



T.C.

**ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**TARIM MAKİNALARI VE TEKNOLOJİLERİ MÜHENDİSLİĞİ
ANABİLİM DALI**

**FT-NIR SPEKTROSKOPİ VE YAPAY SİNİR AĞLARI
KULLANILARAK DOMATESLERİN İÇSEL KALİTE
KRİTERLERİNİN TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

MUHAMMED EKREM ALTUNKÜLAH

Tez Danışmanı

PROF. DR. İSMAİL KAVDIR

ÇANAKKALE – 2023



T.C.

ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TARIM MAKİNALARI VE TEKNOLOJİLERİ MÜHENDİSLİĞİ ANABİLİM DALI

**FT-NIR SPEKTROSKOPİ VE YAPAY SİNİR AĞLARI KULLANILARAK
DOMATESLERİN İÇSEL KALİTE KRİTERLERİNİN TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

MUHAMMED EKREM ALTUNKÜLAH

Tez Danışmanı

PROF. DR. İSMAİL KAVDIR

ÇANAKKALE – 2023



T.C.
ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



Muhammed Ekrem ALTUNKÜLAH tarafından Prof. Dr. İsmail KAVDIR yönetiminde hazırlanan ve **29/08/2023** tarihinde aşağıdaki jüri karşısında sunulan “**FT-NIR Spektroskopi ve Yapay Sinir Ağları Kullanılarak Domateslerin İçsel Kalite Kriterlerinin Tahmin Edilmesi**” başlıklı çalışma, Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü **Tarım Makinaları ve Teknolojileri Mühendisliği Anabilim Dalı**’nda **YÜKSEK LİSANS TEZİ** olarak oy birliği ile kabul edilmiştir.

Jüri Üyeleri

İmza

Prof. Dr. İsmail KAVDIR (Danışman)

Doç. Dr. Caner KOÇ

Dr. Öğr. Üyesi Mehmet Burak BÜYÜKCAN

Tez No : 10570611

Tez Savunma Tarihi : 29/08/2023

Prof. Dr. Ahmet Evren ERGİNAL

Enstitü Müdürü

__/__/2023

ETİK BEYAN

Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kuralları'na uygun olarak hazırladığım bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi taahhüt ve beyan ederim.

Muhammed Ekrem ALTUNKÜLAH

29/08/2023

SUNUŐ ve TEŐEKKÖR

Ulu önder Gazi Mustafa Kemal Atatürk'ün "Kılıç ve saban; bu iki fatihten birincisi, ikincisine daima yenildi." sözünün derinliğine inanarak başladığım yüksek lisans eğitimimi tamamlarken hazırladığım bu akademik çalışmada yoluma ışık tutan danışmanım Prof. Dr. İsmail Kavdır'a, birlikte çalışma şansı bulduğum Ziraat Y. Müh. Aysun İğdeci'ye şükranlarımı sunarım.

Varlıklarını ve desteklerini her daim hissettiğim kıymetli aileme saygı ve hürmetlerimle...

Muhammed Ekrem ALTUNKÜLAH

Çanakkale, Ağustos 2023

ÖZET

FT-NIR SPEKTROSKOPİ VE YAPAY SİNİR AĞLARI KULLANILARAK DOMATESLERİN İÇSEL KALİTE KRİTERLERİNİN TAHMİN EDİLMESİ

Muhammed Ekrem ALTUNKÜLAH

Çanakkale Onsekiz Mart Üniversitesi

Lisansüstü Eğitim Enstitüsü

Tarım Makinaları ve Teknolojileri Mühendisliği Anabilim Dalı Yüksek Lisans Tezi

Danışman: Prof. Dr. İsmail KAVDIR

29/08/2023, 59

Bu çalışmada; domateste sertlik, SÇKM ve pH gibi içsel kalite kriterlerinin örnekler üzerinde hasarsız olarak ölçülen spektral okumaların, hasarlı olarak ölçülen standart fiziksel ölçümlerin ve yapay sinir ağları regresyon (YSA-Regresyon) yöntemlerinin kullanılması ile tahmin edilmesi hedeflenmiştir. Çalışmada ayrıca, YSA-Regresyon modelleri ile tahmin edilen ürün içsel kalite kriterlerinin tahmin başarılarının önceki bir çalışmada (Selen, 2021) aynı veri setlerinin kullanılması ve PLS analizi ile elde edilen tahmin başarıları ile kıyaslanmasının yapılması hedeflenmiştir. Böylelikle, önceki çalışmada PLS analizi gibi doğrusal yöntemlerle yapılan içsel kalite parametreleri tahmin sonuçları, YSA-Regresyon gibi doğrusal olmayan yöntemler ile yapılan tahmin sonuçları ile aynı veri setleri üzerinden kıyaslaması yapılmıştır.

Domatesin üç farklı içsel kalite kriterinin tahmin edilmesi için üç farklı YSA-Regresyon modeli (mimarisi) geliştirilmiştir (farklı giriş değeri sayıları ve farklı saklı tabaka nöron sayıları ile). Geliştirilen YSA-Regresyon modelleri ile domates örneklerinin sertlik, SÇKM ve pH özelliklerinin tahmin edilmesinde elde edilen sonuçlar, daha önce aynı veri seti üzerinde aynı içsel özelliklerin tahmini için geliştirilen ve kullanılan PLS (Kısmi En Küçük Kareler) yöntemi ile elde edilen tahmin sonuçlarına göre özellikle sertlik ve pH tahminlerinde daha iyi sonuç vermiştir. Test veri seti için YSA-Regresyon modelini kullanarak sertlik ve pH tahminleri için elde edilen regresyon değerleri sırasıyla, $R^2=0,85$ ve $RMSE=225,80$ (sertlik); $R^2=0,65$ ve $RMSE=0,11$ (pH) olmuştur. SÇKM içeriği için her iki çalışmada elde edilen tahmin sonuçları hemen hemen aynı olmuştur (her iki çalışmada da

regresyon deęeri $R^2=0,83$ olurken, RMSE deęeri YSA-Regresyon modeli iin 0,38 ve PLS analiz alıřmasında ise 0,406 olarak bulunmuřtur).

Anahtar Kelimeler: FT-NIR Spektroskopi, YSA-Regresyon, Sertlik Tahmini, SKM Tahmini, pH Tahmini, Yapay Sinir Aęları



ABSTRACT

PREDICTION OF INNER QUALITY CRITERIA OF TOMATOES USING FT-NIR SPECTROSCOPY AND ARTIFICIAL NEURAL NETWORKS

Muhammed Ekrem ALTUNKÜLAH

Çanakkale Onsekiz Mart University

School of Graduate Studies

Master of Science Thesis in Agricultural Machinery and Technologies Engineering

Advisor: Prof. Dr. İsmail KAVDIR

29/08/2023, 59

In this study, it was aimed to estimate the inner quality criteria of tomatoes such as firmness, TSSC (Total Soluble Solid Content; brix) and pH by using spectral readings measured without damage, standard physical measurements measured as damaged, and artificial neural network regression (ANN-Regression) methods. In the study, it was also aimed to compare the estimation successes of product inner quality criteria estimated by ANN-Regression models with the estimation successes obtained by using the same data sets in a previous study (Selen, 2021) and using PLS (Partial Least Squares) analysis. Thus, comparing the estimation results of internal quality parameters made with linear methods such as PLS analysis in the previous study with the estimation results made by nonlinear methods such as ANN-Regression on the same data sets has been compared.

Three different ANN-Regression models (architecture) were developed to predict three different tomato inner quality criteria (with different input value numbers and different hidden layer neuron numbers). The results obtained in the estimation of the firmness, TSSC and pH properties of tomato samples with the developed ANN-Regression models, were especially superior for firmness and pH compared to the estimation results obtained by the PLS method, which was previously developed and used for the estimation of the same inner properties on the same data set. The regression values obtained for firmness and pH estimations using the ANN-Regression model for the test data set were $R^2=0,85$ and $RMSE=225,80$ (firmness) ; $R^2=0,65$ and $RMSE=0,11$ (pH) respectively. The estimation results for the content of TSSC in both studies were almost the same (the regression value

R^2 was 0,83 in both studies, while the RMSE value was 0,38 for the ANN-Regression model and 0,406 in the PLS analysis study).

Keywords: FT-NIR Spectroscopy, ANN-Regression, Firmness Prediction, TSSC Prediction, pH Prediction, Artificial Neural Networks



İÇİNDEKİLER

	Sayfa No
JÜRİ ONAY SAYFASI.....	i
ETİK BEYAN.....	ii
SUNUŞ ve TEŞEKKÜR.....	iii
ÖZET.....	iv
ABSTRACT.....	vi
İÇİNDEKİLER.....	viii
SİMGELER VE KISALTMALAR.....	x
TABLolar DİZİNİ.....	xi
ŞEKİLLER DİZİNİ.....	xii

BİRİNCİ BÖLÜM

GİRİŞ

1

1.1. Tez Çalışmasına Genel Bakış.....	1
1.1.1. Çalışmanın Nedenselliği.....	1
1.1.2. Çalışmanın Konusu.....	3
1.1.3. Çalışmanın Amacı.....	4
1.1.4. Çalışmanın Önemi.....	4
1.2. Yakın Kızılötesi Spektroskopisi (NIRS).....	6
1.2.1. Yakın Kızılötesi Yansıma (Reflectance) Spektroskopisi.....	7
1.2.2. Yakın Kızılötesi Etkileşim (Interactance) Spektroskopisi.....	8
1.2.3. Yakın Kızılötesi İletim (Transmittance) Spektroskopisi.....	9

İKİNCİ BÖLÜM

KURAMSAL ÇERÇEVE/ÖNCEKİ ÇALIŞMALAR

10

2.1. Literatür Taraması.....	10
2.1.1. Gıda ve Tarım Ürünleriyle İlgili Çalışmalar.....	10
2.1.2. Domates Üzerine Yapılan Çalışmalar.....	15

ÜÇÜNCÜ BÖLÜM

ARAŞTIRMA YÖNTEMİ/MATERYAL VE YÖNTEM

20

3.1. Domateslerin Yetiştirilmesi ve Verilerin Toplanması.....	20
3.1.1. Domateslerin Yetiştirilmesi ve Hasat Edilmesi.....	20
3.1.2. Domates Özelliklerinin Spektral ve Fiziksel Özelliklerinin Ölçümü.....	21
3.2. YSA-Regresyon Modellerinin Geliştirilmesi.....	27

3.2.1 Yapay Sinir Ağları.....	27
3.2.2. Levenberg Marquardt Yöntemi.....	29
3.3. Model Mimarisinin Oluşturulması ve Verilerin Analiz Edilmesi.....	31
3.3.1. Yapay Sinir Ağları Regresyon (YSA-Regresyon/Artificial Neural Networks Regression) Modellerinin Geliştirilmesi.....	31
3.3.2 Verilerin Analizi ve Kullanılan Paket Programların İşleyişi.....	37
DÖRDÜNCÜ BÖLÜM	
ARAŞTIRMA BULGULARI	
4.1. Analiz Sonuçları.....	41
4.1.1. Domateslerin Sertlik Özelliklerinin Tahmin Sonuçları.....	42
4.1.2 .Domateslerin SÇKM Özelliklerinin Tahmin Sonuçları.....	45
4.1.3. Domateslerin pH Özelliklerinin Tahmin Sonuçları.....	47
4.1.4. Sonuçların Özeti.....	49
BEŞİNCİ BÖLÜM	
SONUÇ VE ÖNERİLER	
KAYNAKÇA.....	53
ÖZGEÇMİŞ.....	I

SİMGELER VE KISALTMALAR

TÜBİTAK	Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
TÜİK	Türkiye İstatistik Kurumu
SÇKM	Suda Çözünür Kuru Madde
TSSC	Soluble Solid Content
pH	Asitlik
N	Newton
kg	Kilogram
NIR	Near InfraRed
NIRS	Near InfraRed Spectroscopy
FT-NIR	Fourier Transform Near InfraRed
R ²	Kararlılık Katsayısı
RMSE	Root Mean Square Error
RMSD	Root Mean Square Deviation
YSA	Yapay Sinir Ağları
ANN	Artificial Neural Network
MSC	Multiplication Scattering Correction
LMA	Levenberg Marquardt Algorithm
SG	Savitzky Golay Filtresi
%	Yüzde
PLS	Partial Least Square
PLSR	Partial Least Square Regression
PCA	Principal Component Analysis
LDA	Linear Discriminant Analysis
°C	Santigrat Derece
nm / µm	Nanometre
mm	Milimetre
ANOVA	Analysis Of VAriance
SVM	Support Vector Machine
AUC	Area Under Curve
GA	Genetik Algoritma
MPA	Multi Purpose Analyser

TABLULAR DİZİNİ

Tablo No	Tablo Adı	Sayfa No
Tablo 1	Çalışmada ele alınan domateslerin hasat ve ölçüm takvim çizelgesi	22
Tablo 2	Çalışmada kullanılan kiraz domates meyvelerinin fiziksel özellikleri	24
Tablo 3	MPA-FT-NIR spektrometre ile yansıma modunda gerçekleştirilen ölçümlere dayalı olarak yapılan en iyi sertlik, SÇKM ve pH tahmin sonuçlarının alındığı modellere ait spektrum ön işleme yöntem bilgileri	26
Tablo 4	Her bir fiziksel özelliğin tespiti için YSA tarafından kullanılan verilerin sayıları	32
Tablo 5	Sertlik için YSA-Regresyon modeline ve PLS analiz yöntemine (önceki çalışma) göre tahmin sonuçları	43
Tablo 6	SÇKM için YSA-Regresyon modeline ve PLS analiz yöntemine (önceki çalışma) göre tahmin sonuçları	45
Tablo 7	pH için YSA-Regresyon modeline ve PLS analiz yöntemine (önceki çalışma) göre tahmin sonuçları	47
Tablo 8	pH için YSA-Regresyon modeline ve PLS analiz yöntemine (önceki çalışma) göre tahmin sonuçları	50

ŞEKİLLER DİZİNİ

Şekil No	Şekil Adı	Sayfa No
Şekil 1	Kiraz (cherry) domates (Getty Images)	1
Şekil 2	Bitkisel üretim istatistikleri (TÜİK, 2022)	5
Şekil 3	Elektromanyetik spektrumda ışımaların Frekans, Dalgaboyu ve Enerji değerleri (Wikipedia topluluğundan Denelson83; 2011)	6
Şekil 4		7
Şekil 5	Yansıma biçimleri; (a) speküler ve (b) difüz yansıma (İğdeci, 2020)	8
Şekil 6	Etkileşim spektroskopisi, ışık kaynağı (a) ve alıcı-verici prob (b) (Yuping ve K, 2021)	9
Şekil 7	NIR iletim spektroskopisi yöntemi (Büyükcan, 2008)	9
Şekil 8	Yapay sinir ağlarının çalışma şeklini gösteren diyagram (Debroy ve Lalu, 2022)	16
Şekil 9	NIR ham datası (ön işleme yapılmamış) (üstte) ve en iyi sonuç veren model mimarisinin (Genetik algoritma ve PLS) ön işlenmiş (Savitzky Golay filtresi ile) data seti (altta) (Diane vd., 2023)	17
Şekil 10	Domateslerin ÇOMÜ Dardanos Yerleşkesi'nde yetiştirildiği sera	21
Şekil 11	Yansıma modu spektrum ölçümü; domates örneği ve üzerine tutulan prob (sağ alt)	23
Şekil 12	MPA FT-NIR spektrometrenin yansıma modunda kullanımı	24
Şekil 13	Renklerine göre hasat edilen domateslerin yeşilden kırmızıya olgunluk aşamalarına göre farklılıkları; hasat sonrası teste alınmadan önce viyol kartona dizilmiş (üstte); laboratuvarında teste alınmaya hazır (altta)	25
Şekil 14	Cahit Arf'ın öğrenen bir makinanın insan beyniyle benzerliğini gösteren şeması	28
Şekil 15	Yapay sinir ağları mimarisi	29
Şekil 16	Sertlik tahmininin eğitimindeki iyileşmeyi veren hata grafiği	34
Şekil 17	SÇKM tahmininin eğitimindeki iyileşmeyi veren hata grafiği	35
Şekil 18	pH tahmininin eğitimindeki iyileşmeyi veren hata grafiği	37
Şekil 19	Verilerin toplanması ve analizinin basamakları	37
Şekil 20	UnscramblerX ve MatLab yazılımlarının çalışması	39
Şekil 21	Modelin geliştirilmesinde izlenen yolu gösteren iş akış şeması	40
Şekil 22	MatLab Yapay Zeka Eğitim modülü ayarlamaları	40
Şekil 23	Microsoft Excel Data Analys eklentisinde verilere uygulanan regresyon analizinin ayarlandığı pencereler	42
Şekil 24	Sertlik Analizi YSA Modelinin test sonuçları	44
Şekil 25	Sertlik Analizi YSA modelinin tüm eğitim sonuçları	44
Şekil 26	SÇKM Analizi YSA Modelinin test sonuçları	46
Şekil 27	SÇKM Analizi YSA Modelinin tüm eğitim sonuçları	46
Şekil 28	pH Analizi YSA Modelinin test sonuçları	48
Şekil 29	pH Analizi YSA Modelinin tüm eğitim sonuçları	48

BİRİNCİ BÖLÜM

GİRİŞ

Tarımda otomasyon, endüstrinin pek çok alanında yoğun ve vazgeçilmez bir şekilde kullanıldığı gibi ürünlerin sınıflandırılması, değerlendirilmesi ve pazarlanması süreçlerinin ayrılmaz bir parçası olarak karşımıza çıkmaktadır. Gıdanın topraktan sofraya uzanan serüveninde tarımsal ürünlerin kalite parametrelerinin hassasiyetle ölçülmesi son derece önemli olmakla birlikte bunun için teknoloji kullanımı mamullerin doğası gereği sanayideki gibi standart uygulamalarla gerçekleştirilememektedir. Bu sebeple tarımsal ürünlerin sınıflandırılması ve kıymetlendirilmesinde ürüne has teknikler geliştirilmesi ihtiyacı ortaya çıkmaktadır (Büyükcan, 2008) (İğdeci, 2020).

1.1. Tez Çalışmasına Genel Bakış

1.1.1. Çalışmanın Nedenselliği

Beslenmede önemli bir yere sahip sebze grubunda yer alan domates (Şekil 1), ülkemiz için de vazgeçilmez tarım ürünlerinden biri olup, üretimi ve tüketimi yıl boyunca devam eden ürünlerin başında gelmektedir. Tüketimi en yaygın olan ürünlerden olan domatesin ekonomik değeri de özellikle kış aylarında yüksek sayılabilecek düzeylerde seyretmektedir.



