Yemek	yanyemek
Çorba	corba
Tatlı Salata Meyve	tatliSalata
Dönem	sinavTatilDers
Ramazan Ayı	ramazan
Maaş Dönemi	maas
Mevsim	mevsim
Çeşit	anaYemCesit
Toplam Personel	personelSay
İznil Personel	izinliSay

Öncelikle uygun analiz türünün belirlenmesi için ölçülebilir (scale) verilere normal dağılım testi (Kolmogorov Smirnov Testi) yapılmıştır. Yapılan testin ekran görüntüsü Şekil 4.2’de gösterilmiştir. Yapılan bütün istatistiksel analizlerde anlamlılık derecesi üst sınırı 0,05 olarak kabul edilmiştir.



Şekil 4.2: SPSS programında Kolmogorov-Smirnov testi

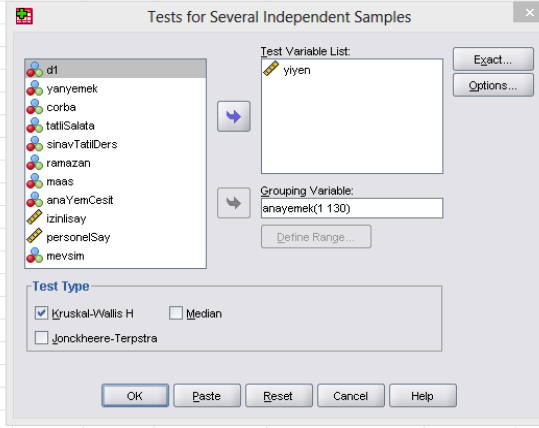
Tablo 4.4: Kolmogorov-Smirnov testi sonuçları

Değişken Adı	Anlamlılık Derecesi
İzinlisay	,000
personelSay	,000
Yiyen	,000

Tablonun anlamlılık sütunundaki değerlerin istatistiksel anlamlılık hesaplamalarında sınır değeri kabul edilen 0,05’den küçük olması incelenen faktörlerin dağılımlarının normal dağılmadığını göstermektedir.

Veriler normal dağılmadığı için ikiden fazla veri grubun ölçümlerinin karşılaştırılmasında kullanılan Kruskal-Wallis H testi yapılmıştır. Yapılan testin ekran görüntüsü Şekil 4.3’te gösterilmiştir.

	Name	Type	Width	Decimals	Label	Values	Missing	Columns	Align	Measure
1	d1	Numeric	8	0		None	None	8	Right	Nominal
2	anayemek	Numeric	8	0		{1, ALABALIK}...	None	8	Right	Nominal
3	yanyemek	Numeric	8	0		{7, BEZELYELI PIRINÇ}...	None	8	Right	Nominal
4	corba	Numeric	8	0		{2, ALAROMEN ÇORB}...	None	8	Right	Nominal
5	tatliSalata	Numeric	8	0		{4, AYRAN}...	None	8	Right	Nominal
6	sinavTatilDers	Numeric	8	0		{1, SINAV DÖNEM}...	None	8	Right	Nominal
7	ramazan	Numeric	8	0		{1, RAMAZAN}...	None	8	Right	Nominal
8	maas	Numeric	8	0		{1, MAAS DÖNEM}...	None	8	Right	Nominal
9	anaYemCesit	Numeric	8	0		{1, SEBZE}...	None	8	Right	Nominal
10	izinliSay	Numeric	8	0		None	None	8	Right	Scale
11	personelSay	Numeric	8	0		None	None	8	Right	Scale
12	mevsim	Numeric	8	0		{1, ILKBAHAR}...	None	8	Right	Nominal
13	yiye	Numeric	8	0		None	None	8	Right	Scale
14										
15										
16										
17										
18										
19										
20										
21										
22										
23										
24										
25										
26										
27										
28										
29										
30										
31										
32										
33										



Şekil 4.3: SPSS programında Kruskal-Wallis H testi

Bağımlı değişken yiye ile anayemek, yanyemek, çorba, tatliSalata, sinavTatilDers, ramazan, maas, anaYemekCesit, mevsim sözel (nominal) değişkenleri ile ayrı ayrı test edilmiştir. Sonuçları Tablo 4.5'teki gibidir.

Tablo 4.5: Kruskal Wallis H testi sonuçları

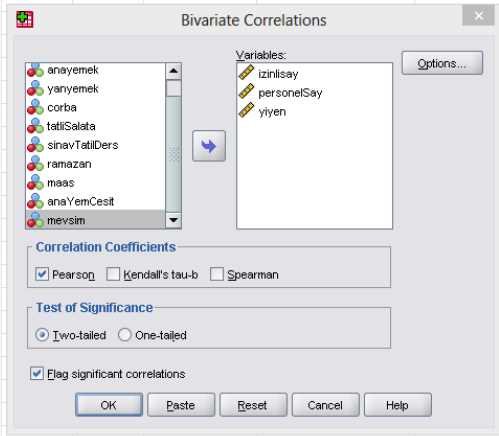
Değişken Adı	Anlamlılık Derecesi
Anayemek	0,000
Yanyemek	0,003
Corba	0,003
tatliSalata	0,000
sinavTatilDers	0,000
Ramazan	0,000
maas	0,626
anaYemekCesit	0,000
Mevsim	0,000

Tablo 4.5'e göre anayemek, yanyemek, çorba, tatliSalata, sinavTatilDers, ramazan, anaYemekCesit, mevsim nominal bağımsız değişkenlerinin bağımlı

değişken yiyen üzerinde anlamlı bir etkisi vardır. Diğer taraftan maas nominal bağımsız değişkenin bağımlı değişken üzerinde anlamlı etkisi yoktur.

Korelasyon analizi ile iki farklı scale değişken arasındaki ilişkinin yönü ve şiddeti hakkında bilgi edinebiliriz. izinlisay ve personelSay bağımsız scale değişkenlerinin bağımlı scale yiyen değişkeni arasındaki ilişkiyi veriler normal dağılmadığı için spearman kolarasyon testi ile test edilmiştir. Yapılan testin ekran görüntüsü Şekil 4.4’te gösterilmiştir.