Şekil 1. Kiraz (cherry) domates (Getty Images)

Bunun yanında, ürünlerin kalitesine göre sınıflandırılması, verimli şekilde değerlendirilmesi için son derece önemlidir. Bu aşamada sofralık ürünlerin en iyi kaliteye sahip olacak şekilde sınıflandırılıp pazara sunulması beklenirken, daha düşük kaliteye sahip ürünler sanayide işlenerek paketlenmiş ürün olarak değerlendirilmektedir. Bu şekilde, ürünler zayi olmaksızın değerlendirilip, doğru ekonomik değerleri belirlenmekte ve tüketici de mümkün olan en yüksek kalitede ürünü tüketme şansına sahip olabilmektedir. Ürünlerin doğru ekonomik değerinin ve kalitesinin belirlenmesinde etkili bir sınıflamanın önemi büyüktür. Bu aşamada, ürünlerin doğru ve hızlı bir şekilde sınıflandırılmasında otomasyon önem kazanmaktadır.

Ürünlerin kalitesine göre sınıflandırılması genellikle dış özelliklerine göre yapılmaktadır; bunlar arasında, ürünün büyüklüğü, rengi, hasar durumu ve şekli ön plana çıkmaktadır. Bu dış özelliklere göre ürünler iyi, orta ve kötü olarak sınıflandırılabilir. Bununla birlikte, ürünlerin kalitesini belirleyen faktörler sadece dışsal faktörler olmayıp, sertlik, suda çözünen kuru madde oranı (SÇKM), pH gibi içsel özellikler de ürünlerin kalitesinde önemli paya sahip faktörlerdir. Son zamanlarda, içsel kalite parametrelerinin de sınıflama uygulamalarına dahil edildiği görülmektedir. Önceleri mekanik sistemlere dayalı, hasarlı olarak ve sadece seçilen ürünler üzerinde yapılan bu sınıflama işlemleri gelişen teknolojiyle hasarsız olarak ölçüm yapabilen ve her bir ürüne uygulanabilen dijital sistemlere dönüşmektedir. Tüm bunların sonucunda her bir ürüne hasarsız olarak NIR spektroskopisine dayalı olarak uygulanan içsel kalite kriteri tahmin yöntemlerine yönelik çalışmalar giderek önem kazanmakta ve literatürdeki yeri artmaktadır.

Bununla birlikte otomatik sınıflama sistemlerinde, elde edilen verilerin değerlendirilme aşamasında yapay-zeka (artificial intelligence) uygulamaları da aynı derecede öneme sahip olup verilerin en iyi şekilde kıymetlendirilmesi, ürün kalitesi hakkında en doğru kararın verilmesi için son derece önemli bir uygulamadır. Özet olarak bir otomatik sınıflama sisteminin başarılı olabilmesi için, ürün kalitesi ile ilgili verilerin en hassas şekilde ölçülmesi ve bu verilerin en iyi şekilde işlenerek ürün kalitesi hakkında en doğru kararın verilmesi gerekmektedir. Bu şekilde çalışan sistemlerin önemli bir avantajı da ölçüm ve değerlendirmelerin her bir ürün için tek tek yapılabilmesi ve aynı zamanda ölçümlerin hasarsız olabilmesidir (tahribatsız muayene). Sonuç olarak her iki alanda da teknik gelişmelere ve yeni araştırmalara ihtiyaç duyulmaktadır. Yapılan bu çalışma, ekonomik değeri yüksek bir ürün olan domateste içsel kalite özelliklerinin tayinine yönelik otomasyona

dayalı bir algılama ve sınıflandırma sisteminin geliştirilmesine yardımcı olacak sonuçlar ortaya koyma potansiyeline sahiptir.

1.1.2. Çalışmanın Konusu

Bu tez çalışmasında, kış mevsiminde sera koşullarında yetişen ve talep-fiyat yönünden sezonluk meyve ve sebzeler ile rekabet etmekte olan sofralık kiraz domateste içsel kalite kriterlerinin (sertlik, suda çözünür kuru madde (SÇKM), pH) FT-NIR spektrometre ile yansıma (reflectance) modunda alınan spektral ölçümlerin ve standart yöntemlerle alınan fiziksel ölçüm (sertlik, SÇKM, pH) değerlerinin yapay sinir ağları regresyon (YSA-Regresyon) yöntemi ile değerlendirilerek ürün kalite tahminine yönelik hasarsız bir modelin geliştirilmesi hedeflemektedir.

Bu çalışma kapsamında veri olarak, daha önce Tarım Makinaları ve Teknolojileri Mühendisliği Bölümü laboratuvarında kiraz domates örnekleri üzerinde FT-NIR spektrometre ile yansıma modunda yapılan spektral ölçümler (TÜBİTAK-118O679) (Kavdır, 2020) ve ardından gerçekleştirilen fiziksel özellik ölçümlerini içeren veri seti (sertlik, pH ve suda çözülebilir kuru madde) kullanılmıştır. Kiraz domatesler üzerinde hasarsız bir şekilde gerçekleştirilen spektral ve hasarlı şekilde gerçekleştirilen fiziksel ölçümler, daha önce ölçümlerin yapıldığı çalışma kapsamında gerçekleştirilmemiş olan ve bu çalışma kapsamında geliştirilen yapay sinir ağları regresyon (YSA-Regresyon) modelinin oluşturulması ile değerlendirilmiş ve domateslerin iç kalite özellikleri tahmin edilmeye çalışılmıştır. Sonuç olarak domates örnekleri çalışma kapsamında geliştirilen yapay sinir ağları regresyon (YSA-Regresyon) modellerinin kullanılması ile değerlendirilmiş ve kalite parametrelerinin tahmin edilmesine çalışılmıştır. Bu anlamda çalışmanın kapsamı, yansıma spektrumlarının yapay sinir ağları için yapısal olarak organize edilmesi (farklı programlar tarafından kullanılabilir ve yapay sinir ağlarına girdi olarak sunulabilir duruma getirilmesi), etkili yapay sinir ağları modelinin ortaya konabilmesi için çalışmalar yaparak en etkili yapay sinir ağları modelinin (mimarisinin) belirlenmesi için gerekli çalışmaların yapılması ve tahmin sonuçlarının değerlendirilmesi aşamalarını içermektedir. Daha önce gerçekleştirilen çalışmalar (TÜBİTAK-118O679) kapsamında yapay sinir ağları sınıflayıcısı herhangi bir şekilde ele alınmamıştır (Kavdır, 2020) (Selen, 2021).

1.1.3. Çalışmanın Amacı

Makine öğrenmesinin temel bileşenlerinin kullanıldığı bu çalışmanın amacı, ülkemiz için önemli bir tarımsal ürün ve gıda olan domateste bazı içsel kalite özelliklerinin FT-NIR yansıma spektroskopisi ve yapay sinir ağları (artificial neural networks) regresyon (YSA-Regresyon; ANN-Regression) modelinin kullanılması ile hasarsız olarak tahmin edilmesidir. Yaygın uygulamalarda, sadece seçilen bir grup domates üzerinde hasarlı olarak yapılan domates iç özelliklerine ait kalite parametrelerinin ölçümleri yerine, FT-NIR spektroskopisi ile her bir ürün üzerine uygulanan hasarsız ölçümlere ve yapay sinir ağlarına dayalı bir makinalı öğrenme yaklaşımının gerçekleştirilmesi bu tezin temelini oluşturmaktadır.

Bu çalışmayı diğer çalışmalardan ayıran önemli farklılıklar şu şekilde sıralanabilir:


- Çalışmada Fourier dönüşümlü yakın kızıl ötesi (FT-NIR) spektrometre ile elde edilen spektrumların kullanılmış olması,
- Yansıma yönteminde 780-2500 nm arasındaki oldukça geniş dalga boyu aralığının domateslerin iç kalite kriterlerinin tahmin edilmesinde kullanılmış olması,
- Literatürde çok sık karşılaşılmayan, spektral ölçümlerin yapay sinir ağlarına (ANN) girdi özellikleri olarak sunulmuş olması (diğer bir deyişle, NIR spektrumları ve yapay sinir ağlarının birlikte kullanılmış olması).

Bu çalışmanın amacının özünde tarımsal bir ürünün yetiştirilmesi, hasat edilmesi, tahribatlı (fiziksel ölçümler) ve tahribatsız (FT-NIR spektral ölçümler) yöntemlerle ölçümlerinin yapılması yanında, domatesin içsel kalite özelliklerinin tahmin edilmesinde farklı bir modelleme mimarisi (yapay sinir ağlarına dayalı olarak) kullanılarak analiz edilmesi, yorumlanması ve yeni regresyon yaklaşımlarının önerilmesi (ayrıca bu çalışmada elde edilen tahmin sonuçlarının önceki tahmin sonuçları ile karşılaştırılması) bulunmaktadır.

1.1.4. Çalışmanın Önemi

Bu çalışmada ülkemizdeki tarım üretiminde payı büyük olan domatesten, sofralık tüketimi yoğun olan kiraz domates cinsi kullanılmıştır. Türkiye'nin tarımsal üretiminde

sebze üretiminin 1/3'ünden fazlasını domates üretimi oluşturmaktadır (Şekil 2) (TÜİK, 2022).



Şekil 2. Bitkisel üretim istatistikleri (TÜİK, 2022)

Bunun yanında teknik açıdan ve literatüre bakılarak, geniş bir dalga boyu aralığına sahip bir FT-NIR spektrometre ile veri alınmış olması, alınan spektrumların bu çalışma kapsamında geliştirilen bir yapay sinir ağları regresyon modeli içerisinde kullanılmış olması (ki bu konu literatürde çok fazla irdelenmemiştir), ve yansıma spektrumlarını en iyi şekilde algılayarak ürün özelliklerinin tahmin edilmesinde kullanılan bir yapay sinir ağları modelinin geliştirilmiş olması tezin önemli farklılıklarıdır. Bu teknik farklılıklar açılacak olursa;

Yakın kızılötesi spektroskopisinin (NIRS) Fourier dönüşümlü bir varyasyonu olan FT-NIR spektroskopisi ile buradan elde edilen verilerin yapay sinir ağları modelleriyle bütünleşmiş şekilde kullanımı literatürde sık rastlanmayan veya sadece ileri uygulamalarda tavsiye edilen bir yöntem iken, bu çalışmada geliştirilen ve kullanılan makina öğrenmesine dayalı model (yapay sinir ağları regresyon, YSA-Regresyon), aynı verileri kullanarak aynı amacı hedefleyen geçmiş çalışmalar (Selen, 2021) ile kıyaslanmıştır. Böylelikle domates

gibi tarımsal ürünlerin içsel kalitelerinin tahmin edilmesinde, yeni, verimli, ekonomik ve hızlı bir yöntem geliştirilmesi hedeflenerek endüstriye ve literatüre güçlü ve farklı bir model kazandırılması hedeflenmiştir.

Ayrıca yerel kalkınma modelinin önemine vurgu yapılan ulusal tarım politikamız göz önüne alındığında, Çanakkale bölgesinin tarımsal ekonomik değeri yüksek bir ürünü olan domates üzerinde yapılan bu çalışmanın bölgesel kalkınma açısından katma değerli bir endüstriyel projeye dönüşme potansiyeli de göz önünde bulundurulmalıdır.

1.2. Yakın Kızılötesi Spektroskopisi (NIRS)

Yakın kızılötesi spektroskopisi (NIRS) son yıllarda gıda endüstrisinde kullanılan ve hızlı sonuç veren bir tahribatsız muayene yöntemi olarak öne çıkan, kalite parametreleri hakkında fazlaca bilgi sağlayan bir tekniktir (Haiyan ve Yong, 2007).

Dalga boyu uzunluğu 700 nm ile 1mm arasında olan, elektromanyetik tayfta görünür kırmızıdan hemen sonra başlayıp mikrodalgaya kadar olan aralıkta bulunan kızılötesi ışınlar, kendi içinde de alt bölgelere ayrılmaktadır (Haynes, 2011). Literatürde en genel haliyle 700-2500 nm bölgesi yakın kızıl ötesi olarak ifade edilse de bunun 1400 nm'ye kadar olan kısmı yakın ve 3000 nm'ye kadar olan kısmı kısıdalga kızılötesi olarak tanımlanmıştır (Şekil 3) (Byrnes, 2009).

CLASS	FREQUENCY	WAVELENGTH	ENERGY
γ	300 EHz	1 pm	1.24 MeV
HX	30 EHz	10 pm	124 keV
SX	3 EHz	100 pm	12.4 keV
EUV	300 PHz	1 nm	1.24 keV
NUV	30 PHz	10 nm	124 eV
UV	3 PHz	100 nm	12.4 eV
NIR	300 THz	1 μm	1.24 eV
MIR	30 THz	10 μm	124 meV
FIR	3 THz	100 μm	12.4 meV
EHF	300 GHz	1 mm	1.24 meV
SHF	30 GHz	1 cm	124 μeV
UHF	3 GHz	1 dm	12.4 μeV
VHF	300 MHz	1 m	1.24 μeV
HF	30 MHz	10 m	124 neV
MF	3 MHz	100 m	12.4 neV
LF	300 kHz	1 km	1.24 neV
VLF	30 kHz	10 km	124 peV
VF/ULF	3 kHz	100 km	12.4 peV
SLF	300 Hz	1 Mm	1.24 peV
ELF	30 Hz	10 Mm	124 feV
	3 Hz	100 Mm	12.4 feV

Şekil 3. Elektromanyetik spektrumda ışımaların Frekans, Dalgaboyu ve Enerji değerleri (Wikipedia topluluğundan Denelson83; 2011)

Yakın kızılötesi spektroskopisinin tarihi, Alman asıllı İngiliz bilim insanı ve müzisyen Fredrick William Herschel'in (Şekil 4) spektrumda görünmez bölgeler keşfetmesi ve 1800'de Philosophical Transactions of The Royal Society of London'da yayınlamasına dayanmaktadır. 1950'lere kadar olan dönemde NIRS üzerine başka çalışma yapılmazken daha sonra NIR Spektroskopisinin babası olarak anılacak olan Karl Norris ve arkadaşlarının yaptığı çalışmalarla 50'lerden itibaren popüler olmuştur. 1970'lerde kemometrideki kullanımı başlamış, 80'lerde ise fiber optiğin gelişimiyle endüstriyel ve bilimsel kullanımı yaygınlaşmıştır. Günümüzde yaygın kullanılan analitik yöntemlerin yanı sıra pek çok avantajıyla gıda ve tarım endüstrisinde tahribatsız kalite tayini için tercih edilen bir teknik haline almıştır (Siesler vd., 2008; Manley ve Baeten, 2018).




Şekil 4. Herschel'in yağlıboya portresi (Lemuel Francis Abbott; National Portrait Gallery; 1785)

1.2.1. Yakın Kızılötesi Yansıma (Reflectance) Spektroskopisi

Elektromanyetik ışınımın (radyasyon) dalga boyunda değişiklik olmaksızın bir yüzeyden geri dönüşüne yansıma denir. Yansıma spektroskopisi, yansıyan ışığın dalga boylarını saptayarak bileşim bilgilerini ortaya çıkarma potansiyeline sahiptir. Dalga boyuna bağlı olarak, numuneden yansımayan ışık, numunenin kimyasal bileşimine göre emilir, saçılır veya iletilir. Bir yüzey ışığın belirli dalga boylarını soğurursa, ışığın göreceli yoğunluğu

azalır. Genel olarak, yansıyan ışığın yoğunluğu, gelme açısının yanı sıra kırılma indisine, yüzey pürüzlülüğüne ve elbette cismin soğurganlığına (absorbsiyon/emilim miktarı) bağlıdır (Flores, 2016). Pürüzsüz yüzeylerde spekül yansıma görülürken, yüzey özelliklerinin kusurlu olduğu durumlarda saçılım (difüz) yansıması gözlenir (Blount, 2018) (Şekil 5).

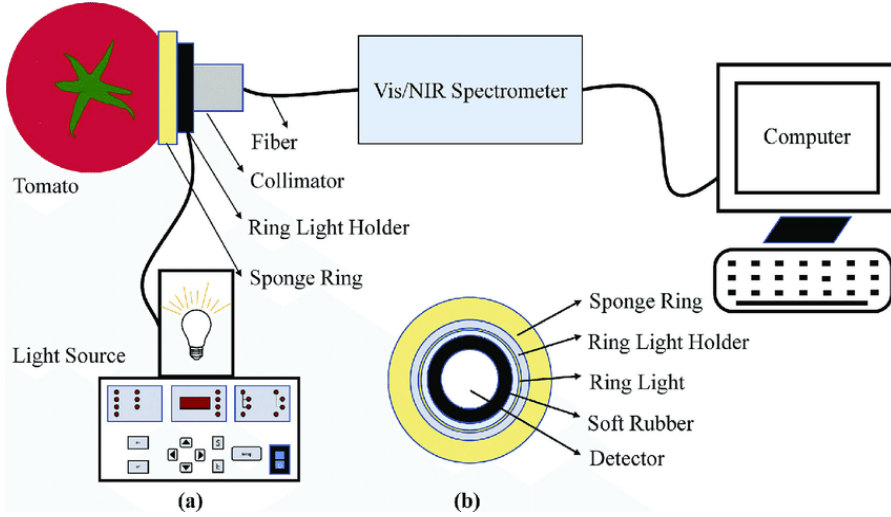


Şekil 5. Yansıma biçimleri; (a) spekül ve (b) difüz yansıma (İğdeci, 2020)

1.2.2. Yakın Kızılötesi Etkileşim (Interactance) Spektroskopisi

Yakın kızılötesi NIR etkileşim spektroskopisinde gelen elektromanyetik radyasyonun yüzeye nüfuz edip etkileşime girmesi ve sonrasında dağılmasıyla ışının yüzeye giriş noktasından farklı bir noktadan toplanmasına dayalı bir ölçüm yöntemidir. Numune, ölçüm probuna dayanabilmekte veya 1-2 mm boşluk bulanacak şekilde konumlandırılabilir (İğdeci, 2020).


Literatürdeki çoğu çalışmada etkileşim ölçümü, halka şeklindeki bir ışık kaynağı üstüne oturtulan numunenin, kaynaktan ışığı alması ve etkileşim sonucu halka göbeğindeki alıcılara geri iletmesi esasına göre yapılmakta (Şekil 6), ölçümlerden önce mutlak siyah ve mutlak beyaz kabul edilen masterlar (kalibrasyon numuneleri) ile cihaz sıfırlanmaktadır (Zhang vd., 2017).



Şekil 6. Etkileşim spektroskopisi, ışık kaynağı (a) ve alıcı-verici prob (b) (Yuping ve K, 2021)

1.2.3. Yakın Kızılötesi İletim (Transmittance) Spektroskopisi

Yakın kızılötesi spektroskopisinde iletim ölçümü ışık kaynağından numuneye giren ışının malzeme eti boyunca ilerleyip karşıdan çıkarak detektör (alıcı) tarafından yakalanması ve ölçülmesi esasına dayanmaktadır (Şekil 7). İletim yönteminde ışınlar malzemeyi boylu boyunca kesecek şekilde ilerlediğinden, uygun olması halinde içerik hakkında daha fazla bilgi vermesi yönüyle öne çıkmaktadır. En önemli eksikliği ise, yetersiz ışık kaynağı ve boyutça büyük numune kullanılması halinde ışığın karşı tarafa geçememesi veya yetersiz ya da hiç veri toplanamamasıdır (Büyükcan, 2008). İletim ölçümünün bir diğer kısıtlayıcısı ise 600-1000 nm dalga boyu aralığında çalışılmasına imkan vermesidir, zira biyolojik materyallerin büyük bölümü bu spektral aralığa duyarlıdır ve bu aralığın dışında yüksek absorpsiyon karakteri göstererek sonuçların yetersiz olması söz konusu olabilir (Kavdır vd., 2009).



Şekil 7. NIR iletim spektroskopisi yöntemi (Büyükcan, 2008)

İKİNCİ BÖLÜM

KURAMSAL ÇERÇEVE/ÖNCEKİ ÇALIŞMALAR

Yakın kızılötesi spektroskopisinin (NIRS) tarımsal ürünlerde hasarsız ölçüm tekniği olarak kullanımı oldukça yaygın ve bilinen bir yöntemdir. Pek çok çalışmada gerek tahıllar gerek meyvelerin fiziki ve kimyevi durumunun tayininde hızlı sonuç veren bir teknik olarak karşılaşılan bu metod için hazır paket programlar ve ticari cihazların yanısıra literatürde pek çok prototip ve farklı regresyon modelinin kullanımına rastlanmaktadır.

Gerçekleştirilen bu tez çalışması, NIR spektroskopi ve spektrumunun geniş bir aralığını kullanarak yansıma modu ölçümleri ve geliştirilecek bir yapay sinir ağı-regresyon (YSA-Regresyon) mimarisinin kullanımı ile domateslerin içsel özelliklerinin tahminini amaçlaması bakımından literatüre ve bu konuda yapılacak çalışmalara önemli katkılar sağlama potansiyeline sahiptir.

2.1. Literatür Taraması

Aşağıda verilen çalışmalar, spektral ölçümlerin yapay sinir ağı ve derin öğrenme uygulamalarında girdi olarak kullanılmasına literatürdeki az sayıdaki örneklerden bazılarıdır.

2.1.1. Gıda ve Tarım Ürünleriyle İlgili Çalışmalar

Nicolai ve arkadaşları 2007 tarihli yayınında NIR spektroskopisinin meyve ve sebze kalitesinin belirlenmesinde tahribatsız bir ölçüm tekniği olarak kullanımından bahsetmişler, hiperspektral teknikler ile kemometrik ölçümlerin kıyaslanmasında, yansıma, iletim ve etkileşim özelliklerinin kullanımı üzerine incelemeler yapmışlardır. Literatürdeki pek çok çalışmayı da tür bazında listeleterek yakın kızılötesi spektroskopisinin meyve ve sebze türlerinin birçoğunda kalite özelliklerini ölçmek için uygulanabilir olduğunu göstermişlerdir (Nicolai, ve diğerleri, 2007).

Massantini'nin başında olduğu bir ekibin 2014'te yayımlanan bir çalışmasında kestanede içsel böcek hasarının tespitinde NIR spektroskopisinin işlevselliği araştırılmıştır.

1582, 1900 ve 1964 nm dalga boyları için optimum sonuçların alındığı çalışmada eğri altında kalan alan (AUC: Area Under Curve) analiziyle %9'un altında bir hata ile sınıflandırma yapılmıştır. Geleneksel olarak kullanılan yüzdürme yöntemine göre ortalama %55 oranında gelişim sağlandığı ifade edilmiştir (Massantini, ve diğerleri, 2014).

2021 tarihli bir diğer yayında Çin tıbbında şeftali çekirdeğinin kanama durdurucu ve kayısı çekirdeğinin balgam söktürücü/öksürük kesici olarak kullanıldığı ifade edilmiş; görünüş olarak benzer oldukları için bazen üretimde yanlışlıkla bazen de bilerek tağşiş amaçlı karıştırıldığı belirtilmiştir. Ancak aktif bileşenlerinin ve tıbbi kullanım alanlarının belirtildiği gibi çok farklı olduğu ifade edilmiştir. Bu sebeple doğru şekilde ayırt edilmeleri gereken şeftali ve kayısı çekirdekleri için insan duyusuna dayanan yöntemin deneyim ve zaman gerektirdiğine dikkat çekilmiştir. Araştırmada şeftali ve kayısı çekirdeklerini doğru belirlemek için yakın kızılötesi spektroskopisi ve çok değişkenli analizler üzerine çalışılmıştır. Analizler 12500-4000 cm^{-1} dalga sayısı bölgesinde (tüm NIR) ve 12500-9000 cm^{-1} (yüksek) dalga sayısı bölgesinde yapılmıştır. Çalışmada ikinci bölgedeki spektrumların, pratik kullanıma uygun, ucuz ve basit bir cihazla ölçülebileceği ifade edilmiştir. Tüm NIR bölgesinden elde edilen spektrumlarda ise temel bileşen skor grafiği kullanılarak iki tip çekirdeğin ayırt edilebileceği sonucu alınmıştır. Yüksek dalga sayısı bölgesinde kısmi en küçük kareler diskriminant analizi kullanılarak analiz yapılmıştır. Sonuç olarak önerilen yöntemin şeftali ve kayısı çekirdeklerini doğru bir şekilde tanımlamak için güçlü bir araç olduğu ifade edilmiştir (Takayanagi vd., 2021).

Wang ve diğ., (2002) zararlı etkisinde olan soya fasulyesi tohumlarının yakın kızıl ötesi spektroskopi kullanılarak sınıflandırmışlardır. NIR bölgesinde 400-1700 nm arasında yansıma spektroskopisini kullanarak yaptıkları çalışmada PLS ve Neural Networks yöntemlerini kullanarak modeller geliştirmişlerdir. Araştırmacılar, sağlam ve hasarlı soya fasulyesi tanelerini birbirinden ayırdıkları iki-sınıflı modeli ele aldıklarında, %99'un üzerinde bir başarı oranı elde etmişlerdir. Bunun yanında, sağlam tohumların, hava koşullarından kaynaklı zarara sahip tohumlardan, donma hasarı, çimlenme durumu, ısı ve küf hasarına maruz kalmış tanelerden ayrılmasında sırasıyla %90, %61, %72, %54, %84 ve %86'lık sınıflama başarıları elde etmişlerdir (PLS modellerinin kullanılması ile). Diğer taraftan Neural Networks modelinin kullanılması ile ise daha iyi sınıflama başarıları elde edilmiştir; sağlam, hava koşulları zararı, donma hasarı, çimlenme durumu, ısı ve küf hasarına

maruz kalmış taneler için sırasıyla %100, %98, %97, %64, %97 ve %83'lük sınıflama başarıları elde edilmiştir (Wang vd., 2002).

Rong ve diğerlerinin 2020 tarihli çalışmasında şeftalileri VIS/NIR spektrumlarını ve derin öğrenme tekniğini kullanarak çeşitlerine göre birbirinden başarılı bir şekilde ayırt edebilmişlerdir. Bu çalışmada, şeftalilerin çeşitlerine göre sınıflandırılmasında, derin öğrenme sınıflandırıcısı diğer istatistiksel sınıflandırıcılar ile karşılaştırılmıştır. Derin öğrenme ile yapılan sınıflandırmada girdi olarak işlenmemiş şeftali spektrumları kullanılırken, istatistiksel sınıflandırıcılarda girdi olarak kullanılan spektrumlar ise ön işleme tabii tutulmuştur. Sonuçta derin öğrenme yaklaşımı ile elde edilen sonuçlar diğer sınıflandırıcılara göre istatistiksel olarak farklı olarak daha iyi olmuştur (Rong vd., 2020).

Zhaoyong ve ekibi 2016'da iletim spektrumları, yapay sinir ağları (ANN), destek vektör makinası (SVM) ve genetik algoritmanın (GA) kullanılması ile elma eksenindeki çürüklüğü belirlemişlerdir. Eksen çürüklüğünün tespitinde en optimum sonucu (%96,92) veren sınıflandırıcı GA-SVM olmuştur (Zhaoyong vd., 2016).

Kavdır ve diğerleri 2018'de yeşil zeytinleri yüzey özelliklerine göre (sinek zararı, eziklik ve sağlam olma durumları) sınıflandırmayı hedefledikleri çalışmada, FT-NIR spektroskopisi, yapay sinir ağları ve istatistiksel sınıflandırıcıları kullanmışlardır. Eziklik hasarına sahip ürünleri sağlam ürünlerden ayırmak için gerçekleştirilen uygulamada yapay sinir ağları %99 oranında bir başarı göstermiştir. Benzer şekilde sinek zararına maruz kalmış zeytinlerin sağlam zeytinlerden ayırt edilmesinde yapay sinir ağlarının kullanılması ile %98 oranında bir başarı elde edilmiştir. Diğer taraftan yapay sinir ağları uygulaması daha iyi sonuçlar vererek, üç sınıflı sınıflandırmada (eziklik zararına sahip ürünler, sinek zararına sahip ürünler ve sağlam ürünler) başarı oranı %92 olmuştur (Kavdır vd., 2018).

2021'de yayımlanan bir başka çalışmada siyah çayın kalitatif kategorizasyonu için hızlı ve ucuz bir yöntem aranmış, Ren ve diğerleri bunun için VIS-NIR spektroskopisi ve destek vektör makinesi (SVM) tabanlı bir sistem kullanmışlardır. Yedi ayrı seviyedeki çay örneklerinden spektral veri elde edilmiş, spektrumlar ön işleme alındıktan sonra karakteristik dalga boylarının tespitine çalışılmıştır. Kısmi en küçük kareler (PLS), rekabetçi uyarlamalı yeniden ağırlıklandırılmalı örnekleme (CARS) ve değişken yinelemeli boşluk küçültme yaklaşımı (VISSA) teknikleri kullanılmıştır. Doğrusal, kübik, kuadratik ve Gaussyen metodlar değişkene dayalı model geliştirilmesi için denenmiştir. %92'ye varan doğruluk oranıyla CARS-SVM modelinin en iyi sonuç verdiği bulunmuştur. Araştırmacılar VIS-NIR

spektroskopisinin siyah çayın kalitesini tahmin etmek için ucuz, hızlı ve alternatif bir yöntem olma potansiyelini vurgulamıştır (Ren vd., 2021).

2014'te Nakariyakul tarafından yapılan araştırmada, yakın kızılötesi spektral verileri kullanan gelişmiş dalga bandı seçimi ve denetimli model tanıma tekniklerine dayalı olarak bademde iç hasarın tespiti için sayısal bir teknik geliştirilmiştir. Çalışmada önerilen yöntem sınıflandırıcı olarak bir destek vektör makinesi ve küçük bir dalga bandı seti seçmek için optimal bir uyarlanabilir dal ve sınır algoritması kullanır. İlgili projede iç hasarlı bademlerin normal olanlardan ayırt edilmesi üzerine çalışılmıştır. Sınıflandırma modeli birkaç dalga bandı kullandığından ve sensör sistemleri tarafından hızlıca kaydedilebildiğinden, ticari uygulamalar için umut vadettiği vurgulanmıştır (Nakariyakul, 2014).

Brezilya'ya özgü juçara ve açai meyveleriyle ilgili 2016'da yayımlanan bir çalışmada Fourier Dönüşümlü (FT) NIR spektrumları kullanılarak oluşturulan kısmi en küçük kareler (PLS) regresyon modelinin sağlamlığı açıklanmıştır. İki yıl süreyle 6 seferde toplanan 505 örnek için, tek katmanda 25 meyve olacak şekilde bir cam tabak üzerinde dağınık yansıma spektrumları elde edilmiş, taramalar santimetreye 8 spektral çözünürlük olacak şekilde 64 seferde yapılmıştır. Açai meyvesindeki toplam antosiyanin içeriği (TAC) için 1606-1793 nm dalga boyu aralığı kullanılmış, standart normal değişken (SNV) yöntemi ve Savitzky-Golay gibi matematiksel işlemler uygulanmıştır. Yapılan çalışmada geliştirilen modellerin suda çözünebilir katı madde miktarı (SSC; TSSC; SÇKM; brix) ve antosiyanin içeriğine (TAC) dayalı olarak açai ve juçara meyvelerini iki sınıfa (düşük ve yüksek içerikli) ayırmak için kullanılabilir olduğu ifade edilmiştir (Júnior vd., 2016).

Sarımsakla ilgili 2021 tarihli bir çalışmada ekonomik kaygılarla gıdada tağşiş uygulanmasının önüne geçilmesi için araştırmalar yapılmıştır. Sarımsak ile talk, maltodekstrin, mısır nişastası, mısır unu, fıstık ezmesi tozu, sodyum kazeinat, patates nişastası, pirinç unu, manyok ve beyaz mısır unu gibi olası katkı maddelerinin ayırt edilmesine yönelik bir yöntem geliştirilmeye çalışılmıştır. Yakın kızılötesi (NIR) ve Fourier transform kızılötesi (FT-NIR) ile kemometri, tağşiş saptama yönteminin geliştirilmesi için kullanılmıştır. Sarımsakların katkı maddelerinden ayrılıp ayrılmadığını belirlemek için temel bileşen analizi (PCA) modellerinin oluşturulduğu çalışmada veri analizi için ortogonal kısmi en küçük kareler – diskriminant analizi (OPLS-DA) modeli kullanılmıştır. İlgili araştırmada yüzde 91 ila 99 oranında başarı sergilediği ifade edilen yöntemin baharat endüstrisinde

sahtekarlığın önüne geçmek için de kullanılabilceği ifade edilmiştir (Galvin-King vd., 2021).

2019 tarihli bir diğer çalışmada, pastırmanın nem, protein ve yağ içeriğinin NIR spektrometresi ile tayini amaçlanmış, sistemin akıllı telefonlara uyarlanması üzerine çalışılmıştır. Avrupa Birliği Horizon 2017 programında ödüle layık görülen üç girişim şirketinin geliştirdiği akıllı telefonlarla kullanılabilen mobil NIR spektrometre platformlarının kullanıldığı çalışmada, 740-1070 nm spektrum aralığı sunan bir mobil ünite ve Android işletim sistemli bir cep telefonu ile 940-1700 nm spektrum bandı sunan normal bir cihaz kullanılmış, sonuçlar karşılaştırılmıştır. Çalışmada analiz metodu olarak en küçük kareler regresyonu (PLSR), Rastgele Orman modeli (Random Forest) ve global modellerden faydalanılmış; akıllı telefon tabanlı bir platformun masaüstü sistemlerle kıyaslanır ölçüde doğruluk sağladığı belirtilmiştir (Kartakoullis vd., 2019).

Kamruzzaman ve diğerlerinin 2022'deki çalışmasında ultrasonik kurutmada gerçek zamanlı veri izleme amacıyla 900-1700 nm dalga boyunda NIR kullanan taşınabilir bir cihazın kullanımı üzerine çalışmışlardır. Veri işlemede, PLS ve YSA kullanan ekip ön işlem metodu olarak Savitzky-Golay birinci ve ikinci türevlerini kullanmıştır. R^2 değerinin 0,91 ve 0,95 olarak tespit edildiği çalışma ultrasonik yöntemle elma kurutmada sertliğin anlık olarak saptanmasında NIR ve YSA'nın faydalı olabileceğini göstermişlerdir (Kamruzzaman vd., 2022).

Tatlı limonlarda donma hasarının tespitini amaçlayan bir diğer çalışmada 400-1100 nm aralığında kısa dalga yakın kızılötesi (SW-NIR) ile yansıma, iletim ve yarı iletim (etkileşim) spektroskopileri kullanılarak alınan veriler yapay sinir ağlarıyla desteklenmiş temel bileşen analizi ve (PCA-ANN) ve destek vektör makinesi (SVM) kullanılarak işlenmiş, yarı iletim (etkileşim) modunun diğer tüm ölçümlerden daha iyi sonuç verdiği hatta %100 doğruluğa ulaştığı belirtilmiştir. Tüm spektrumlar ve model mimarilerinin toplam kullanımında %96'nın üzerinde doğruluk ile yapay sinir ağları, destek vektör makinesinden daha iyi sonuçlar vermiştir. Bu çalışma ile NIR ve YSA kullanımının donma hasarı tespitinde umut verici olduğu görülmüştür (Moomkesh vd., 2017).

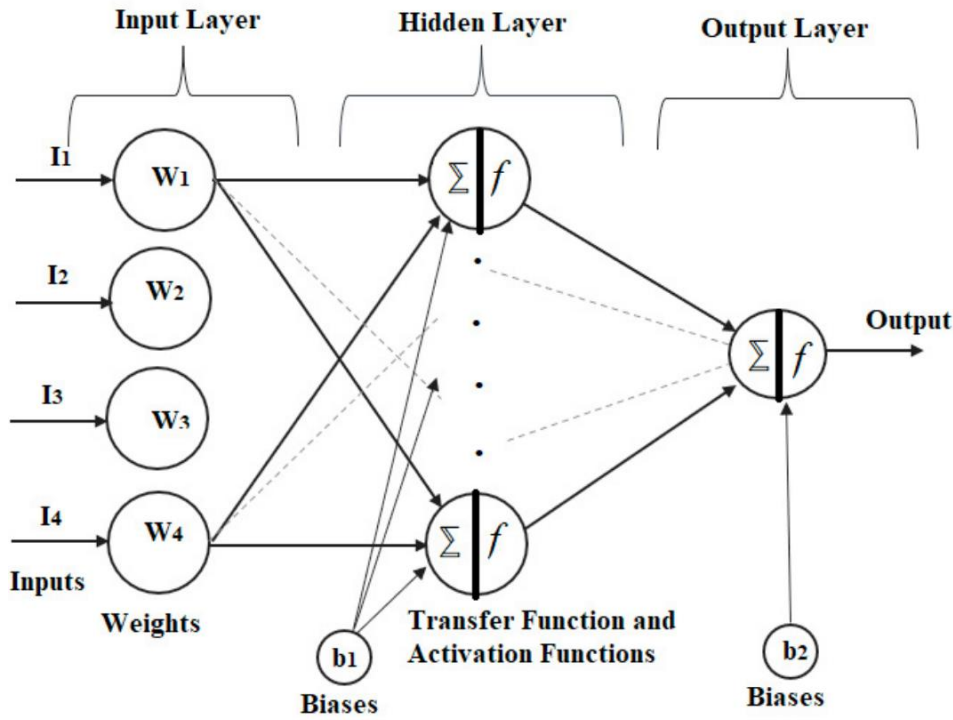
2.1.2. Domates Üzerine Yapılan Çalışmalar

Yukarıda verilenlerin dışında, domateste önemli kalite kriterleri olan suda çözülebilir kuru madde (SÇKM), sertlik ve pH gibi kalite kriterlerinin NIR spektroskopi kullanarak tahminine yönelik çalışmalar aşağıda belirtildiği üzere, farklı araştırmacılar tarafından ele alınmıştır.