	Name	Type	Width	Decimals	Label	Values	Missing	Columns	Align	Measure
1	d1	Numeric	8	0		None	None	8	Right	Nominal
2	anayemek	Numeric	8	0		{1, ALABALIK}...	None	8	Right	Nominal
3	yanyemek	Numeric	8	0		{7, BEZELYELI PIRINÇ}...	None	8	Right	Nominal
4	corba	Numeric	8	0		{2, ALAROMEN ÇORB}...	None	8	Right	Nominal
5	tatliSalata	Numeric	8	0		{4, AYRAN}...	None	8	Right	Nominal
6	sinavTatliDers	Numeric	8	0		{1, SINAV DÖNEMİ}...	None	8	Right	Nominal
7	ramazan	Numeric	8	0		{1, RAMAZAN}...	None	8	Right	Nominal
8	maas	Numeric	8	0		{1, MAAŞ DÖNEMİ}...	None	8	Right	Nominal
9	anaYemCesit	Numeric	8	0		{1, SEBZE}...	None	8	Right	Nominal
10	izinlisay	Numeric	8	0		None	None	8	Right	Scale
11	personelSay	Numeric	8	0		None	None	8	Right	Scale
12	mevsim	Numeric	8	0		{1, ILKBAHAR}...	None	8	Right	Nominal
13	yiyen	Numeric	8	0		None	None	8	Right	Scale
14										
15										
16										
17										
18										
19										
20										
21										
22										
23										
24										
25										
26										
27										
28										
29										
30										
31										
32										
33										
34										



Şekil 4.4: SPSS’te Korelasyon testi

Spearman Kolerasyon testi sonuçları Tablo 4.6’ da vardır.

Tablo 4.6: Spearman Kolerasyon Testi Sonuçları

Değişken Adı	Anlamlılık Derecesi
İzinlisay	0,000
personelSay	0,000

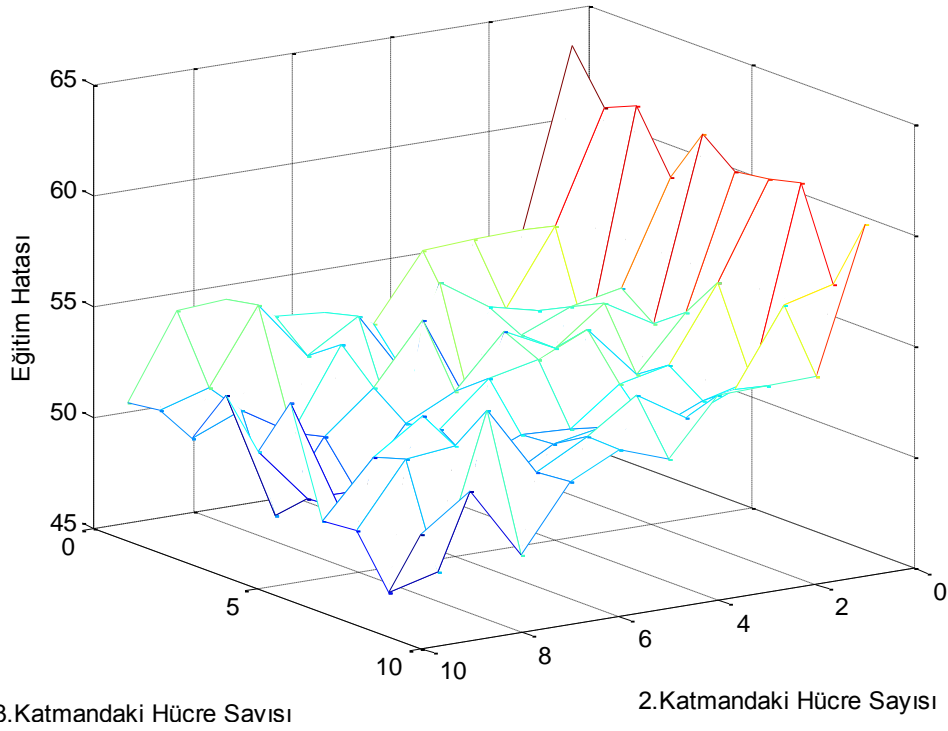
Scale bağımsız izinlisay ve scale bağımsız personelSay değişkenleri scale bağımlı yiyen değişkeni üzerinde istatistiksel olarak anlamlı bir etkisi vardır.

4.2 Farklı Yöntemler ile Günlük Yemek Tahmini

Çalışmanın bu kısmında daha önceki bölümde anlatılan tekniklerle PAÜ yemekhanesinde talep tahmin çalışması yapılmıştır. Yapılan çalışmalar ile ilgili grafikler ayrı ayrı bölümlerde gösterilmiş, her bölümün sonuçları ayrı bir tabloda karşılaştırılmıştır. Kullanılan yöntemlerin karşılaştırılmasının doğru olması için her bir yöntemlerde kullanılan eğitim ve test kümesi aynı tutulmuştur. Kodlamalar ve grafikler için Matlab programı kullanılmıştır. Veriler $[-1,1]$ aralığında normalize edilmiş, hata ölçümlerinde veriler tekrar denormalize edilerek gerçek değerler elde edilmeye çalışılmıştır. Yapay sinir ağları yöntemlerinin karşılaştırılmasının sağlıklı olması için eğitim ve test kümesi her yöntemde aynı alınmıştır. 767 adet veri kümesinin ilk 540'ı eğitim kümesi olarak, kalan 227 veri ise test kümesi olarak kullanılmıştır. Tahmin yapılan bütün yöntemlerde hata ölçüm fonksiyonu olarak RMSE kullanılmıştır.

4.2.1 Çok Katmanlı Yapay Sinir Ağları ile Talep Tahmini


Gradyen azalması çok katmanlı geri yayımlı bu yapay sinir ağında problemin büyüklüğüne göre 3 katmanlı ağ mimarisinin kullanılması yeterli görülmüştür. Eğitimde kullanılan ağ için eğitim n , m , her bir ağ katmanındaki hücre sayısı, tatmin eden hata sayısı ağ eğitilirken parametre olarak belirlenmiştir. 3 katmanlı ileri beslemeli YSA ile öncelikle eğitim ve test hatasını minimize edecek katmanlardaki hücre sayıları belirlenmeye çalışılmıştır. 3 katmanlı yapıda bir her bir katmandaki yapay sinir hücre sayıları 1-10 arasında değiştirilmiştir. 3-30 arasındaki hücrenin 3 katmana farklı şekilde yayılması ile 1000 farklı şekilde eğitim ve test hataları ölçülmüştür. Bu hatalar ölçülürken m ve n değeri 0.5 ile tatmin eden hata 50 ile sabitlenmiş sabit değerler ile her katmandaki en uygun sinir hücre sayıları belirlenmiştir. Yapılan denemeler sonucunda 1. Katmanda 10 2. Katmanda 10 3. Katmanda 9 hücre olduğunda en düşük eğitim hatası elde edilmiştir. En iyi eğitim hatasının elde hücre sayılarına göre 1. Katmandaki hücre sayısı sabit tutulmuş 2. Ve 3. Katmana göre eğitim hatası Şekil 4.5' teki gibidir.