İğdeci 2020’de yayımlanan çalışmasında ele alınan domates örneklerine ait içsel kalite kriterlerinden olan sertlik, suda çözümlü kuru madde (SÇKM) ve pH özelliklerini tahmin etmek için VIS-NIR (Visual NIR, görünür NIR) spektral ölçümleri, fiziksel (standart/hasarlı) ölçümleri ve PLS regresyon analiz yöntemini kullanmıştır. Sonuç olarak sertlik $R^2=0,79$ (RMSEP=279,18) ile $R^2=0,83$ (RMSEP=268,42) aralığında; SÇKM $R^2=0,52$ (RMSEP=0,705) ile $R^2=0,592$ (RMSEP=0,657) aralığında ve pH ise $R^2=0,72$ (RMSEP=0,12) ile $R^2=0,75$ (RMSEP=0,11) aralığında tahmin edilmiştir (İğdeci, 2020).

Benzer alanda Selen’in 2021 tarihli çalışmasında ele alınan domates örneklerine ait sertlik, suda çözümlü kuru madde (SÇKM) ve pH özelliklerini tahmin etmek için FT-NIR spektral ölçümleri (bu çalışmada da kullanılan), fiziksel (standart/hasarlı) ölçümleri ve PLS (en küçük kısmi kareler) regresyon analiz yöntemini kullanmıştır. Regresyon analizi sonuçlarında sertlik $R^2=0,80$ (RMSEP=256,0), SÇKM $R^2=0,86$ (RMSEP=0,38) ve pH ise $R^2=0,56$ (RMSEP=0,15) kararlılık ve hata katsayıları ile tahmin edilmiştir. Selen’in çalışmasında kullandığı spektral ve fiziksel ölçüm verileri bu çalışmada da aynen kullanılmıştır; ancak, bu veriler söz konusu çalışmalarda ele alınmamış olan yapay sinir ağlarına dayalı olarak geliştirilmiş farklı bir regresyon modeli olan Yapay Sinir ağları modelinde değerlendirilmiştir. Araştırma bulguları kısmında söz konusu fiziksel özellikler için elde edilen tahmin değerleri birbiriyle kıyaslanmıştır (Selen, 2021).

Debroy ve Lalu’nun 2022’de yayımladığı çalışmada akuaponik bir sistemde üretilen domatesin biyokütlesini doğru tahmin edebilmek için ileri beslemeli geri yayılım (feed forward back propagation) yapısına sahip bir YSA mimarisi (ANN) (Şekil 8) ve Gaussian fonksiyona sahip bir bulanık sinir ağı hibriti (ANFIS: Adaptive Neuro-Fuzzy Inference System) kullanılmıştır. Verilerin daha önceden yayımlanmış bir matematik model üzerinden elde edildiği çalışmada standart hata 0,4582 ve R^2 0,9918 olarak hesaplanmıştır. Geçmiş çalışmalarla yapılan kıyaslamada ANFIS modeli kullanımının faydasından bahsedilmiştir (Debroy ve Lalu, 2022).

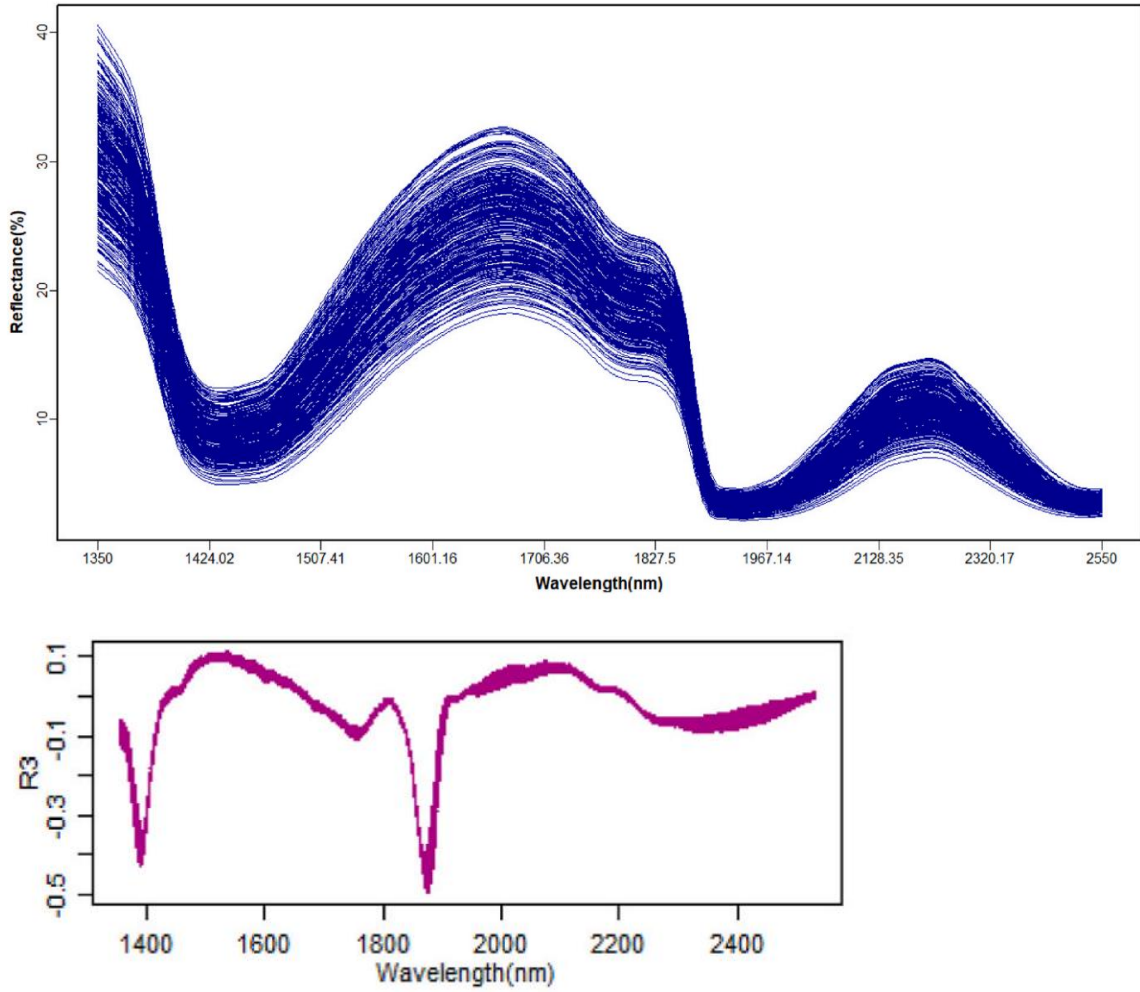


Şekil 8. Yapay sinir ağlarının çalışma şeklini gösteren diyagram (Debroy ve Lalu, 2022)

2023'te yayımlanan bir diğer çalışma, domateste yüksek ışık stresinin tespitinde verilerin işlenmesi için yapay sinir ağları kullanılmıştır. Çalışmada üç farklı yapay sinir ağları modeli; Boruta, Destek vektör makinesi (SVM: Support Vector Machine) ve Tekrarlamalı özellik eleyici (RFE: Recursive Feature Elimination) mimarileri kullanılmıştır. Söz konusu yapay sinir ağı mimarileri yüksek ışık stresi (High light stress) ile klorofil floresans (ChlF) arasındaki doğrusal olmayan ilişkinin belirlenmesinde kullanılarak, klorofil floresans (ChlF)'a bağlı en güvenilir özellikler belirlenmiş ve bu teknikle yüksek ışık stresine maruz kalan ve kalmayan bitkiler birbirinden ayırt edilebilmiştir. Yapay zekadan yardım alınan bu uygulamada tahminleme yapılmamış olup öne çıkan belirleyici özelliklerin tespiti amaçlanmıştır (Shomali vd., 2023).

Diane ve diğerleri tarafından 2023'te yayımlanan bir diğer çalışmada ise domates yaprağındaki Azot'un tahribatsız ve hızlı ölçümünün taşınabilir bir NIR spektrometre ve makine öğrenmesi metodlarıyla gerçekleştirilmesine odaklanılmıştır. 1350-2550 nm geniş dalga boyu aralığında 5 saniyelik ölçümler yapılan çalışmada verilere ön işlemenin SG (Savitzky Golay) filtreleme algoritmasıyla gerçekleştirildiği ifade edilmiştir. Genetik algoritmayla en küçük kareler ve genetik algoritmayla destek vektör makinesi metodları ayrı

ayrı değerlendirilmiş, validasyon sonuçlarında en iyi tahminlemeler kararlılık katsayısı (R^2) 83,41 ve hata (RMSE) 7,286 ile en küçük kareler yaklaşımı ile elde edilmiştir. Makine öğrenmesi tarafında destek vektör makinesi ise $R^2=81,744$ ve $RMSE=7,643$ değerleri ile Azot (N) tahmininde bulunmuştur. olarak sonuç vermiştir (Diane vd., 2023). Spektrum ön işleme yöntemlerinin spektrumlar üzerinde yaptığı değişikliklere bir örnek olarak bu çalışmada verilen spektrumlar ön işlenmesiz (orijinal halleri ile) olarak ve ön işlemeye tabii tutulmuş olarak Şekil 9’da verilmiştir.



Şekil 9. NIR ham datası (ön işleme yapılmamış) (üstte) ve en iyi sonuç veren model mimarisinin (Genetik algoritma ve PLS) ön işlenmiş (Savitzky Golay filtresi ile) data seti (altta) (Diane vd., 2023)

2022’de Ninja ve Manuj tarafından yayımlanan bir diğer çalışmada farklı çok derin evrişimli öğrenme teknikleri olan VGG (Visual Geometry Group), Inception ve ResNet

(Residual Neural Network) yaklaşımları domateslerin olgunluk durumuna göre sınıflandırılması için kullanılmıştır. Derin transfer öğrenimi tekniklerinin kullanıldığı bu çalışmada domatesler, olgun, kısmi olgunlaşmış ve olgunlaşmamış olarak (kırmızı, turuncu, yeşil) sınıflandırılmış; dil olarak Python, editör paket program olarak Anaconda3 kullanılmıştır. Yapılan farklı hacimdeki denemelerde VGG %96,05 doğruluk oranı ile en yüksek performansı göstermiştir. İlgili çalışma tahribatsız görsel muayenede yapay zeka kullanımının bir örneğini teşkil etmektedir (Ninja ve Manuj, 2022).

2022 de Brito ve diğerleri tarafından yapılan derleme çalışmasında son 10 yılda domatesin içsel kalite kriterlerinin NIR spektroskopisi ile belirlenmesiyle ilgili literatürde yapılan çalışmalar incelenmiştir. Çalışmada renk, asitlik, kuru madde temel parametreler olarak değerlendirilmiştir. Derlenen çalışmalarda yapay zeka, makine öğrenmesi vb. ileri doğrusal olmayan modelleme mimarilerine yer verilmemiş olup, temel bileşen analizi, en küçük kareler metodu gibi konvansiyonel regresyon yaklaşımları değerlendirilmiştir. Ayrıca standart normal dağılım, çarpımsal dağılım düzeltmesi, ortogonal dağılım düzeltmesi, Savitzky Golay gibi veri işleme metodlarının kullanımına değinilmiştir (Arruda de Brito vd., 2022).

2009'da Dariouchy ve diğerleri tarafından yapılan çalışmada Domates serasının içsel iklim koşulları, dış iklim koşullarına bağlı olarak çok katmanlı algılayıcılar modeli (MLP: Multi Layer Perceptron) ile YSA kıyaslanmıştır. Sıcaklık, nem, radyasyon ve rüzgar ölçümlerinin sera içi ve dışındaki sabit alıcılarla ölçüldüğü çalışmada, sıcaklık ve nem tahmininde %99'u geçen kesinlik (R^2) seviyelerine ulaşılmıştır. Çalışmada, sera iklimlendirmesinde de yapay zekadan destek alınabileceği gözler önüne serilmiştir (Dariouchy vd., 2009).

Domates üzerinde çalışılan 2016 tarihli bir araştırmada tohum canlılığı ve tohum partilerindeki varyasyon gibi önemli tohum kalitesi parametrelerinin tespitinde NIR görüntüleme tekniği kullanılabileceğinin keşfedildiği ifade edilmiştir. 2013, 2014 ve 2015 yıllarından Cal J, Monprecus, NCL ve Chiuri olmak üzere dört domates çeşidinin kullanıldığı çalışmada 975-2500 nm dalga boyu aralığında NIR hiperspektral verileri kullanılmış, değerlendirme temel bileşen analizi (PCA) ve kısmi en küçük kareler-diskriminant analizi (PLS-DA) ile yapılmıştır. PCA'nın canlı ve cansız domates tohumları arasında belirgin bir ayırma modeli ortaya koyamadığının ifade edildiği çalışmada PLS-DA modeline yalnızca tek bir hasat yılının tohumları sunulduğunda, çeşit sınıfları için yüzde

100 doğrulukla tahmin etme yeteneđi gösterdiđi belirtilmiřtir. Tm numunelerin aynı anda kullanıldıđı denemelerde ise dođruluk, yzde 34 ile 88 arasında tespit edilmiřtir. C-H, N-H, O-H kimyasal bilgilerini ieren NIR blgelerinin, PCA ve PLS-DA modelleri zerinde etkili olduđunun ifade edildiđi alıřmada domates tohumlarının eřit tanımlama alıřmalarında NIR hiperspektral grntleme tekniđinin kullanımı nerilmiřtir (Gislum vd., 2016).

Sirisomboon ve arkadaşlarının 2012’de yaptıđı alıřmada domateste olgunluk ve tekstr zelliklerinin hasarsız olarak tahmin edilmesinde NIR spektroskopi kullanmıřlardır. 1100–2500 nm dalga boyu aralıđında, etkileřim (interactance) modunda gerekleřtirdikleri hasarsız spektral lmler ile hasarlı olarak gerekleřtirdikleri sertlik, SKM ve AIS (taze ađırlıktaki alkolde znmez katı madde) parametreleri arasındaki korelasyon iliřkilerine bakmıřlardır. Sonuta, yırtılma sertliđi iin biyo-yırtılma kuvveti en iyi sonucu ($R^2=0,95$ ve $RPD=2,71$) vermiřtir. Bunun yanında, SKM tahmini iin elde edilen modelin istatistiksel verileri ise $R^2=0,80$ ve $RPD=1,62$ řeklinde olurken, AIS iin $R^2=0,56$ ve $RPD=1,00$ řeklinde olmuřtur (Sirimsonboom vd., 2012).

Nikbakht ve diđerleri 2011’de domateste bazı kalite parametrelerinin hasarsız olarak tahmin edilmesinde Raman spektroskopi yntemini kullanmıřlardır. Kalite parametreleri olarak, suda zlr kuru madde (SKM) ve renk hedeflenmiřtir. Sonuta, domateste suda zlebilir kuru madde ieriđi ve renk zellikleri Raman Spektroskopi yntemi ile bařarılı bir řekilde tahmin edilmiřtir (renk tahmininde $R^2=0,85$ $RMSEP=0,33$ ve kuru madde tahmininde $R^2=0,79$ $RMSEP=0,29$) (Nikbath vd., 2011).

2014 tarihli bir diđer alıřmada btn domateste, toplam kuru madde (TSS), asitlik (pH), titre edilebilir asitlik (TA) ve likopen ieriđi gibi kalite kriterlerini VIS/NIR spektroskopi kullanarak hasarsız olarak tahmin edilmesi amalanmıřtır. En iyi sonular, PLS ynteminin spektrumların ortogonal sinyal dzeltme (OSC) yntemi ile iřlenmesinden sonra alt dalga boyu aralıđı olan 370-1040 nm iin elde edilmiřtir. Kararlılık katsayısı (R^2) kalite parametrelerinin ođunluđu iin, TA dıřında, 0,82’den daha byk bulunmuřtur (Saad vd., 2014).

Bu tez alıřmasında, nemli bir tarımsal rn olan domateste isel kalite kalitelerinin hasarsız olarak tahmin edilmesine ynelik olarak, yapay sinir ađları ve NIR spektrumları birlikte kullanılmıř ve bu anlamda literatrde az sayıdaki benzer alıřmalara nemli katkılar sađlanmıřtır.

ÜÇÜNCÜ BÖLÜM

ARAŞTIRMA YÖNTEMİ/MATERYAL VE YÖNTEM

Bu çalışma ile amaçlanan, verileri daha önceki bir çalışmada (Selen, 2021) alınan domates örneklerine ait içsel kalite kriterlerinin (sertlik, SÇKM ve pH) tahmin edilmesinde makinalı öğrenme prensibine dayalı olarak yapay sinir ağları regresyon (YSA-Regresyon) modelleri geliştirmek ve bu modellerden elde edilen tahmin sonuçlarının önceki çalışmada (Selen, 2021) PLS'ye (kısmi en küçük kareler) dayalı olarak elde edilen tahmin sonuçları ile kıyaslamasını yapmak olmuştur. Bu çalışmada ağırlık, etkili YSA-Regresyon modellerinin geliştirilmesine verilmiştir. Sonuçta, ürün kalite tahmininde elde edilecek bir iyileşme, geliştirilecek modellere bağlı olarak çalışacak/geliştirilecek otomasyon sistemlerinin başarısında ve ürünlerin (ve özelliklerinin) etkili olarak algılanmasında önemli avantajlar sağlayacaktır. Bu yüzden tahmin başarısının yüksek olması bu gibi çalışmalarda her zaman en önemli hedef olmaktadır. Tahmin başarısını yükseltmeye yönelik literatürde birçok çalışma göstermek mümkündür ve bu konuya oldukça önem verilmektedir.