Şekil 4.5: Çok katmanlı ağda katmanlardaki hücre sayısına göre eğitim hatası

Belirlenen en iyi hücre sayıları ile m değeri değiştirilerek en iyi m değeri hesaplanmaya çalışılmıştır. Aynı eğitim ve test kümeleri ile m değeri 0.001 ile 1 arasında 0.001 oranında artırılarak 1000 defa test edilmiş en iyi hücre sayıları ve en iyi m değeri belirlenmiştir. Yapılan denemeler sonucunda en düşük eğitim hatasının alındığı m değeri =0.98 bulunmuştur. Eğitim hatalarının m değerine göre değişimi Şekil 4.6'da vardır.

En düşük eğitim hatasının alındığı hücre sayıları ve m değeri ile n değeri değiştirilerek en düşük eğitim hatası alınacak n değeri hesaplanmaya çalışılmıştır. Aynı eğitim ve test kümeleri ile n değeri 0.001 ile 1 arasında 0.001 oranında artırılarak 1000 defa test edilmiş en iyi hücre sayıları ve en iyi m değeri ile en iyi n değeri belirlenmiştir. Yapılan denemeler sonucunda n değeri=0.534 bulunmuştur. Eğitim hatalarının n değerine göre değişimi Şekil 4.7'de vardır.




Şekil 4.6: Çok katmanlı ağda m değerine göre eğitim hatasının değişimi



Şekil 4.7: Çok katmanlı ağda n değerine göre eğitim hatasının değişimi

Tatmin edecek eğitim hatası en iyi 1 en kötü 100 olması gerektiği düşünülmüş. Tatmin edecek eğitim hatasını ağa eğitim parametresi olarak verilmiştir. Yapılan 100 farklı iterasyonda eğitim hatalarına göre en iyi test hatası bulunmaya çalışılmıştır. Eğitim hatalarının çok küçük olduğu durumlarda iterasyon sayısı çok olacağından ağa giriş parametresi olarak verilen eğitim

hatasına veya maksimum iterasyon sayısına ulaşıldığındaki eğitim hatası en düşük hata olarak kabul edilmiştir. Maksimum iterasyon sayısı 1000 kabul edilmiştir. İstenen eğitim hatasına veya maksimum iterasyon sayısına ulaşıldığında eğitilen ağ test verileri ile test edilmiştir. Yapılan incelemede eğitim hatası yüksek tutulduğunda ağ öğrenecek kadar iyi eğitilememiş düşük tutulduğunda ise gereğinden fazla öğrenip ezberleme yaptığı görülmüştür. Parametrelerin en uygun değerlerine ayarlandığı ağda tatmin edecek hataya göre test hatasının değişimi Şekil 4.8’de vardır.




Şekil 4.8: Tatmin edecek eğitim hatasına göre test hatası değişimi

Eğitim hatasını en çok düşüren m , n ve katmanlardaki yapay sinir hücre sayıları kullanılarak ağın çok ya da az öğrenmesini dikkate alarak ağ normalize veriler ile eğitilmiştir. Test sonuçları denormalize edilerek verilmiştir. Tatmin eden hatanın en uygun diğer değişkenlerin en düşük eğitim hatası verdiği durumlarda en düşük test hatası ($RMSE_{ÇKTest}$) 98,40 olarak bulunmuştur.

4.2.2 Levenberg-Marquardt Algoritması Kullanan İleri Beslemeli Yapay Sinir Ağları ile Talep Tahmini

Bir önceki yöntem ile karşılaştırmak için Matlab programının YSA toolbox'ı kullanılmıştır. Önceki yöntem ile karşılaştırmaların sağlıklı olabilmesi için ağ mimarisi de değiştirilmemiş 3 katmanlı ağda aynı sayıda hücre kullanılmıştır. Maksimum epoch sayısı daha önceki ağdaki gibi 1000 olarak alınmıştır. Test hataları denormalize edilerek gerçek değerlere yakın değerler elde edilmeye çalışılmıştır. epoch sayısı 1-1000 arasında birer birer arttırılmış her epoch sayısında test hatası alınmıştır. Ağ mimarisi ve hücre sayıları değiştirilmemiştir. Her epoch sayısına göre test hataları elde edilerek ağın genellemeyi en iyi yaptığı ezberlemeden çıkışlar ürettiği durumdaki test hataları alınmaya çalışılmıştır. Epoch sayısına göre test hatası değişimi Şekil 4.9'da gösterilmiştir.

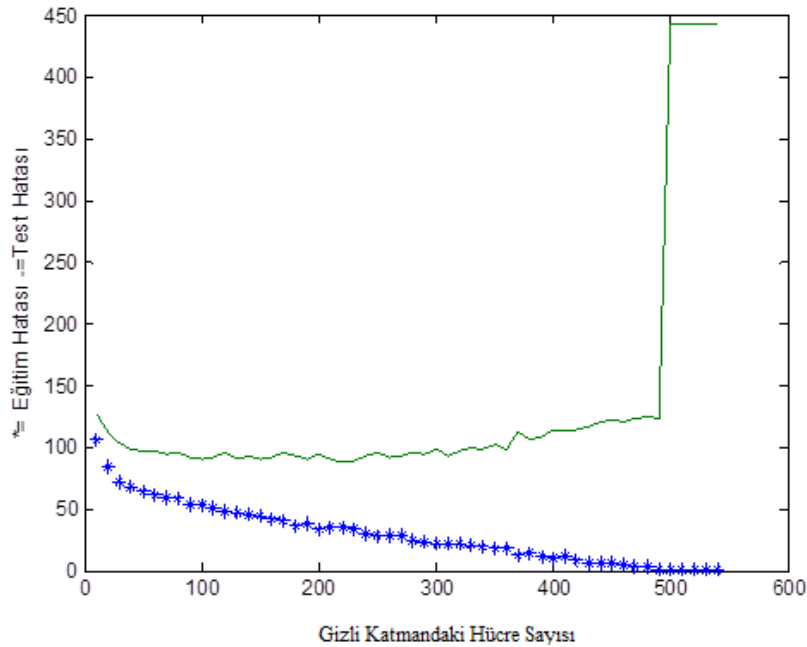


Şekil 4.9: LM kullanan ileri beslemeli ağda epoch sayısına göre test hatası değişimi

Yapılan denemeler sonunda ağ 24 epoch çalıştığında genelleme yapacak yeteneğe kavuşmuş henüz ezberleme yapmamışken en iyi test hatası elde edilmiştir. Yukarıdaki şekilde görüldüğü gibi en düşük hata ($RMSE_{LMTest}$) 63,06 olmuştur.