3.1. Domateslerin Yetiştirilmesi ve Verilerin Toplanması

3.1.1 Domateslerin Yetiştirilmesi ve Hasat Edilmesi

Bu tez çalışmasında; TÜBİTAK-118O679 nolu projede ve Selen'in 2022'de yayımladığı çalışmada 720 adet Yingzi F1 cinsi kiraz domatesten alınan veriler kullanılmıştır (Selen, 2021). Domatesler Çanakkale Onsekiz Mart Üniversitesi Ziraat Fakültesi Dardanos yerleşkesinde bulunan uygulama seralarında yetiştirilmiş (Şekil 10); periyodik olarak hasat edilerek belli olgunluk seviyelerindeki domateslerden önce 780-2500 nm dalga boyu aralığında FT-NIR spektral ölçümler; ardından da standart fiziksel ölçümler gerçekleştirilmiştir. Veri setine ön işlem olarak Savitzky-Golay algoritması ile filtreleme uygulanmış ve bu işlem Unscrambler X paket programı ile yapılmıştır (Camo Analytics AS, Aspentech, Ver. 10.5.1).



Şekil 10. Domateslerin ÇOMÜ Dardanos Yerleşkesi'nde yetiştirildiği sera

3.1.2. Domates Özelliklerinin Spektral ve Fiziksel Özelliklerinin Ölçümü

Çalışmada kullanılan domates örneklerine ait fiziksel ölçümlerin istatistik bilgileri Tablo 1'de verilmiştir. Domatesler yaklaşık 2 aylık bir dönemde her seferinde yaklaşık 90 domates olacak şekilde periyodik olarak hasat edilmişlerdir (Tablo 1). Her hasatta 6 farklı olgunluk grubundan örnekler toplanmıştır. Hasat akşamüzeri gerçekleştirilmiş ve örnekler 4°C sıcaklıkta depolanmıştır. Hasadı takip eden gün örneklerin spektral ölçümleri gerçekleştirilmiştir. Spektral ölçümlerin ardından örnekler tekrar soğuk ortamda depolanmış ve sonraki gün örnekler üzerinde standart fiziksel ölçümler gerçekleştirilmiştir. Ölçümlerden önce örnekler soğuk ortamdan alınıp oda sıcaklığında 3 saat kadar bekletildikten sonra ölçümlere başlanmıştır (hem spektral hem fiziksel ölçümler). Ölçümlerden önce tüm domatesler numaralandırılmış ve numara sırasına göre ölçümler gerçekleştirilip kaydedilmiştir. Spektral ve fiziksel ölçümler örnekler üzerinde aynı yüzey üzerinde gerçekleştirilmiştir.

Tablo 1

Çalışmada ele alınan domateslerin hasat ve ölçüm takvim çizelgesi

	Toplandığı iş günü	Spektrum alındığı iş günü	Standart ölçümlerin yapıldığı iş günü
1. Grup	1	2	3
2. Grup	3	4	5
3. Grup	7	8	9
4. Grup	10	11	12
5. Grup	14	15	16
6. Grup	17	18	19
7. Grup	21	22	23
8. Grup	24	25	26

(Her grup ürün yaklaşık 90 adet örnek domatesin renk gruplarına göre hasat edilmesiyle elde edilmiştir.)


Yansıma modunda FT-NIR Spektrometre ile Yapılan Ölçümler

Spektral ölçümler için çok amaçlı bir cihaz olan (Multi Purpose Analyser) Bruker MPA II model bir FT-NIR spektrometre ve Opus paket programı kullanılmıştır (Bruker Optics GmbH & Co. KG, Ettlingen, Deutschland) (Şekil 11).



Şekil 11. Yansımada spektrum ölçümü; domates örneği ve üzerine tutulan prob (sağ alt)

Yansımada spektrumlarının alınmasında iki yönlü fiber optik kanallara (ışık kaynağından ışığı örneğe ve örnekten yansıyan ışığı detektöre taşıyacak şekilde) ve yaklaşık 11,7 mm²'lik bir ölçüm yüzeyine sahip ölçüm probu kullanılmıştır (Şekil 12). FT-NIR spektrometre içerisinde yansımada yüksek yoğunlukta NIR ışık kaynağına (tungsten-halojen) sahip TE-INGaAs detektörü kullanılmıştır. Spektral ölçümler 780-2500 nm dalga boyu aralığında gerçekleştirilmiştir. Her 10 domates örneği üzerinden gerçekleştirilen spektral ölçümlerden sonra karanlık ve standart materyalden (spectralon (kalibrasyon amaçlı referans materyali)) de birer spektral ölçüm gerçekleştirilmiştir (Şekil 11 ve 12). Her bir spektral ölçüm, yukarıda belirtilen dalga boyu aralığında bir spektrumu ifade etmekte ve ölçülen frekansın sayısal bir karşılığını vermektedir.



Şekil 12. MPA FT-NIR spektrometrenin yansıma modunda kullanımı


Hasarsız spektrum ölçümlerinden sonra, domateslere geleneksel tahribatlı muayene yöntemleri yani standart fiziksel ölçümler uygulanmıştır (model geliştirerek tahmin edilmesi hedeflenen). Bunlar uygulanma sırasına göre mekanik özelliklerden sertlik tayini, kimyasal özelliklerden ise suda çözünür kuru madde tayini (SÇKM/brix) ve pH tayinidir (Tablo 2).

Tablo 2

Çalışmada kullanılan kiraz domates meyvelerinin fiziksel özellikleri

Özellik (birim)	Ortalama değer	En düşük değer	En yüksek değer	Standart sapma
Ağırlık (g)	12,68	5,80	22,45	3,02
Uzunluk (mm)	39,35	26,55	83,23	3,92
Çap (mm)	23,20	17,57	28,37	1,90
pH (0-7-14)	4,19	3,59	4,95	0,23
SÇKM (%)	6,70	4,10	9,40	0,98
Kuvvet02 (g)	1518,0	697,04	5014,59	647,47
Kuvvet01 (g)	1397,0	678,06	4595,18	575,76

Domatesler tüm olgunlaşma düzeylerini doğru temsil edebilmesi adına her hasatta yeşilden kırmızıya, sarı ve turuncu geçişleriyle, toplamda 6 farklı olgunluk grubu olacak şekilde, tüm renk kombinasyonlarında toplanmış, sonrasında diğer fiziksel ölçümler için hazırlanmıştır (Şekil 13).



Şekil 13. Renklerine göre hasat edilen domateslerin yeşilden kırmızıya olgunluk aşamalarına göre farklılıkları; hasat sonrası teste alınmadan önce viyol kartona dizilmiş (üstte); laboratuvarında teste alınmaya hazır (altta)

Sertlik ölçümü TA-XT Plus tekstür cihazı (Stable Micro Systems Ltd. UK) ve TextureExponent 32 yazılımının kullanılması ile gerçekleştirilmiştir. Sertlik testi batma veya delinme yolu ile değil yük hücresi metoduyla yapılmıştır. Bunun için 40 mm çapında ve 20 mm yüksekliğinde akrilik malzemeden silindir bir yük hücresi kullanılmıştır. Yük hücresi domateslerin üzerine 1 mm/s'lik bir deformasyon hızı ile yaklaştırılmıştır. Yük hücresi örneğe dokunduktan sonra 4 mm kadar ürünü sıkıştırmaya devam etmiştir. Sıkıştırma kuvveti uygulaması art arda iki kez gerçekleştirilmiştir. Domatese uygulanan her iki sıkıştırma kuvveti de 5 g olarak gerçekleştirilmiştir. Domateslerin sertlik özelliği olarak birinci ve ikinci sıkıştırmalardaki en yüksek kuvvet değerleri ele alınarak YSA-Regresyon analizlerinde ürünlerin sertlik özellikleri için kullanılmıştır.

Kuru madde ölçümü dijital bir refraktometre olan PR-32 α cihazı (Atago, Tokyo, Japan) ile pH ölçümü ise HQ40d model dijital multimetre (HACH; Berlin, Deutschland) cihazı ile gerçekleştirilmiştir. Bu ölçümler (SÇKM ve pH) için ise domatesler rende ile püre haline getirilmiş ve ölçümler püre üzerinden gerçekleştirilmiştir (Tablo 2). Rendelenmiş domatesleri homojen hale getirmek için (pH ölçümlerinden önce) MX-S model (DLAB Scientific, Beijing, China) vortex cihazı kullanılmıştır.

Böylelikle her bir domates için yansıma spektrum değeri ve buna karşılık tahribatlı standart ölçüm sonuçları tek tek elde edilerek, veri seti oluşturulmuştur (Selen, 2021). Bu

tez çalışmasında yapılan bilgisayar analizleri önceki çalışmada elde edilen bu verilerin kullanımıyla gerçekleştirilmiştir. Veriler YSA'da eğitim ve değerlendirme aşamasına girmeden önce veri ön işlemlerine tabii tutulmuştur (Tablo 3).

Elde edilen spektral veriler daha sonra Unscrambler X paket programına (Camo Analytics AS, Aspentech, Ver. 10.5.1) aktarılmıştır. Önceki çalışmada (Selen, 2021) bu veri seti kullanılarak domates örneklerinin içsel özellikleri (Sertlik, SÇKM, pH); PLS (Kısmi en küçük kareler) analiz yöntemi ile tahmin edilmiştir. Bu süreçte (PLS analizleri sonucunda) domates örneklerine ait spektrumların kullanılarak içsel özelliklerin tahmin edilmesi çalışmalarında, etkili dalga boyu aralıkları ve etkili spektrum ön işleme teknikleri belirlenmiştir. YSA-Regresyon modellerinin geliştirildiği bu tez çalışmasında da, önceki çalışmada belirlenen etkili dalga boyu aralıkları ve spektrum ön işleme teknikleri kullanılmıştır (yani önceki çalışmada kullanılan aynı veri seti). Diğer bir deyişle, PLS analizlerinde (önceki çalışmada (Selen, 2021)) en ideal tahmin sonuçlarını veren etkili dalga boyu aralıkları ve spektrum işleme teknikleri bu çalışmada da aynen kullanılmıştır (bu süreçlerden geçen spektrumlar YSA-Regresyon modellerine girdi olarak alınmıştır). Savitzky-Golay algoritması ile filtreleme genel olarak tüm spektrumlara uygulanmıştır. pH ve SÇKM'de ilave olarak çarpımsal dağılım düzeltmesi (MSC: Multiplicative scatter correction) kullanılmıştır. Araştırma bulguları bölümünde verildiği üzere, sertlik, SÇKM ve pH için önceki çalışmada elde edilen tahmin sonuçları (PLS analizi kullanılarak) ile bu çalışmada elde edilen tahmin sonuçları (YSA-Regresyon) karşılaştırılmıştır.

Tablo 3

MPA-FT-NIR spektrometre ile yansıma modunda gerçekleştirilen ölçümlere dayalı olarak yapılan en iyi sertlik, SÇKM ve pH tahmin sonuçlarının alındığı modellere ait spektrum ön işleme yöntem bilgileri

Fiziksel özellik türü	Veri ön işleme yöntemi	Etkin dalga boyu
Sertlik	Filtreleme (Savitzky-Golay)	800-2175 nm
pH ve SÇKM	Filtreleme (Savitzky-Golay) + Çarpımsal dağılım düzeltmesi (MSC: Multiplicative scatter correction)	1333-1836 nm

3.2. YSA-Regresyon Modellerinin Geliştirilmesi

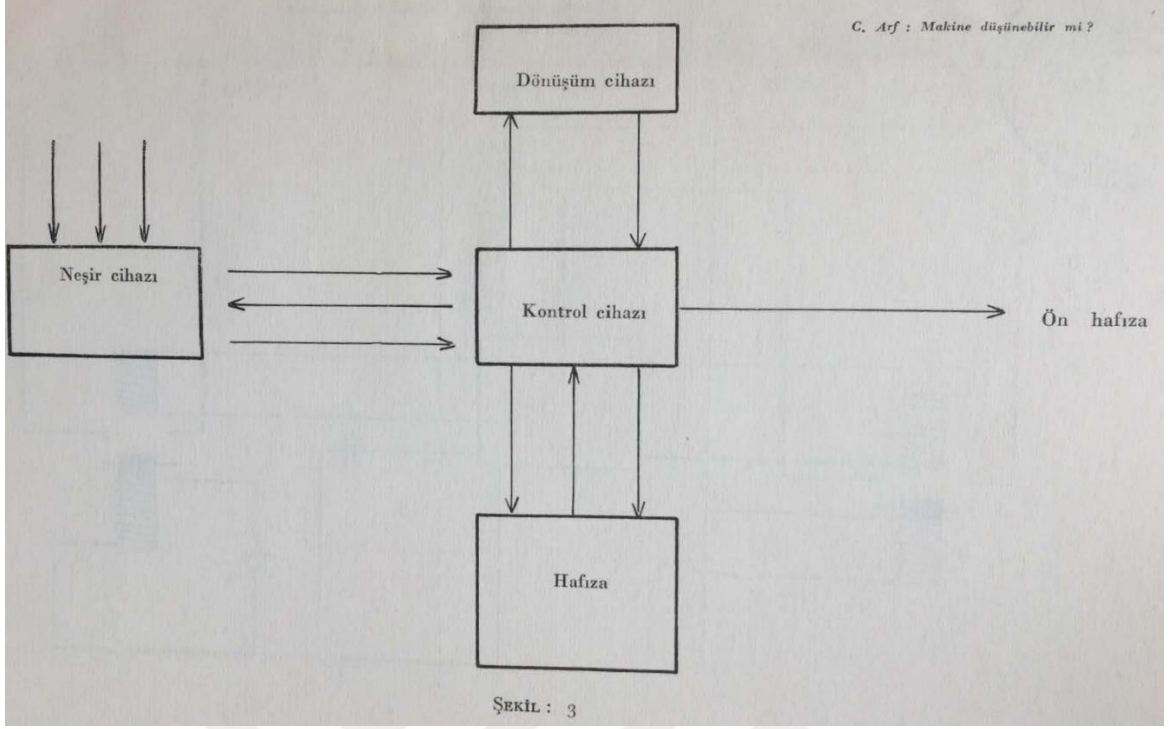
Bu çalışmanın temeli kiraz domatesten yakın kızılötesi spektroskopisiyle (FT-NIR) alınan spektrumları, standart ölçümlere (hasarlı) ait verileri ve yapay sinir ağları regresyon (YSA-Regresyon) modellemesi kullanılarak domates örneklerine ait fiziksel ölçüm sonuçlarının tahmin edilmesine dayanmaktadır.

3.2.1. Yapay Sinir Ağları

Tarih boyunca insanlık, canlı ve cansız tüm varlıklara hükmetmeyi, onları hareket ettirmeyi arzu etmiştir. Yazılı tarihle birlikte başlayan veri madenciliğinin bir sonucu olarak yapay zeka ve dolayısıyla yapay sinir ağları 1950'lerden sonra dijital bilgisayarların icadı ve yaygınlaşmasıyla gelişmiştir. Filozofların insanın düşünce mekaniğini simgesel olarak açıklayagelmiş olsalar da tam anlamıyla “yapay zeka” terimi ilk kez 1956'da ABD'deki bir konferansta ortaya atılmıştır. 70'lerden sonra popüleritesini kaybeden yapay zekaya karşı pek çok yazı yayımlanmış, hükümetlerin ilgisi azalmıştır. 1974-1980 arasına denk gelen bu döneme “AI Winter” yani “Yapay Zeka Kışı” denilmektedir (Öztürk ve Şahin, 2018).

Yapay Sinir Ağları insan beyninin sinirsel yapısını, öğrenme, anlama ve algılama biçimini matematiksel modellerle taklit etmeye çalışan bağlantılı matematiksel ağlar olarak tanımlanabilir. İlk yapay sinir ağları modeli ise tıp doktoru Warren McCulloch ve matematikçi Walter Pitts tarafından 1943'te bir makalede yayımlanmıştır (Öztürk ve Şahin, 2018).

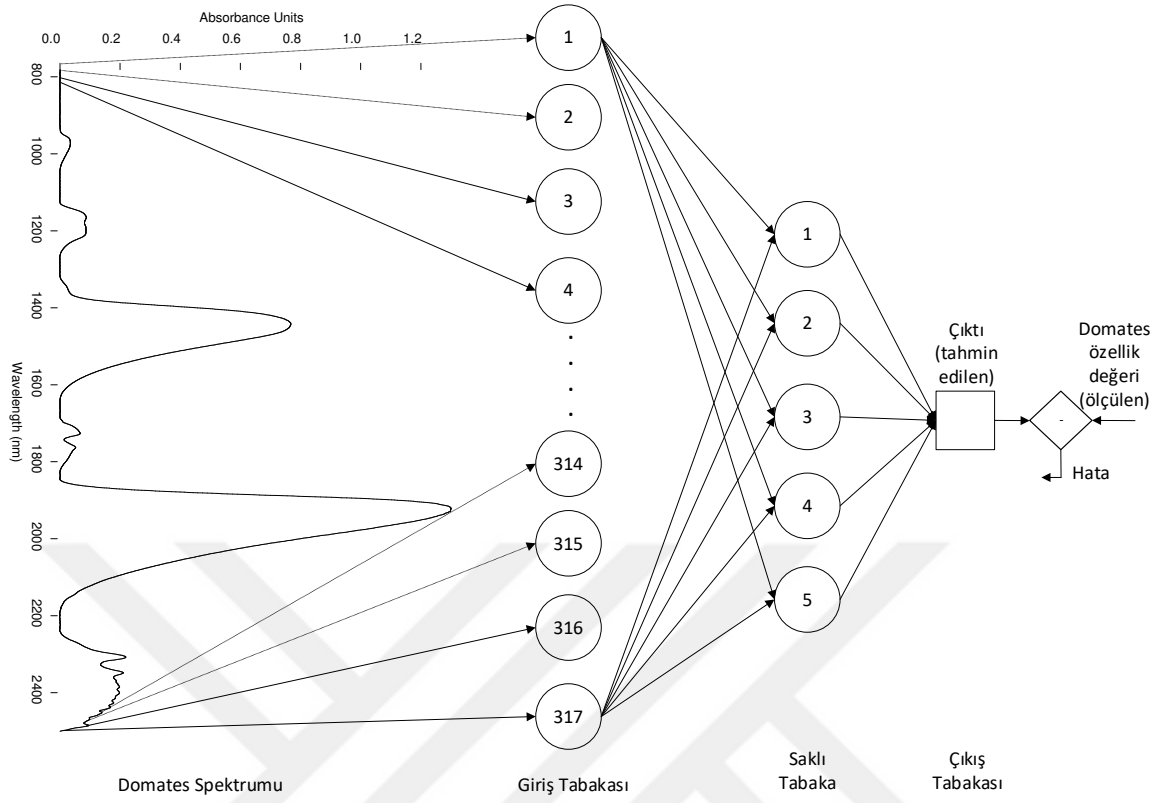
Türk matematikçi Cahit Arf'ın 1958'de Erzurum'da verdiği bir konferansta insan beyninin işleyiş tarzından esinlenerek oluşturulmuş düşünen bir makinenin şematiği Şekil 14'te verildiği şekliyle gösterilmiştir (Arf, 1959).



Şekil 14. Cahit Arf'ın öğrenen bir makinanın insan beyniyle benzerliğini gösteren şeması

Giriş değerleri ile saklı tabaka nöronları ve çıkış tabakası nöronları arasındaki bağlantılar/ilişkiler tam olarak anlaşılmasına rağmen, yapay sinir ağları; giriş özellikleri ile çıkış değerleri arasındaki doğrusal olmayan ilişkileri öğrenmede oldukça üstün kabiliyetlere sahip olan ve çok iyi bilinen yapay sınıflayıcılar ya da regresyon yapılarıdır (Kavdır vd., 2018).

Bu çalışmada geliştirilen ve kullanılan yapay sinir ağları yapısı (mimarisi) genel olarak Şekil 15'te verilmiştir. Bu yapıda yapay sinir ağlarına olan giriş değerleri bir domates örneğine ait NIR spektrumunun içerisindeki spektral değerlere karşılık gelmektedir. Çalışmada sertlik, SÇKM ve pH özelliklerinin ürün üzerinden algılanması amacı ile geliştirilen YSA-Regresyon modellerinde kullanılan giriş değerleri sertlik için 2050 olurken, SÇKM ve pH özellikleri için geliştirilen modellerde 534 olmuştur. Geliştirilen YSA-Regresyon modellerinde yapay sinir ağlarının eğitilmesinde aşağıda detayları verilen Levenberg-Marquardt geri beslemeli algoritması kullanılmıştır.



Şekil 15. Yapay sinir ağları mimarisi

3.2.2. Levenberg Marquardt Yöntemi

Yapay Sinir Ağları (YSA), giriş verileri, saklı tabakadaki nöron mimarisi ve çıkış katmanı nöronları arasındaki ilişki karmaşık ve tam anlaşılabilir olmakla birlikte girdiler ve çıktılar arasındaki non-linear (doğrusal olmayan) ilişkiyi analiz etme yeteneğiyle öne çıkan yapay sınıflayıcılardandır. Eğitim aşaması diğer tüm sınıflayıcı model mimarilerinde de olduğu gibi en önemli aşamadır. Eğitimin en önemli amacı hızlı bir şekilde öğrenme yapılırken mümkün olan en düşük hata oranına ulaşmak olup aşağıdaki şekilde formülize edilebilir. e_n hata değeri, n . giriş değeri için i_n tahmin değeri ile y_n gerçek değeri arasındaki farkı ifade eder (Çavuşlu, 2023).

$$e_n = i_n - y_n \quad (3.1)$$

Levenberg-Marquardt algoritması Steepest descent ve Newton algoritmalarının özelliklerinden faydalanılarak geliştirilmiş bir yöntem olup son zamanlarda yapay sinir

ağlarının eğitilmesinde en çok kullanılan algoritmalarından olan geriye beslemeli yayılım (back propagation) yönteminin yerine kullanımı artmaktadır.

Newton algoritmasının hızını ve Steepest descent metodunun kararlılığını birleştiren Levenberg-Marquardt Algoritması (LMA) ikinci derece türevler gerektirmesinden dolayı daha fazla kaynak gerektirmesine rağmen yapay sinir ağlarının eğitilmesinde hızlı ve etikili sonuçlar verdiği bildirilmiştir.

LMA aşağıdaki şekilde formülize edilmiş olup burada W ağırlık vektörünü gösterirken I birim vektör, μ kombinasyon katsayısı, J Jacobian matrisi ($[(P \times n), N]$ boyutunda), e hata vektörü ($[(P \times n), 1]$ boyutunda) olarak ifade edilmektedir (P eğitime dahil girdi sayısını, n çıktı sayısını ve N ağırlık sayısını göstermektedir).

$$\Delta W(n) = [J_n^T J_n + \mu_n I] J_n^T e_n \quad (3.2)$$

$$W(n+1) = W(n) + \Delta W(n) \quad (3.3)$$

LMA'nın backpropagation (geriye yayılım) algoritmasından farkı parametre güncellemesini tüm giriş değerleriyle oluşturduğu hata vektörü ile Jacobian matrisini kullanarak yapmasıdır. Hata vektörü ve Jacobian matrisi aşağıdaki gibidir.

$$J = \begin{bmatrix} \frac{\partial e_{11}}{\partial w_1} & \frac{\partial e_{11}}{\partial w_2} & \dots & \frac{\partial e_{11}}{\partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{1n}}{\partial w_1} & \frac{\partial e_{1n}}{\partial w_2} & \dots & \frac{\partial e_{1n}}{\partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{p1}}{\partial w_1} & \frac{\partial e_{p1}}{\partial w_2} & \dots & \frac{\partial e_{p1}}{\partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{pn}}{\partial w_1} & \frac{\partial e_{pn}}{\partial w_2} & \dots & \frac{\partial e_{pn}}{\partial w_N} \end{bmatrix} \quad (3.4)$$

$$e = \begin{bmatrix} e_{11} \\ \dots \\ e_{1n} \\ \dots \\ e_{p1} \\ \dots \\ e_{pn} \end{bmatrix} \quad (3.5)$$

Denklem 2'deki μ ayarlanabilir bir değişkeni ifade etmektedir. Aşağıda verildiği üzere eğer bu değişken çok büyükse işlem steepest descent yöntemindeki gibi ilerlemektedir. Bu değişkenin (parametre) çok küçük olması durumundaysa Newton metodundaki gibi değerlendirilmektedir (Çavuşlu, 2023).

$$\mu(t) = \begin{cases} \mu(t)k & E(t) > E(t-1) \\ \mu(t)/k & E(t) \leq E(t-1) \end{cases} \quad (3.6)$$

3.3. Model Mimarisinin Oluşturulması ve Verilerin Analiz Edilmesi

3.3.1. Yapay Sinir Ağları Regresyon (YSA-Regresyon/Artificial Neural Networks Regression) Modellerinin Geliştirilmesi

Önceki çalışmada toplamda 720 domates örneğine ait spektral ölçümler ile yine aynı örneklere ait fiziksel ölçümler (sertlik, SÇKM ve pH) arasında YSA-Regresyon modelleri geliştirilerek domateslerin içsel özelliklerinin tahmin edilmesi üzerine çalışılmıştır. Domates örneklerine ait spektrumlar ölçüm sırasında aşağıda verilen Denklem 3.7'nin sonucu olarak kaydedilmiş ve değerlendirilmiştir.

$$s(\text{spektrum}) = \frac{|\text{domates-karanlık}|}{|\text{standart-karanlık}|} \quad (3.7)$$

Her bir domates örneği için elde edilen bir spektral veri (yansıma modu) ve üç farklı fiziksel ölçüm değeri (sertlik, SÇKM ve pH) YSA-Regresyon modellerinde (her bir fiziksel özellik için ayrı ayrı geliştirilen) kullanılarak örneklerin fiziksel özelliklerinin tahmini üzerine çalışılmıştır (Tablo 4).

Domates örneklerinin sertlik, SÇKM ve pH özelliklerinin tahmini için YSA-Regresyon modellerinin geliştirilmesinde MatLab (R2018b, MathWorks) yazılımı kullanılmıştır. Bunun için iki tabakalı ileri beslemeli bir yapay sinir ağı kullanan Neural Net Fitting modülü kullanılmıştır. Ağ içerisinde, saklı tabakadaki nöronlarda sigmoid fonksiyonu ve doğrusal çıkış nöronları kullanılarak çok boyutlu ölçekleme ile regresyon modelleri oluşturulmuştur. Yapay sinir ağlarının eğitilmesinde yukarıda detayları verilen Levenberg-Marquardt geri beslemeli algoritması kullanılmıştır.

Tablo 4

Her bir fiziksel özelliğin tespiti için YSA tarafından kullanılan verilerin sayıları

Aşama	Standart Özellikler için Veri Sayısı		
	pH	Kuvvet	SÇKM
Validasyon (Test)	209	215	209
Eğitim (All)	453	472	453
Eğitim (Test)	68	71	68
Eğitim (Validasyon)	68	71	68
Eğitim	317	330	317

Yapılan çalışmada spektrumlar ve gerçek-fiziksel ölçüm sonuçlarından oluşan ikili setler matrisler halinde yapay sinir ağlarına (YSA, ANN: Artificial Neural Network) sunularak model çalışmaları gerçekleştirilmiştir; en açık ifadeyle modelin spektrumları kullanarak gerçek (fiziksel) ölçümleri tahmin etmesi için farklı ve uzun süreçler gerektiren eğitim çalışmaları yürütülmüştür.

Domates örneklerinden alınan spektrumlar ile gerçek (fiziksel) ölçüm sonuçlarının ve MatLab (R2018b, MathWorks) yazılımı içerisinde yer alan Neural Net Fitting uygulamasının kullanılması ile yapay sinir ağları-regresyon (YSA-Regresyon) modelleri her bir fiziksel özelliğin tahmini için geliştirilmiştir. MatLab üzerinden alınan regresyona dayalı fiziksel özellik tahmin sonuçlarına ait veriler ayrıca Microsoft Excel üzerinde de tekrar değerlendirilerek ANOVA analizi yapılmış; regresyona ait sonuçlar yeniden ele alınmıştır.

Sertlik tahmininde kullanılan YSA-Regresyon modeli


Bu çalışmada Şekil 15’te verilen çoklu tabakalı bir yapay sinir ağları yapısı kullanılmıştır. Fazla sayıda saklı tabaka kullanmak ağın karmaşıklığını ve eğitim için gerekli zamanı aşırı arttırdığından dolayı bu çalışmada geliştirilen yapay sinir ağı içerisinde bir adet saklı tabaka kullanılmıştır. Ayrıca, birden fazla saklı tabaka kullanmak yapay sinir ağlarında aşırı öğrenmeye (overtraining) sebep olarak ağın genelleme kabiliyetini de zayıflatmaktadır. Diğer taraftan bu çalışmada geliştirilen ve kullanılan YSA-Regresyon modellerinde giriş

tabakasındaki özelliklerin sayısı tek bir domates üzerinden elde edilen spektral okumaların sayısına eşit olacak şekilde alınmıştır. Buna göre, sertlik tahmini için geliştirilen YSA-Regresyon modellerinde kullanılan yapay sinir ağının tabakalarındaki nöron sayıları şöyle olmuştur; giriş tabakasındaki giriş özellikleri bir domates spektrumundaki okumalara karşılık olarak sertlik tahmininde 2050 olarak alınmıştır. Sertlik tahmininde kullanılan yapay sinir ağındaki saklı tabakadaki nöron sayısı 7 olarak alınmıştır. Saklı tabakadaki 7 nöronun seçilerek kullanılması deneme-yanılma yaklaşımı ile gerçekleştirilmiştir (7'den daha az ve daha çok saklı tabaka nöronlarının kullanımı ile denemeler yapılmış, optimum sonuç 7 nöron kullanımı ile elde edilmiştir). Geliştirilen yapay sinir ağı tabakası regresyon için kullanıldığından çıkış tabakasındaki nöron sayısı ise 1 olarak alınmıştır. Saklı tabakadaki nöronlarda sigmoid fonksiyonu kullanılmıştır. Sertlik için kullanılan YSA-Regresyon modelinin tabakalarındaki nöron sayıları özet olarak 2050x7x1 (sırasıyla giriş tabakasındaki nöron sayısı, saklı tabakadaki nöron sayısı ve çıkış tabakasındaki nöron sayısı) olarak gerçekleşmiştir.

Yapay sinir ağlarının eğitilmesinde Levenberg-Marquardt geri beslemeli algoritması kullanılmıştır. Sertlik tahmini için geliştirilen YSA-Regresyon modelinde toplam 687 örnekten 472 adedi modelin eğitimi için kullanılırken, 215 adet örnek ise modelin testinde validasyon amaçlı dış veri olarak kullanılmıştır. Ayrıca 472 eğitim örneği de kendi içinde, 330'u eğitim (%70), %15'ine karşılık 71'er örnek ise eğitim testi ve eğitim validasyonu için rastgele seçilerek kullanılmıştır. Geliştirilen YSA-Regresyon modelinin tahmin başarısını ölçmek için R^2 ve RMSEC (eğitimdeki kararlılık katsayısı ve Root Mean Square Error Calibration, eğitimdeki kök ortalama standart hatası) gibi regresyon istatistikleri kullanılmıştır. Dış veri seti ile yapılan test süreci değerlendirmesi de yine aynı parametrelerin kullanılması ile yapılmış; bu durumda standart hata olarak R^2 ve RMSEP (testteki kararlılık katsayısı ve Root Mean Square Error Prediction, testteki (tahminlemedeki) kök ortalama standart hatası) kullanılmıştır.

Tablo 3'te verildiği üzere sertlik değerleri için SG (Savitzky Golay) filtrelemesi kullanılmış ve yalnızca 800-2175 nm aralığındaki spektrum işleme alınmıştır.

Şekil 16'da sertlik tahmini için en verimli (başarılı) YSA-Regresyon modelinin geliştirilmesi sırasında en başarılı sonucu veren YSA-Regresyon eğitime ait hata kayıt (error log) grafiği verilmiştir.



Şekil 16. Sertlik tahmininin eğitimindeki iyileşmeyi veren hata grafiği


SÇKM tahmininde kullanılan YSA-Regresyon Modeli

Domateslerin SÇKM içeriğini tahmin etmek için geliştirilen YSA-Regresyon modelinin yapısındaki nöron sayıları ise aşağıda verildiği gibi seçilmiştir; giriş tabakasındaki giriş özellikleri bir domates spektrumundaki okumalara karşılık olarak SÇKM tahmininde 534 olarak alınmıştır. SÇKM tahmini için, sertlik tahmini için kullanılan dalga boyu aralığına göre daha dar bir dalga boyu aralığı belirlendiği için YSA-Regresyon modeline daha az sayıda giriş verisi (534) sunulmuştur. SÇKM tahmini için geliştirilen YSA-Regresyon modellerinin eğitimi için kullanılan 453 verinin 317 adedi (%70'i) eğitim ve %15'e karşılık 68'er adedi eğitim testi ve eğitim validasyonu için yine rastgele seçilerek kullanılmıştır. 209 örnek ise eğitim dışı veri olarak validasyonda (test) kullanılmıştır. SÇKM tahmininde kullanılan yapay sinir ağının saklı tabakasındaki nöron sayısı 5 olarak alınmıştır. Saklı tabakadaki 5 nöronun seçilerek kullanılması deneme-yanılma yaklaşımı ile gerçekleştirilmiştir. Geliştirilen yapay sinir ağı tabakası regresyon için kullanıldığından çıkış

tabakasındaki nöron sayısı ise 1 olarak alınmıştır. Saklı tabakadaki nöronlarda sigmoid fonksiyonu kullanılmıştır. SÇKM için kullanılan YSA-Regresyon modelinin tabakalarındaki nöron sayıları özet olarak 534x7x1 (sırasıyla giriş tabakasındaki nöron sayısı, saklı tabakadaki nöron sayısı ve çıkış tabakasındaki nöron sayısı) olarak gerçekleşmiştir.

SÇKM tahmini için geliştirilen YSA-Regresyon modellerinin eğitilmesinde de Levenberg-Marquardt geri beslemeli algoritması kullanılmıştır. Geliştirilen YSA-Regresyon modelinin tahmin başarısını ölçmek için R^2 ve RMSEC (eğitimdeki kararlılık katsayısı ve Root Mean Square Error Calibration, eğitimdeki kök ortalama standart hatası) gibi regresyon istatistikleri kullanılmıştır. Dış veri seti ile yapılan test süreci değerlendirmesi de yine aynı parametrelerin kullanılması ile yapılmış; bu durumda standart hata olarak R^2 (testteki kararlılık katsayısı) ve RMSEP (Root Mean Square Error in Prediction, testteki (tahminlemedeki) kök ortalama standart hatası) kullanılmıştır.

Şekil 17’de SÇKM tahmini için en verimli (başarılı) YSA-Regresyon modelinin geliştirilmesi sırasında en başarılı sonucu veren YSA-Regresyon eğitime ait hata kayıt (error log) grafiği verilmiştir.




Şekil 17. SÇKM tahmininin eğitimindeki iyileşmeyi veren hata grafiği

pH tahmininde kullanılan YSA-Regresyon Modeli

Domateslerin pH içeriğini tahmin etmek için geliştirilen YSA-Regresyon modelinin yapısındaki nöron sayıları ise aşağıda verildiği gibi seçilmiştir; giriş tabakasındaki giriş özellikleri bir domates spektrumundaki okumalara karşılık olarak pH tahmininde 534 olarak alınmıştır. pH tahmini için, sertlik tahmini için kullanılan dalga boyu aralığına göre daha dar bir dalga boyu aralığı belirlendiği için YSA-Regresyon modeline daha az sayıda giriş verisi (534) sunulmuştur. pH tahmini için geliştirilen YSA-Regresyon modellerinin eğitimi için kullanılan 453 verinin 317 adedi (%70'i) eğitim ve %15'e karşılık 68'er adedi eğitim testi ve eğitim validasyonu için yine rastgele seçilerek kullanılmıştır. 209 örnek ise eğitim dışı veri olarak validasyonda (test) kullanılmıştır. pH tahmininde kullanılan yapay sinir ağının saklı tabakasındaki nöron sayısı 10 olarak alınmıştır. Saklı tabakadaki 10 nöronun seçilerek kullanılması deneme-yanılma yaklaşımı ile gerçekleştirilmiştir. Geliştirilen yapay sinir ağı tabakası regresyon için kullanıldığından çıkış tabakasındaki nöron sayısı ise 1 olarak alınmıştır. Saklı tabakadaki nöronlarda sigmoid fonksiyonu kullanılmıştır. pH için kullanılan YSA-Regresyon modelinin tabakalarındaki nöron sayıları özet olarak 534x10x1 (sırasıyla giriş tabakasındaki nöron sayısı, saklı tabakadaki nöron sayısı ve çıkış tabakasındaki nöron sayısı) olarak gerçekleşmiştir.

pH tahmini için geliştirilen YSA-Regresyon modellerinin eğitilmesinde de Levenberg-Marquardt geri beslemeli algoritması kullanılmıştır. Geliştirilen YSA-Regresyon modelinin tahmin başarısını ölçmek için R^2 ve RMSEC (eğitimdeki kararlılık katsayısı ve Root Mean Square Error Calibration, eğitimdeki kök ortalama standart hatası) gibi regresyon istatistikleri kullanılmıştır. Dış veri seti ile yapılan test süreci değerlendirmesi de yine aynı parametrelerin kullanılması ile yapılmış; bu durumda standart hata olarak R^2 (testteki kararlılık katsayısı) ve RMSEP (Root Mean Square Error in Prediction, testteki (tahminlemedeki) kök ortalama standart hatası) kullanılmıştır.