4.2.3 Radyal Tabanlı Fonksiyon Sinir Ağları ile Yemek Talep Tahmini

RTFYSA ile yapılan talep tahmininde de karşılaştırmanın sağlıklı olması için eğitim kümesi %70 olarak belirlenmiştir. Kalan %30 veri test kümesi olarak kullanılmıştır. Gizli katmandaki yapay sinir hücresi sayısı eğitim kümesindeki hücre sayısı kadar arttırılmış her hücre sayısına göre eğitim ve test hataları alınmıştır. Hücre sayısına göre hata değişimleri Şekil 4.10' da vardır. Ağın gizli katman sayısındaki artışa göre ilk başlarda öğrenme yeteneğine göre uygun test hatalarının yüksek çıktığı ağın çok fazla hücre ile eğitildiği durumlarda ise ezberlemeye başladığı ve test hatalarının yüksek çıktığı görülmüştür.



Şekil 4.10: RTFYSA gizli katmandaki hücre sayısına göre eğitim ve test hatası değişimi


Her bir hücre sayısındaki artışta eğitim ve test hatalarının bulunduğu grafiğe göre en düşük hata ($RMSE_{RBFTest}$) 87,35 olarak 220 hücreli ağ ile bulunmuştur.

4.2.4 Regresyon Modeli ile Yemek Talep Tahmini

Çalışmanın bu kısmında daha önceki bölümde anlatılan istatistiksel yöntemler ile talep tahmini yapılmıştır. Regresyon modelinde eğri oluşturmak için toplam verinin YSA yöntemlerinde de eğitim için kullanılan kısmı kullanılmış kalan kısım oluşturulan eğri ile verileri test etmek için kullanılmıştır.

4.2.4.1 Çoklu Doğrusal Regresyon Modeli İle Yemek Talep Tahmini

Bu yöntemde de veriler -1,1 aralığında normalize edilmiş. Test hataları alınırken veriler tekrar denormalize edilip gerçek değerlere yakın değerler elde edilmeye çalışılmıştır. Yapılan test ve gerçek değerlerin gösterimi Şekil 4.11’de vardır.




Şekil 4.11: Çoklu doğrusal regresyon ile test ve tahmini değerler

Test hataları bulunurken RMSE kullanılmıştır. ÇDR için RMSE ($RMSE_{\text{ÇDRTest}}$) 112,06 olarak bulunmuştur.

4.2.4.2 Etkileşimli Çoklu Doğrusal Regresyon Modeli ile Yemek Tahmini

Bir önceki yöntem ile aynı veriler kullanılmış doğru uydururken değişkenlerin birbiriyle çarpımı da hesaba katılmıştır. Yapılan test ve gerçek değerlerin gösterimi Şekil 4.12’de vardır.



Şekil 4.12: Etkileşimli çoklu doğrusal regresyon ile test ve tahmini değerler

Test hataları bulunurken RMSE kullanılmıştır. EÇDR için RMSE ($RMSE_{EÇDRTest}$) 100,51 olarak bulunmuştur.

4.2.5 Tahmin Yöntemlerinin Genel Karşılaştırılması

Yöntemlerde hata hesaplamada RMSE kullanılmıştır. Test kümeleri her yöntem için aynı alınmıştır. Bu sayede bu veri kümesi için hangi yöntemin daha başarılı olduğu çıkarılabilir. Test kümesindeki verilerin ortalaması alınmıştır. Test kümesindeki ortalama sayı 396,78'dir. Her yöntem ile bulunan hata bu ortalamaya bölünerek hataların yüzde olarak karşılıkları hesaplanmıştır. Hesaplamalarda virgülden sonraki 2 basamak alınmıştır. Sonuçlar Tablo 4.7'de vardır.

Tablo 4.7: Kullanılan yöntemlerin test hatalarının karşılaştırılması

Hata Değişkeni	Ortalama Sayı	Hata	Oran
$RMSE_{ÇKTest}$	396,78	98,4	0,24
$RMSE_{LMTTest}$	396,78	63,06	0,15
$RMSE_{RBFTest}$	396,78	87,35	0,22
$RMSE_{ÇDRTest}$	396,78	112,06	0,28
$RMSE_{EÇDRTest}$	396,78	100,51	0,25

Bu çalışmada tahmin yapmada yapay sinir ağlarının istatistiksel yöntemlere göre daha başarılı olduğu söylenebilir. Ağ için uygun parametrelerin ayarlanması ve ağın ezberlemeden uygun eğitim hatasıyla test edilmesinin test sonuçlarını iyileştireceği söylenebilir.

4.2.6 Tasarlanan Grafik Kullanıcı Arayüzü

Tasarlanan sistemler için parametrelerin çoktan seçimli, tahmin yöntemlerin seçilebildiği, toplam ve izinli personel sayısının girilebileceği metin kutularının bulunduğu arayüz tasarlanmıştır. Arayüzden hesaplanan modelin çıkışları uzman için bir görüş niteliği taşıyabilir. Ekran görüntüsü Şekil 4.13'te vardır.

Şekil 4.13: Tasarlanan Grafik Kullanıcı Arayüzü

4.2.7 En İyi ve En Kötü Örneklerin Uzman Görüşü ile Karşılaştırılması

Tez kapsamında tahmin yöntemlerinin en iyi tahmin ettiği 5 günlük veriler ve en kötü tahmin ettiği 5 günlük veriler alınarak toplam 38 günlük liste

oluşturulmuştur. En iyi en kötü örneklerin bulunduğu liste için uzman kişiler ile görüşülmüş ve uzman kişiler tarafından o günlerin yemek sayılarının tahmin edilmesi istenmiştir.