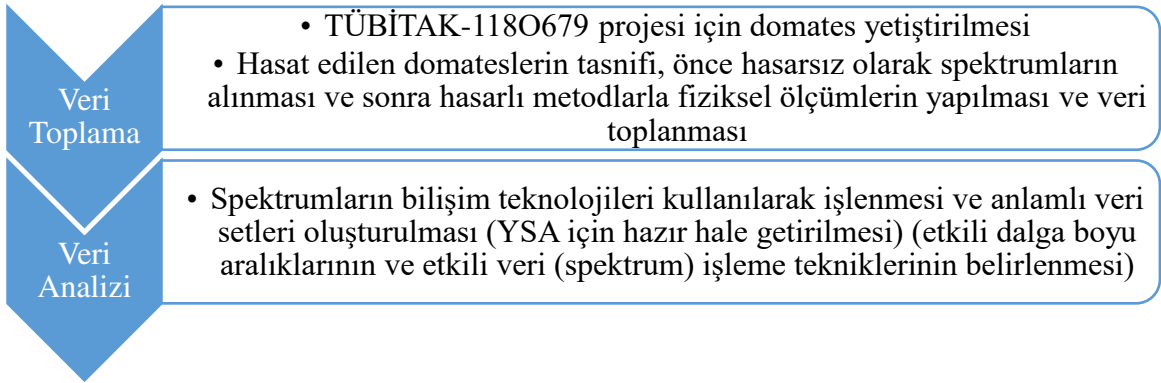
Şekil 18'de pH tahmini için en verimli (başarılı) YSA-Regresyon modelinin geliştirilmesi sırasında en başarılı sonucu veren YSA-Regresyon eğitimine ait hata kayıt (error log) grafiği verilmiştir.



Şekil 18. pH tahmininin eğitimindeki iyileşmeyi veren hata grafiği

3.3.2 Verilerin Analizi ve Kullanılan Paket Programların İşleyişi

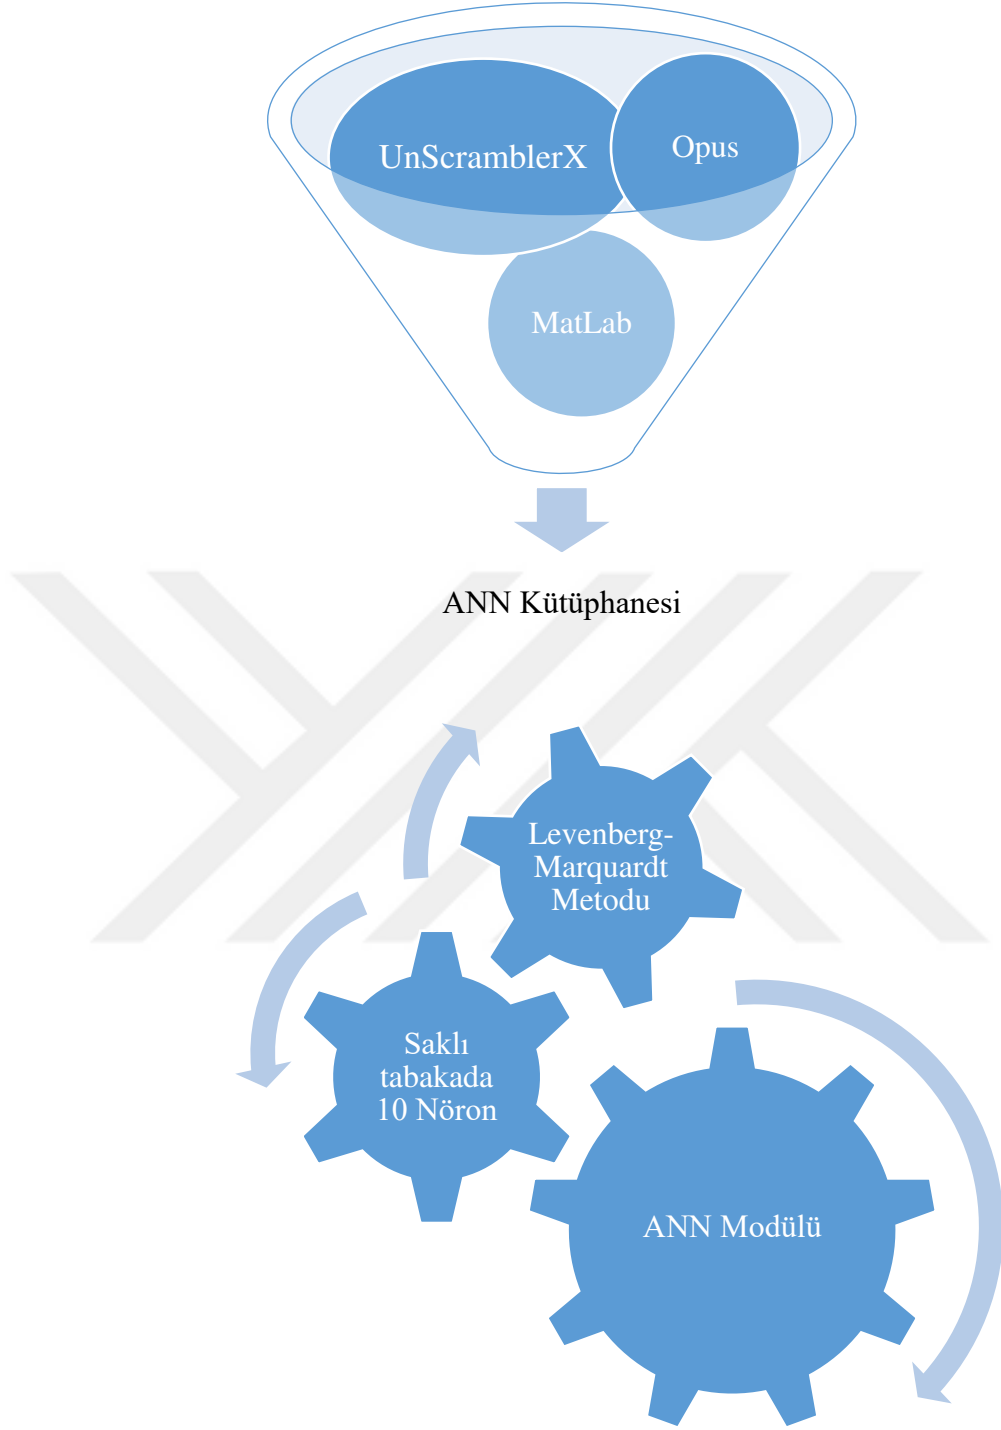
TÜBİTAK-1180679 nolu projeden alınan ve bir önceki bölümde elde edilmiş biçimi açıklanan veriler Şekil 19'daki akış diyagramında verildiği gibi işlenmiş olup anlamlı sonuçlar alınmıştır.



Şekil 19. Verilerin toplanması ve analizinin basamakları

Yapay sinir ağıları modelinin kurulması için kullanılmaya hazır işlenmiş veriler MATLAB (R2018b, MathWorks) paket programının yapay sinir ağıları uygulaması olan Neural Net Fitting modülünün kullanılması ile YSA-Regresyon modelleri geliştirilmiştir. Yapılan işlemlerin oldukça karmaşık ve yüksek işlemci gücü gerektirmesine rağmen yukarıda belirtilen etkinleştirilmiş uygulama ve gerekli ayarlamalar ile modeller makul sürelerde çalıştırılabilmiştir. Bununla birlikte, verimli-etkili tahmin sonuçları veren YSA-Regresyon modelinin (her bir fiziksel özellik tahmini için) belirlenmesi uzun ve çok sayıda farklı modelin deneme-yanılma yolu ile denenerek-geliştirilerek bulunması ile gerçekleştirilmiştir. Verilerin iş akış diyagramı Şekil 20 ve 21’de verilmiş olup ilgili program modülünün ayarlamalarının yapıldığı pencere (diyalog kutusu) da Şekil 22’de gösterilmiştir.





Şekil 20. UnscramblerX ve MatLab yazılımlarının çalışması

Yapay Sinir Ağları-
Regresyon
modellerinin
geliştirilmesi

Gerçek Ölçüm
Sonuçları

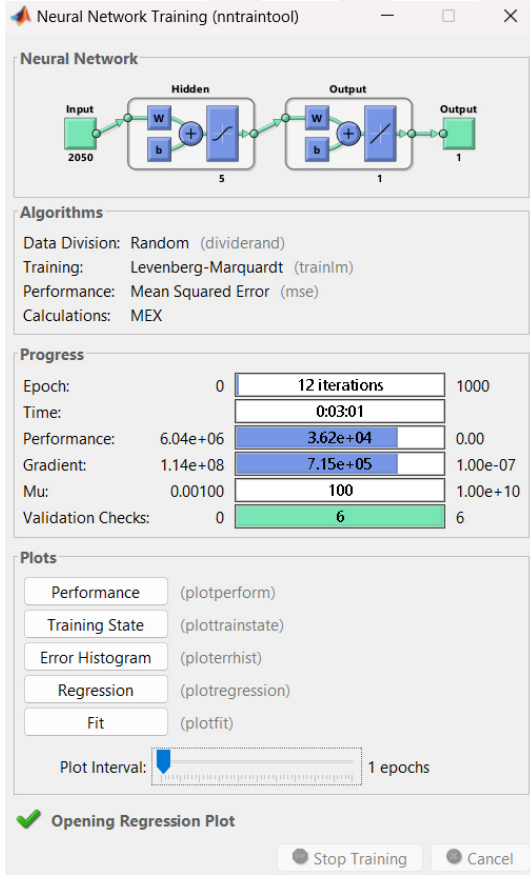
Ön İşlemeye Alınmış
Spektrumlar

Tahminlenen
Sonuçlar

MS Excel

Regresyon Analizi ve
Sonuçların
Değerlendirilmesi

Şekil 21. Modelin geliştirilmesinde izlenen yolu gösteren iş akış şeması



Şekil 22. MatLab Yapay Zeka Eğitim modülü ayarlamaları

DÖRDÜNCÜ BÖLÜM

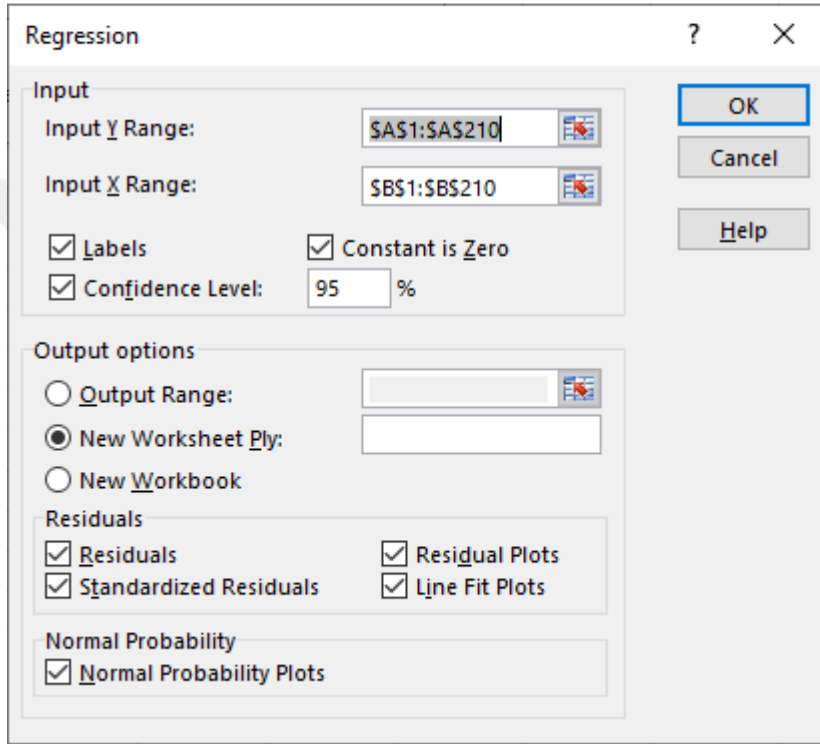
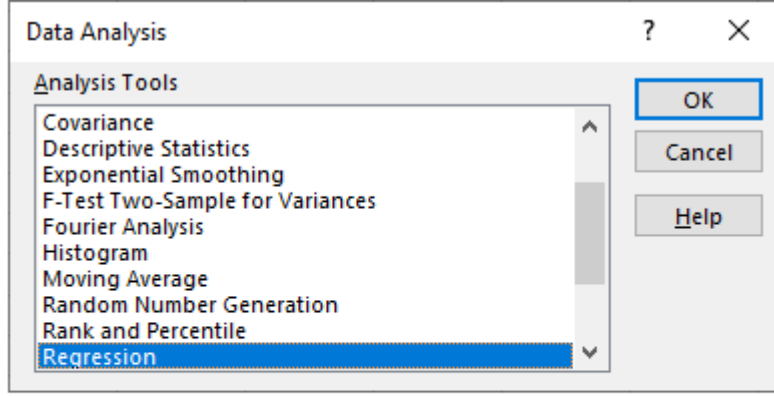
ARAŞTIRMA BULGULARI

Daha önceki bir çalışmada (Selen, 2021) alınan domates örneklerine ait içsel kalite kriterlerinin (sertlik, SÇKM ve pH) tahmin (Selen, 2021) FT-NIR (Fourier Transform Yakın Kızılötesi) spektroskopi ve PLS (Kısmi En küçük Kareler) analiz yöntemlerinin kullanılarak domates örneklerinin sertlik, SÇKM ve pH gibi içsel kalite özelliklerinin tahmini yapılmıştır. Bu çalışma kapsamında da domatesler üzerinden elde edilen aynı veri seti (FT-NIR spektral ve standart fiziksel ölçümler) kullanılarak ancak bu kez, YSA-Regresyon (Yapay Sinir Ağları) yöntemi ile domateslerin içsel kalite özellikleri tahmin edilmeye çalışılmıştır. Sonuç olarak, bu çalışmada elde edilen tahmin sonuçları ile önceki çalışmada (Selen, 2021) elde edilen tahmin sonuçları karşılaştırılmıştır. Aşağıda bu çalışmada alınan sonuçlar ve ilgili çalışma ile olan karşılaştırmaları, elde alınan kalite özelliklerine göre verilmiştir.

4.1. Analiz Sonuçları

MatLab (R2018b, MathWorks) yazılımı içerisinde yer alan Neural Net Fitting uygulaması yardımı ile oluşturulan domates içsel özellik tahmin modelleri YSA-Regresyon yöntemi kullanılarak geliştirilmiştir. Tahmin sonuçları YSA-Regresyon modelinin eğitimi için kullanılan veri seti (4 ayrı şekilde; eğitim (eğitim verilerinin % 70'i), eğitim-validasyon (eğitim verilerinin % 15'i), eğitim-test (eğitim verilerinin % 15'i) ve tüm eğitim verisi (eğitim verilerinin tamamı)) ve eğitimde kullanılmayan test grubu (validasyon/test) seti için verilmiştir.

MatLab ortamında geliştirilen YSA-Regresyon modellerinin sonuçları ayrıca Microsoft Excel kullanılarak da değerlendirilmiştir. Excel eklentilerinden (Add-in) Çözümleme Aracı (Data Analysis) Şekil 23'te gösterildiği gibi ayarlanmış ve tüm *P Tahmin edilen* ve *TT Gerçek ölçülen* değerler her bir kalite kriteri ve eğitim basamağı için ayrı ayrı ANOVA (Analysis Of Variance) regresyon analizi gerçekleştirilmiştir.



Şekil 23. Microsoft Excel Data Analysis eklentisinde verilere uygulanan regresyon analizinin ayarlandığı pencereler

4.1.1 Domateslerin Sertlik Özelliklerinin Tahmin Sonuçları

Domateslerin sertlik özelliklerinin (maksimum kuvvet) YSA-Regresyon modelinin kullanılması ile tahmin edilmesinde, eğitim veri grubu için elde edilen sonuçlar aşağıdaki gibi olmuştur.

Eğitim için (eğitim verilerinin %70'inin kullanıldığı) $R^2=0,83$ (RMSE=206,78), eğitim-validasyon veri grubu için $R^2=0,88$ (RMSE=231,55), eğitim-test veri grubu için $R^2=0,87$ (RMSE=205,61), ve eğitim için ayrılan tüm ölçümlerin kullanıldığı veri grubu için $R^2=0,85$ (RMSE=212,29) olarak bulunmuştur. Bunun yanında, eğitimde kullanılmayan test

(validasyon) grubu için (dış veri seti) elde edilen sertlik tahmin sonucu ise $R^2=0,85$ (RMSE=225,80) olarak elde edilmiştir (Tablo 5).