Uzman görüşü almak için Pamukkale Üniversitesi merkez yemekhanesi beslenme uzmanı Çağla ŞAŞMAZ ve baş aşçı Yalçın BAYER ile görüşülmüştür. Görüşmede yemek tahmini ile ilgili belli bir akıllı sistemin bulunmadığı ve tahminlerin beslenme uzmanı ve baş aşçı uzman görüşlerine dayandığı ifade edilmiştir. Yapılan tahminlerin bu tez kapsamında kullanılan verilerin bulunduğu tarih aralığını kapsamadığı öğrenilmiştir. Uzman tahmininde ele alınan kriterlerin bu tezde belirlenen kriterlerle benzer olduğu ve ayrıca uzman tahmininde günlerden Cuma olmasının da yemek sayısına etkisi olduğu belirtilmiştir. Uzman kişiler 3600 kişiden kaç kişinin personel yemekhanesinde yemek yiyeceğini tahmin etmiştir. Tahminde kullanılan yıllardaki toplam personel sayısı 3600'e bölünüp, elde edilen bölüm uzmanların tahmin ettiği sayılar ile çarpılmıştır. Bu sayede verilerin bulunduğu güne ait uzman görüşü elde edilmeye çalışılmıştır.

En iyi ve en kötü örneklerin tahmin yöntemi ortalamaları ve uzman görüşü ortalamaları Tablo 4.8'de verilmiştir. En iyi en kötü tahminlerin bulunduğu yemekler Tablo 4.9'da listelenmiştir. Her bir model ve uzman görüşünün en iyi tahminleri ve o gün gerçekten kaç kişinin yediği arasındaki farklar hesaplanmış yöntemlerin en iyi ve en kötü sonuçları daha koyu şekilde Tablo 4.10'da vardır.

Tablo 4.8: En iyi en kötü örneklerin ortalamalarının karşılaştırılması

Hata Değişkeni	Tüm iyi ve kötü örnekler için ortalama
FarkÇKTest _{ortalama}	81,23
FarkLMTTest _{ortalama}	84,93
FarkRBFTest _{ortalama}	67,72
FarkÇDRTest _{ortalama}	96,08
FarkEÇDRTest _{ortalama}	99,67
FarkUzmanGörüş _{ortalama}	128

Bütün yöntemlerin en iyi ve en kötü örneklerinin bir arada bulunduğu 38 günlük verilerin ortalaması ele alındığında ise yapay sinir ağları ve istatistiksel yöntemlerin uzman görüşünden daha başarılı olduğu söylenebilir.

Tablo 4.9: En iyi en kötü örneklerin oluşturduğu yemek verileri

Tarih	Ana Yemek	Yan Yemek	Çorba	Diğer	Dönem	Ramazan Ayı	Maaş Dönemi	Mevsim	Çeşit	Toplam Personel	İzinli Personel
17.10.2011	ZEYTİNYAĞLI KURU FASULYE	PIRINÇ PİLAVI	EZOĞELİN ÇORBA	TURŞU	ders dönemi	Ramazan Değil	Maaş Dönemi	sonbahar	sebze	2815	166
10.02.2010	ZEYTİN YAĞLI TAZE FASÜLYE	PIRINÇ PİLAVI	ŞEHİRİYE ÇORBA	İRMİK HELVA	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	121
23.03.2011	ELBASAN TAVA	BULGUR PİLAVI	DOMATES ÇORBA	AYRAN	ders dönemi	Ramazan Değil	Maaş Dönemi	ilkBahar	et	2815	146
25.07.2012	FIRIN PATATES	BULGUR PİLAVI	ALAROMEN ÇORBA	SALATA	ders dönemi	Ramazan Değil	Maaş Dönemi	yaz	sebze	3011	591
04.06.2012	ZEYTİNYAĞLI NOHUT	BULGUR PİLAVI	TARHANA ÇORBA	CACIK	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	yaz	sebze	3011	241
23.06.2010	ELBASAN TAVA	ERİŞTE	ŞEHİRİYE ÇORBA	KARPUZ	ders dönemi	Ramazan Değil	Maaş Dönemi	yaz	et	2784	378
26.03.2012	ZEYTİNYAĞLI BARBUNYA	PIRINÇ PİLAVI	SÜT ÇORBA	TURŞU	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	ilkBahar	sebze	3011	145
18.08.2010	ELBASAN TAVA	BULGUR PİLAVI	YAYLA ÇORBA	KARPUZ	Tatil Dönemi	ramazan ayı	Maaş Dönemi	yaz	et	2784	704
19.08.2010	KABAK MUSAKKA	ERİŞTE	EZOĞELİN ÇORBA	YOĞURT	Tatil Dönemi	ramazan ayı	Maaş Dönemi	yaz	sebze	2784	739
03.06.2011	ZEYTİNYAĞLI KABAK	ŞEHİRİYELİ GÜVEÇ	EZOĞELİN ÇORBA	YOĞURT	sinav dönemi	Ramazan Değil	Maaş Dönemi Değil	yaz	sebze	2815	183
02.04.2012	TAVUKLU BEZELYE	PIRINÇ PİLAVI	DOMATES ÇORBA	MEYVE	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	ilkBahar	karışık	3011	171
25.01.2011	SEBZELİ KEBAP	ERİŞTE	ŞEHİRİYE ÇORBA	CACIK	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	Kış	et	2815	198
18.01.2011	ROSTO KÖFTE	SOSLU SPAGETTİ	SÜT ÇORBA	ELMA	sinav dönemi	Ramazan Değil	Maaş Dönemi	Kış	et	2815	145
01.08.2012	ZEYTİNYAĞLI KURU FASULYE	PIRINÇ PİLAVI	EZOĞELİN ÇORBA	SALATA	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	yaz	sebze	3011	561
21.04.2011	TERBİYELİ KÖFTE	SOSLU MAKARNA	SEBZE ÇORBA	ELMA	ders dönemi	Ramazan Değil	Maaş Dönemi	ilkBahar	et	2815	170
14.01.2013	ETLİ KURU FASULYE	PIRINÇ PİLAVI	ALAROMEN ÇORBA	TURŞU	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	karışık	3269	192
13.01.2010	MEVSİM TÜRLÜ	BULGUR PİLAVI	ŞEHİRİYE ÇORBA	SUPANGLE	sinav dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2784	113
10.06.2010	ZEYTİNYAĞLI KABAK	ŞEHİRİYELİ GÜVEÇ	MERCİMEK ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	yaz	sebze	2784	255
22.03.2010	ZEYTİN YAĞLI TAZE FASÜLYE	PIRINÇ PİLAVI	ŞEHİRİYE ÇORBA	TAHİN HELVA	ders dönemi	Ramazan Değil	Maaş Dönemi	ilkBahar	sebze	2784	121
19.10.2010	TAS KEBABI	SOSLU MAKARNA	DOMATES ÇORBA	SALATA	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	sonbahar	et	2784	165
15.07.2011	PİLAVÜSTÜ IZGARA KÖFTE		MERCİMEK ÇORBA	AYRAN	ders dönemi	Ramazan Değil	Maaş Dönemi	yaz	et	2815	751
27.12.2011	ZEYTİN YAĞLI TAZE FASÜLYE	ÖZBEK PİLAVI	ALAROMEN ÇORBA	CACIK	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	2815	223
19.01.2010	IZGARA KÖFTE	PIRINÇ PİLAVI	ŞEHİRİYE ÇORBA	SALATA	Tatil Dönemi	Ramazan Değil	Maaş Dönemi	Kış	et	2784	148
29.09.2010	PATLICAN MUSAKKA	PIRINÇ PİLAVI	MERCİMEK ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	sonbahar	sebze	2784	201
07.07.2010	ZEYTİNYAĞLI BEZELYE	PIRINÇ PİLAVI	ŞEHİRİYE ÇORBA	KARPUZ	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	yaz	sebze	2784	580
27.03.2012	KARIŞIK KIZARTMA	SOSLU MAKARNA	EZOĞELİN ÇORBA	YOĞURT	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	ilkBahar	sebze	3011	145
24.06.2010	SEBZELİ KEBAP	PIRINÇ PİLAVI	MERCİMEK ÇORBA	SUPANGLE	ders dönemi	Ramazan Değil	Maaş Dönemi	yaz	et	2784	380
13.09.2012	ZEYTİNYAĞLI BARBUNYA	BULGUR PİLAVI	TAVUKSUYU ÇORBA	ŞEKERPAZE	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	sonbahar	sebze	3011	536
27.05.2011	TERBİYELİ KÖFTE	ERİŞTE	EZOĞELİN ÇORBA	REVANİ	sinav dönemi	Ramazan Değil	Maaş Dönemi Değil	ilkBahar	et	2815	207
08.02.2010	PİLAVÜSTÜ DÖNER		MERCİMEK ÇORBA	AYRAN	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	et	2784	122
30.01.2013	KARIŞIK KIZARTMA	ETLİ PİLAV	TARHANA ÇORBA	YOĞURT	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	sebze	3269	582
21.06.2012	PİLAVÜSTÜ IZGARA KÖFTE		EZOĞELİN ÇORBA	SALATA	ders dönemi	Ramazan Değil	Maaş Dönemi	yaz	et	3011	419
12.04.2012	TAVUKLU NOHUT	BULGUR PİLAVI	HAVUÇ ÇORBA	TURŞU	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	ilkBahar	karışık	3011	159
03.12.2012	TAVUKLU NOHUT	BULGUR PİLAVI	YAYLA ÇORBA	TURŞU	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	Kış	karışık	3011	217
30.03.2012	TAS KEBABI	SOSLU SPAGETTİ	TARHANA ÇORBA	CACIK	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	ilkBahar	et	3011	167
20.06.2011	ZEYTİNYAĞLI BARBUNYA	PIRINÇ PİLAVI	ŞEHİRİYE ÇORBA	CACIK	ders dönemi	Ramazan Değil	Maaş Dönemi	yaz	sebze	2815	306
08.06.2012	ALBALIK	ERİŞTE	MERCİMEK ÇORBA	REVANİ	Tatil Dönemi	Ramazan Değil	Maaş Dönemi Değil	yaz	et	3011	307
04.10.2011	MEVSİM TÜRLÜ	SOSLU SPAGETTİ	EZOĞELİN ÇORBA	YOĞURT	ders dönemi	Ramazan Değil	Maaş Dönemi Değil	sonbahar	sebze	2815	191

Tablo 4.10: En iyi en kötü örnekler için tahminler ile gerçek veriler arasındaki fark

Tarih	Yenilen Yemek	ÇKTest	LMTTest	RBFTest	ÇDRTest	EÇDRTest	Uzman Görüş	FarkÇKTest	FarkLMTTest	FarkRBFTest	FarkÇDRTest	FarkEÇDRTest	FarkUzmanGörüş
17.10.2011	510	397,7	226,4	369,8	336,2	316,1	297,1	112,3	283,6	140,2	173,8	193,9	212,9
10.02.2010	321	320,8	314,7	323,9	348,7	319,9	270,7	0,2	6,3	2,9	27,7	1,1	50,3
23.03.2011	410	398,4	403	404,4	422,4	409,6	430,1	11,6	7	5,6	12,4	0,4	20,1
25.07.2012	270	264,9	235,5	261,2	315	271	267,6	5,1	34,5	8,8	45	1	2,4
04.06.2012	536	540,9	179,8	454,1	475,2	475	284,4	4,9	356,2	81,9	60,8	61	251,6
23.06.2010	933	470,9	918,1	897,8	366,2	384,5	348,0	462,1	14,9	35,2	566,8	548,5	585,0
26.03.2012	833	698,1	769	760,9	545,1	652,9	284,4	134,9	64	72,1	287,9	180,1	548,6
18.08.2010	127	130	76,2	401,2	134	175,5	232,0	3	50,8	274,2	7	48,5	105,0
19.08.2010	109	132,7	108,3	153,5	55,1	107	174,0	23,7	0,7	44,5	53,9	2	65,0
03.06.2011	256	339,3	316,4	352,8	255,6	341,5	234,6	83,3	60,4	96,8	0,4	85,5	21,4
02.04.2012	512	753,5	799,5	607,4	616,8	767,7	334,6	241,5	287,5	95,4	104,8	255,7	177,4
25.01.2011	297	396,6	306,4	295,8	343,4	374,9	305,0	99,6	9,4	1,2	46,4	77,9	8,0
18.01.2011	347	392,6	345,1	346,9	305,8	285,9	351,9	45,6	1,9	0,1	41,2	61,1	4,9
01.08.2012	326	341,3	323,5	300,9	324,4	297,7	309,5	15,3	2,5	25,1	1,6	28,3	16,5
21.04.2011	369	382,3	368	379,8	418,1	342,5	391,0	13,3	1	10,8	49,1	26,5	22,0
14.01.2013	499	539,5	489,7	498,2	757,8	567,3	336,0	40,5	9,3	0,8	258,8	68,3	163,0
13.01.2010	342	347,4	344,2	342,4	251,3	280,4	286,1	5,4	2,2	0,4	90,7	61,6	55,9
10.06.2010	247	309,2	397,7	424	276,1	306	247,5	62,2	150,7	177	29,1	59	0,5
22.03.2010	281	280,3	341,4	230,4	352,4	260,2	324,8	0,7	60,4	50,6	71,4	20,8	43,8
19.10.2010	383	381,3	325,7	376,2	309,3	325,7	386,7	1,7	57,3	6,8	73,7	57,3	3,7
15.07.2011	344	426,5	301,2	533,8	313,1	419,7	328,4	82,5	42,8	189,8	30,9	75,7	15,6
27.12.2011	338	336,8	320,8	350,1	338,1	369,6	320,6	1,2	17,2	12,1	0,1	31,6	17,4
19.01.2010	373	390,8	361,2	409,9	334,4	372,8	371,2	17,8	11,8	36,9	38,6	0,2	1,8
29.09.2010	551	374,8	425,8	493,6	287,7	335,7	332,5	176,2	125,2	57,4	263,3	215,3	218,5
07.07.2010	289	263,1	281,4	236,3	287,8	261	309,3	25,9	7,6	52,7	1,2	28	20,3
27.03.2012	656	703,3	312,8	575,4	548	712,4	418,2	47,3	343,2	80,6	108	56,4	237,8
24.06.2010	779	350,3	306,4	346,1	344	333,5	363,5	428,7	472,6	432,9	435	445,5	415,5
13.09.2012	466	467,9	468,8	479,2	416,1	381	317,8	1,9	2,8	13,2	49,9	85	148,2
27.05.2011	325	343,9	326,7	326	302,4	456,8	391,0	18,9	1,7	1	22,6	131,8	66,0
08.02.2010	408	430,9	408,4	403,3	390,2	419,9	386,7	22,9	0,4	4,7	17,8	11,9	21,3
30.01.2013	443	448,1	443	440	623,3	504,2	399,5	5,1	0	3	180,3	61,2	43,5
21.06.2012	735	663	625,6	564,2	514,2	617,3	418,2	72	109,4	170,8	220,8	117,7	316,8
12.04.2012	592	752,3	775,1	659,3	612,2	850,4	334,6	160,3	183,1	67,3	20,2	258,4	257,4
03.12.2012	533	746,9	594,2	645,1	598,4	783,6	334,6	213,9	61,2	112,1	65,4	250,6	198,4
30.03.2012	601	745,5	575,4	651,8	600,7	669,4	376,4	144,5	25,6	50,8	0,3	68,4	224,6
20.06.2011	267	356	372,5	320,7	346,3	266,5	273,7	89	105,5	53,7	79,3	0,5	6,7
08.06.2012	497	704,9	752,7	578,5	518,2	560,8	342,92	207,9	255,7	81,5	21,2	63,8	154,1
04.10.2011	456	460	457,1	433,5	362,1	408,8	312,78	4	1,1	22,5	93,9	47,2	143,2

5. SONUÇ VE ÖNERİLER

Bu çalışmada Pamukkale Üniversitesi yemekhanesine ait tabldot yemek veren yemekhane verileri kullanılmıştır. Üniversite bünyesinde bulunan hızlı yemek servisleri tabldot yemek tercih edilmediği durumlarda kullanılmaktadır. Diğer kafe ve hızlı yemek servislerinin kullanılma oranı tabldot yemekhane talep sayısındaki artış ve azalış ile bağlantılıdır. Bu çalışmada yemekhaneyi kullanan idari, akademik ve hizmet alımı şeklinde çalışıp yemekhaneyi kullanan personelin verileri kullanılmıştır. Öğrenci yemekhanesi verileri ise değerlendirmeye alınmamıştır. Yemekhane yetkilileri ile görüşüldüğünde talep tahmini için herhangi bir akıllı sistemin bulunmadığı, talep tahmininde uzman görüşünün esas alındığı belirtilmiştir.

Yapay Sinir Ağları ve istatistiksel yöntemler ile yapılan testlerin sonuçları tabldot yemek yenilen yemekhaneler için tahmin niteliğindedir. Bu çalışma diğer talep tahminleri gibi yemekhane talep tahmininde de yapay sinir ağları ve diğer yöntemlerin başarılı bir şekilde kullanılabileceğini ortaya koymaktadır.

Bu çalışmanın devamı olarak tabldot yemekhane verileri dışındaki yemek verilerinin tahmin edilmesi ile ilgili bir çalışma yapılabilir. Ayrıca farklı yerleşkelerde bulunan üniversite birimlerindeki veriler de değerlendirilmeye alınabilir.

Üniversite içindeki kafeler ve öğrenci yemekhanesi, Kınıklı kampüsü dışındaki okulların verileri ile bu verilerin taleplerini etkileyen kriterler belirlenip üniversite bünyesine toplam atık yemek miktarını azaltacak sistemler tasarlanabilir.

Oluşturulan kullanıcı arayüzü sayesinde geleceğe yönelik günlük tahminler yapılabilir. Yapılan günlük tahminler uzman görüşü ile karşılaştırılıp uzman görüşünün olumlu yönde etkilenmesi sağlanabilir. Uzman görüşleri ile program çıktıları ayrı bir ağ mimarisi oluşturularak katmanlı bir yapı ya da iki çıktının değerlendirildiği bulanık sistemler tasarlanabilir.

6. KAYNAKLAR

Alpar R., Uygulamalı Çok Değişkenli İstatistiksel Yöntemlere Giriş I. 2. bs., Nobel Yayınevi. 411 s., Ankara, (2003).

Başaran S., "Yapay Sinir Ağları Kullanarak Konuşmacı Tanıma", Yüksek Lisans Tezi, T.C. Uludağ Üniversitesi Fen Bilimleri Ens. Elektronik Müh. Anabilim Dalı, Bursa, (2007).

Blecher L., "Using forecasting techniques to predict meal demand in Title IIIc congregate lunch programs", Journal of the Academy of Nutrition and Dietetics, 104,8, 1281-1283, (2004).

Buhmann M. D., "Radial Basis Functions: Theory and Implementations" , Cambridge University Press, (2009).

Bulut Ş., "Orta Ölçekli Bir İşletmede Talep Tahmin Yöntemlerinin Uygulanması", Yüksek Lisans Tezi, Kırıkkale Üniversitesi Endüstri Mühendisliği Anabilim Dalı, Kırıkkale, (2006).

Çetinkaya C., "Retina Görüntülerinde Radyal Tabanlı Fonksiyon Sinir Ağları İle Damar Tipik Noktalarının Tespit Edilmesi", Yüksek Lisans Tezi, Ege Üniversitesi Uluslararası Bilgisayar Anabilim dalı, İzmir, (2011).

Çuhadar M., Kayacan C., "Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme", Anatolia: Turizm Araştırmaları Dergisi, Cilt 16, Sayı 1, Bahar: 24-30, (2005).

Doğan G., "Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi", Yüksek Lisans Tezi, Hacettepe Üniv. İstatistik Anabilim Dalı, (2010).

Filiz B., "Samsun Organize Sanayi Bölgesinde Troposferik Ozon (O3) Konsantrasyonunun Yapay Sinir Ağ Yöntemi İle Modellenmesi", Yüksek Lisans

Tezi, Ondokuz Mayıs Üniversitesi Çevre Mühendisliği Anabilim Dalı, Samsun, (2013).

Hu C., Chen M. ve McCain S., "Forecasting in Short-Term Planning and Management for a Casino Buffet Restaurant", Journal of Travel & Tourism Marketing, (2008).

Elmas Ç., "Yapay Sinir Ağları (kuram, mimari, eğitim, uygulama)", Seçkin Yayıncılık, (2003).

Engstrom R., Carlsson-Kanyama A., "Food losses in food service institutions Examples from Sweden", Food Policy, 29, (2009).

Frewer L.J., Schifferstein H. ve E. Risvik (Editörler), Does Taste Determine Consumption ? Understanding the Psychology of Food Choice, People and Society. A European Perspective of Consumers' Food Choice. Berlin, Heidelberg: Springer-Verlag, 177-195 (2001).

Kara Y., Acar Boyacıoğlu M., Baykan Ö. K., "Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange", Expert Systems with Application, 38, 5, 5311-5319, (2011).

Karaatlı M., "Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini", Uluslararası Yönetim İktisat ve İşletme Dergisi, 8, 12, (2012).

Karahan M., "Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini", Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Ens. İşletme Anabilim Dalı, Konya, (2011).

Khare M., Nagendra S.M., "Artificial Neural Networks in Vehicular Pollution Modelling", Springer, (2007).

Lindeman M., Vaananen M., Measurement of Ethical Food Choice Motives, Appetite, 34: 55-59. (2000).

Lisa G., Lientjie V.R, The Hospitality Industry Handbook on Nutrition and Menu Planning, 9 780702 155789, PO Box 24309, Landsdowne,7779 (2002).

Montazar Gh. A., Sabzevari R., Ghorbani F. , "Improvement of Learning Rate for RBF Neural Networks in a Helicoptersound Identification Sysytem Introduction Two-Phase OSD Learning Method", Proceeding of the 5th International Symposium on Mechatronics and its Applications (ISMA08), Amman, Jordan, May 27-29, (2008).

Nesine A., Üretim Planlama Yönetim ve Uygulamaları, MPM Yayınları, Ankara, (1996).

Okkan U., Dalkılıç H.Y., "Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi ", İMO Teknik Dergi, 5957-5966, Yazı 379, (2012).

Özdamar K., Paket Programlar ile İstatistiksel Veri Analizi-1, Kaan Kitabevi, (2004).

Özdemir B. Dışarıda Yemek Yeme Olgusu: Kuramsal Bir Model Önerisi Anatolia: Turizm Araştırmaları Dergisi, Cilt 21, Sayı 2, Güz: 218-232, (2010).

Öztemel E., Yapay Sinir Ağları, Papatya Yayıncılık (2006).

Öztürkcan M., "Regresyon Analizi", Maltepe Üniversitesi Yayınları Sayı:3, No:40 (2009).

Pınarbaşı M., "Elektrik Enerji Sistemlerinde Talep Tahmin Yöntemleri ve Yapay Sinir Ağları Uygulaması", Yüksek Lisans Tezi, İstanbul Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı,İstanbul, (2009).

Prescott J., Young O., O'Neill L., You N. J. N. ve Stevens R., Motives for Food Choice: A Comparison of Consumers from Japan, Taiwan, Malaysia, and New Zealand, Food Quality and Prefence, 13:489-495, (2002).

Sarioğlu Ş., Beşdok E., Erler M., Mühendislikte Yapay Zeka Uygulamaları Yapay Sinir Ağları, Ufuk Kitap Kırtasiye- Yayıncılık Tic. Ltd. Şti., (2003).

Steptoe A., Pollard T. M., Wardle J., Development of a Measure of the Motives Underlying the Selection of Food: The Food Choice Questionnaire, *Appetite*, 25: 183-196. (1995).

Takma Ç., Çoklu Doğrusal Regresyon ve Yapay Sinir Ağı Modellerinin Laktasyon Süt Verimlerine Uyum Yeteneklerinin Karşılaştırılması, *Kafkas Üniversitesi Veterinerlik Fakültesi Dergisi*, 18 (6): 941-944, (2012).

Url 2015^a www.nutrition.org.uk erişim tarihi 15.01.2015.

Url 2015^b http://www.tdk.gov.tr/index.php?option=com_gts&arama=gts erişim tarihi 20.01.2015.

Url 2015^c <http://www.pau.edu.tr/sks/tr/sayfa/tanitim-5> erişim tarihi 03.03.2015.

Üreten S., Üretim/İşler Yönetimi, Stratejik Kararlar ve Karar Modelleri, Gazi Kitapevi, Ankara, (2002).

Wilesa P. S., Enkeb D., "Nonlinear Modeling using Neural Networks for Trading the Soybean Complex", *Procedia Computer Science*, 36, 234 – 239 (2014).

Wu J., Liu J., "A forecasting system for car fuel consumption using a radial basis function neural network", *Expert Systems with Applications*, 39, 2, 1883–1888 , (2012).

Yıldırım N., "En Küçük Kareler, Ridge Regresyon ve Robust Yöntemlerinde Analiz Sonuçlarına Aykırı Değerlerin Etkilerinin Belirlenmesi", Yüksek Lisans Tezi, Çukurova Üniversitesi Fen Bilimleri Ens. Zooteknik Anabilim Dalı, Adana, (2010).

Yurdakul M., "Karbonat Kökenli Doğal Taşların Yapay Sinir Ağları ile Kesilebilirlik Tayini", Doktora Tezi, Osmangazi Üniversitesi Maden Mühendisliği Anabilim Dalı, Eskişehir, (2009).

Zhang G., Patuwo B. E., "Forecasting with artificial neural networks: The state of the art", *International Journal of Forecasting*, 14, 35–62, (1998).

7. ÖZGEÇMİŞ

Ad Soyadı	Günay KILIÇ
Doğum Yeri ve Tarihi	Sivas 10.10.1984
Lisans	Pamukkale Üniversitesi
Elektronik Posta	gkilic@pau.edu.tr
İletişim Adresi	Pamukkale Üniversitesi Bilgi İşlem Daire Başkanlığı Rektörlük Binası Kınıklı Kampüsü Denizli