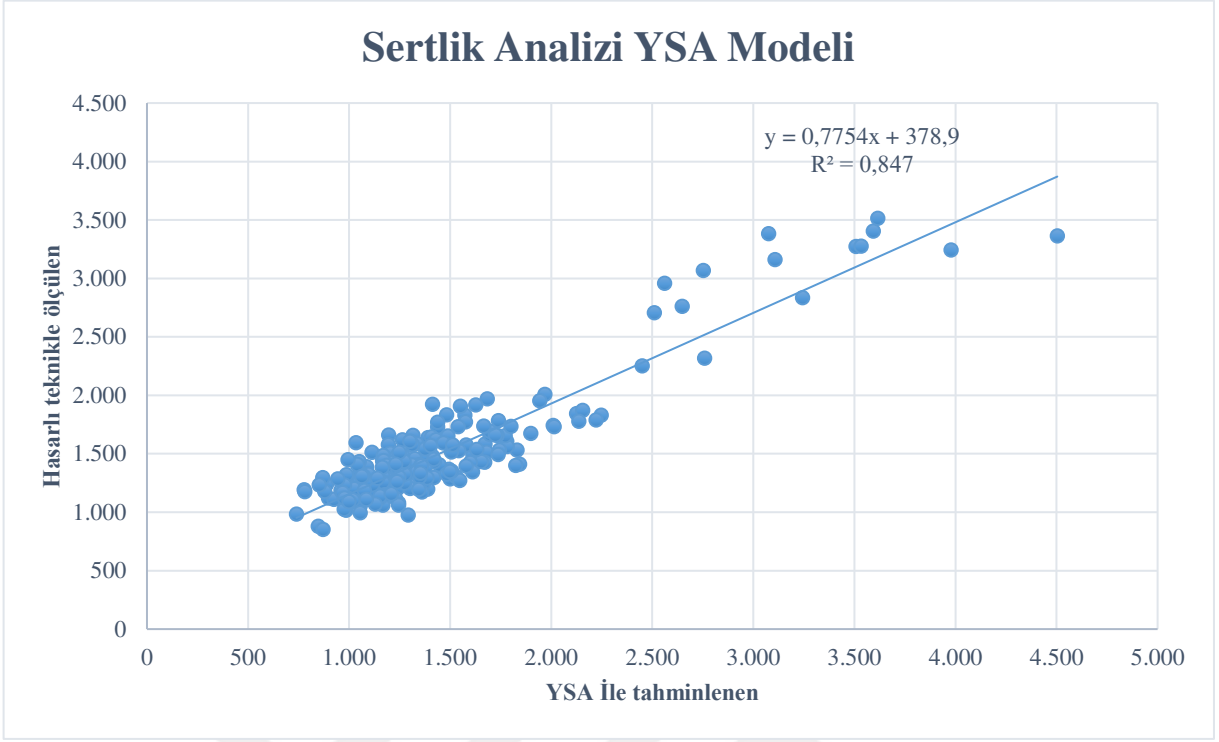
Aynı veri setinin kullanılması ile PLS (Kısmi En küçük Kareler) analiz yöntemini kullanarak yapılan domates sertlik tahmin sonuçları ise; eğitim veri grubu için $R^2=0,76$ (RMSE=259,65), eğitim validasyon veri grubu için $R^2=0,75$ (RMSE=269,22) olarak bulunurken, test veri grubu için $R^2=0,80$ (RMSE=260,16) olarak bulunmuştur. Tablo 6'dan görüleceği üzere, bu çalışmada geliştirilen ve kullanılan YSA-Regresyon modeli ile yapılan sertlik tahmini, PLS analizi ile yapılan sertlik tahmininden önemli derecede daha iyi bir şekilde gerçekleşmiştir (test veri grubu için $R^2=0,85$ (RMSE=225,80)). Bu durum hem eğitim veri grupları hem de test veri grubu için geçerlidir (Tablo 5, Şekil 24 ve 25).

Tablo 5


Sertlik için YSA-Regresyon modeline ve PLS analiz yöntemine (önceki çalışma) göre tahmin sonuçları

	Eğitim Kalibrasyon (%70)								Test Validasyon (%30)	
	Eğitim (%70)		Validasyon (%15)		Test (%15)*		All (%100)*		Test (%100)	
	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE
YSA-Regresyon	0,83	206,78	0,88	231,55	0,87	205,61	0,85	212,29	0,85	225,80
PLS	0,76	259,65	0,75	269,22	-	-	-	-	0,80	260,16

*PLS analizleri için geçerli değildir (bu uygulamada bu veri grupları yer almamıştır).



Şekil 24. Sertlik Analizi YSA Modelinin test sonuçları



Şekil 25. Sertlik Analizi YSA modelinin tüm eğitim sonuçları

4.1.2 Domateslerin SÇKM Özelliklerinin Tahmin Sonuçları

Domateslerin SÇKM özelliklerinin (suda çözülür kuru madde içeriği) YSA-Regresyon modelinin kullanılması ile tahmin edilmesinde, eğitim veri grubu için elde edilen sonuçlar aşağıdaki gibi olmuştur: eğitim için (eğitim verilerinin % 70'inin kullanıldığı) $R^2=0,82$ (RMSE=0,36), eğitim-validasyon veri grubu için $R^2=0,79$ (RMSE=0,39), eğitim-test veri grubu için $R^2=0,74$ (RMSE=0,42), ve eğitim için ayrılan tüm ölçümlerin kullanıldığı veri grubu için $R^2=0,81$ (RMSE=0,37) olarak bulunmuştur. Bunun yanında, eğitimde kullanılmayan test (validasyon) grubu için (dış veri seti) elde edilen SÇKM tahmin sonucu ise $R^2=0,83$ (RMSE=0,38) olarak elde edilmiştir.


Daha önceki çalışmada aynı veri setinin kullanılması ile PLS (Kısmi En küçük Kareler) analiz yöntemini kullanarak yapılan domateslerin SÇKM özelliğinin tahmin sonuçları ise; eğitim veri grubu için $R^2=0,81$ (RMSE=0,405), eğitim validasyon veri grubu için $R^2=0,76$ (RMSE=0,451) olarak bulunurken, test veri grubu için $R^2=0,83$ (RMSE=0,406) olarak bulunmuştur (Tablo 7). Tablo 7'den görüleceği üzere, bu çalışmada geliştirilen ve kullanılan YSA-Regresyon modeli ve önceki çalışmada kullanılan PLS analiz yöntemleri ile gerçekleştirilen SÇKM tahmin başarıları hemen hemen aynı olmuştur. Gerek eğitim veri grubu ve gerekse test veri grubu için tahmin sonuçları benzer olmuştur. Test grubu için elde edilen tahmin sonuçlarından R^2 değeri her iki uygulama için de aynı olurken (0,83), hata oranı (RMSE) YSA-Regresyon modeli için daha düşük bulunmuştur (RMSE=0,38) (Tablo 6, Şekil 26 ve 27).

Tablo 6


SÇKM için YSA-Regresyon modeline ve PLS analiz yöntemine (önceki çalışma) göre tahmin sonuçları

	Eğitim Kalibrasyon (%70)				Test Validasyon (%30)					
	Eğitim (%70)		Validasyon (%15)		Test (%15)*		All (%100)*		Test (%100)	
	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE
YSA-Regresyon	0,82	0,36	0,79	0,39	0,74	0,42	0,81	0,37	0,83	0,38
PLS	0,81	0,405	0,76	0,451	-	-	-	-	0,83	0,406

*PLS analizleri için geçerli değildir (bu uygulamada bu veri grupları yer almamıştır).



Şekil 26. SÇKM Analizi YSA Modelinin test sonuçları



Şekil 27. SÇKM Analizi YSA Modelinin tüm eğitim sonuçları

4.1.3 Domateslerin pH Özelliklerinin Tahmin Sonuçları

Domates örneklerinin pH özelliklerinin YSA-Regresyon modelinin kullanılması ile tahmin edilmesinde, eğitim veri grubu için elde edilen sonuçlar aşağıdaki gibi olmuştur. Eğitim için (eğitim verilerinin % 70'inin kullanıldığı) $R^2=0,71$ (RMSE=0,12), eğitim-validasyon veri grubu için $R^2=0,68$ (RMSE=0,14), eğitim-test veri grubu için $R^2=0,69$ (RMSE=0,13), ve eğitim için ayrılan tüm ölçümlerin kullanıldığı veri grubu için $R^2=0,70$ (RMSE=0,13) olarak bulunmuştur. Bunun yanında, eğitimde kullanılmayan test grubu için (dış veri seti) elde edilen pH tahmin sonucu ise $R^2=0,65$ (RMSE=0,11) olarak elde edilmiştir.


Önceki çalışmada aynı veri setinin ve PLS (Kısmi En küçük Kareler) analiz yönteminin kullanılması ile yapılan domates pH tahmin sonuçları ise; eğitim veri grubu için $R^2=0,58$ (RMSE=0,15), eğitim validasyon veri grubu için $R^2=0,56$ (RMSE=0,15) olarak bulunurken, test veri grubu için $R^2=0,56$ (RMSE=0,15) olarak bulunmuştur (Tablo 8). Tablo 8'den de görüleceği üzere, bu çalışmada geliştirilen ve kullanılan YSA-Regresyon modeli ile yapılan pH tahmini, PLS analizi ile yapılan pH tahmininden önemli derecede daha iyi bir şekilde gerçekleşmiştir ($R^2=0,65$ (RMSE=0,11)). Bu durum hem eğitim veri grupları hem de test veri grubu için geçerlidir (Tablo 7, Şekil 28 ve 29).

Tablo 7

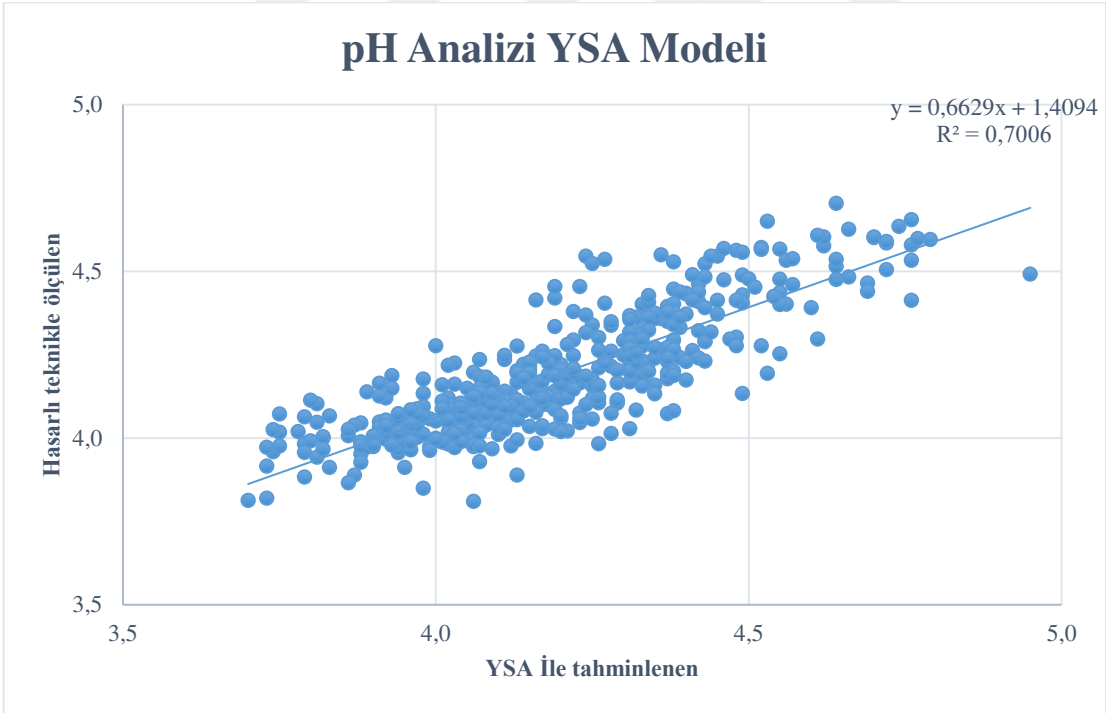
pH için YSA-Regresyon modeline ve PLS analiz yöntemine (önceki çalışma) göre tahmin sonuçları

	Eğitim Kalibrasyon (%70)				Test Validasyon (%30)					
	Eğitim (%70)		Validasyon (%15)		Test (%15)*		All (%100)*		Test (%100)	
	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE
YSA-Regresyon	0,71	0,12	0,68	0,14	0,69	0,13	0,70	0,13	0,65	0,11
PLS	0,58	0,15	0,56	0,15	-	-	-	-	0,56	0,15

*PLS analizleri için geçerli değildir (bu uygulamada bu veri grupları yer almamıştır).



Şekil 28. pH Analizi YSA Modelinin test sonuçları



Şekil 29. pH Analizi YSA Modelinin tüm eğitim sonuçları

4.1.4 Sonuçların Özeti

Sertlik, SÇKM ve pH olmak üzere 3 farklı domates içsel kalite kriterinin YSA-Regresyon modeli yardımı ile tahmin edilmesi üzerine yürütülen bu çalışmada elde edilen regresyon sonuçları (R^2 ve RMSE) Tablolar 5, 6 ve 7 'de (ve kısmen Şekiller 24, 25, 26, 27, 28 ve 29'da) verilmiştir. Sonuçlar eğitim veri grubu (eğitim verilerinin %70'inin kullanıldığı), eğitim-validasyon veri grubu (eğitim verilerinin %15'inin kullanıldığı), eğitim-test veri grubu (eğitim verilerinin %15'inin kullanıldığı) ve tüm eğitim veri grubu (eğitim verilerinin tamamının kullanıldığı) için ayrı ayrı verilmiştir. Bunun yanında, sonuçlar test grubu veri seti (eğitimde kullanılmayan dış veri seti) için de ayrıca verilmiştir. Ele alınan her bir fiziksel özelliğin (sertlik, SÇKM ve pH) tahmininde farklı özelliklere sahip YSA-Regresyon modelleri geliştirilmiştir. Tablolar 5, 6 ve 7'de verilen tahmin sonuçları geliştirilen tahmin modelleri ile elde edilen optimum sonuçları sunmaktadır.

Geliştirilen YSA-Regresyon Modelleri ile domates örneklerinin sertlik, SÇKM ve pH özelliklerinin tahmin edilmesinde elde edilen sonuçlar, daha önce aynı veri seti üzerinde aynı içsel özelliklerin tahmini için geliştirilen ve kullanılan PLS (Kısmi En Küçük Kareler) yöntemi ile elde edilen tahmin sonuçlarına göre özellikle sertlik ve pH tahminlerinde çok daha iyi olmuştur; test veri seti için YSA-Regresyon modelini kullanarak sertlik tahmininde elde edilen regresyon değerleri $R^2=0,85$, $RMSE=225,80$ olurken, aynı veri grubu için önceki çalışmada PLS analiz yöntemini kullanarak sertlik tahmini için elde edilen regresyon değerleri $R^2=0,80$, $RMSE=260,16$ olmuştur. YSA-Regresyon modelini kullanarak pH tahmini için elde edilen regresyon değerleri $R^2=0,65$, $RMSE=0,11$ olurken, PLS analiz yöntemini kullanarak pH tahmini için elde edilen regresyon değerleri $R^2=0,56$, $RMSE=0,148$ olmuştur. Bununla birlikte, domateslerin SÇKM içeriği için her iki çalışmada elde edilen tahmin sonuçları hemen hemen aynı olmuştur (her iki çalışmada da değeri $R^2=0,83$ olurken, RMSE değeri YSA-Regresyon modeli için 0,38, PLS analiz çalışmasında (önceki çalışma) ise 0,406 olarak bulunmuştur).

YSA-Regresyon modelleri ile PLS analizine göre daha iyi tahmin sonuçlarının alınması, yapay sinir ağlarının model geliştirmede giriş özellikleri (spektrum değerleri) ile çıkış değerleri (içsel kalite kriterleri ile ilgili ölçümler) arasındaki doğrusal olmayan ilişkileri algılamada daha iyi bir potansiyele sahip olması ile açıklanabilir. Sertlik, SÇKM ve pH olmak üzere 3 tane içsel kalite kriteri üzerine yapılan çalışmada toplanan verilerle eğitilen Yapay Sinir Ağları Regresyon modelinin Eğitim (Training/Kalibrasyon) ve Doğrulama

(Test/Validation) aşamalarındaki kararlılığı Tablo 8’de verilmiştir. YSA mimarisi oluşturulurken pek çok deneme yapılmış, gerek literatürde gerek deneme sonuçlarında en güvenilir ve standart yöntem olarak tüm verilerin %70’i eğitimde kullanıldıktan sonra kalan %30’u ile model test edilmiştir. Eğitim aşaması da kendi içinde 4 aşamadan oluşmaktadır. Eğitime ayrılan verilerin %70’i ile öğrenme yapılmakta; %15’i ile doğrulama ve kalan %15’i ile sınamaya yapılmakta, sonrasında tüm eğitim verileri bir kez daha Yapay Sinir Ağları’nda işlenerek eğitim tamamlanmaktadır. Her bir aşamanın kararlılık katsayıları ve kendi içindeki tutarlılığı önemlidir.

Tablo 8

Yapay Sinir Ağları Regresyon modelinin eğitim ve test aşamalarındaki kararlılık ve hata katsayıları

	Eğitim Kalibrasyon (%70)								Test Validasyon (%30)	
	Eğitim (%70)		Validasyon (%15)		Test (%15)		All (%100)		Test (%100)	
	R²	RMSE	R²	RMSE	R²	RMSE	R²	RMSE	R²	RMSE
pH	0,71	0,12	0,68	0,14	0,69	0,13	0,70	0,13	0,65	0,11
Kuvvet	0,83	206,78	0,88	231,55	0,87	205,61	0,85	212,29	0,85	225,80
SÇKM	0,82	0,36	0,79	0,39	0,74	0,42	0,81	0,37	0,83	0,38

BEŞİNCİ BÖLÜM

SONUÇ VE ÖNERİLER

Literatürdeki önceki çalışmalarda PLS (kısmi en küçük kareler) gibi konvansiyonal doğrusal matematik yaklaşımlarının tahminleme ve regresyondaki işlevselliği üzerine denemeler yapılırken, bu tez çalışmasında giriş ve çıkış değerleri arasındaki doğrusal olmayan ilişkileri algılamada daha başarılı olduğu öngörülen bir yapay sinir ağı modeli kullanılmış, doğruluk ve hata oranları benzer çalışmalarla kıyaslanmıştır.

NIR spektroskopisi, PCA (Temel Bileşenler Analizi) ve SIMCA (Yumuşak bağımsız sınıf analojisi modellemesi) kullanarak domateslerin olgunluk ve tekstür özelliklerinin algılanmasına yönelik olarak yürütülen bir çalışmada (Sirimsoomboon, Tanaka, Kojima, & Williams, 2012) sertlik, SÇKM ve AIS (taze ağırlıktaki alkolde çözünmez katı madde) parametrelerinin tahmininde aşağıdaki sonuçlar elde edilmiştir.

Sertlik tahmininde elde edilen regresyon değerleri ($R^2=0,95$ ve $SEP=0,35$ (SEP: Standard Error of Performance)), sertlik tahmini için bu çalışmada elde edilen değerlerden daha iyi olmuştur. Bununla birlikte SÇKM tahmini için çalışmada elde edilen regresyon değerleri ($R^2=0,80$ ve $SEP=0,210$) bu çalışmada elde edilen regresyon değerlerinden ($R^2=0,83$ ve $RMSE=0,38$) biraz daha düşük olmuştur.

Önceki bir çalışmada domateste SÇKM içeriğinin hasarsız olarak tahmin edilmesinde Raman spektroskopisi, PCR (temel bileşenler regresyonu) ve PLS analiz yöntemlerini kullanmışlardır (Nikbath vd., 2011). Sonuçta, suda çözünür kuru madde (SÇKM) $R^2=0,79$ ve $RMSEP=0,29$ regresyon değerleri ile bu çalışmada elde edilen R^2 değerinden daha düşük bir değerle tahmin edilebilmiştir.

Yine domateste, toplam kuru madde (TSS), asitlik (pH), titre edilebilir asitlik (TA) ve likopen içeriği gibi kalite kriterlerinin VIS/NIR spektroskopisi, PLS analizi ve OSC (spektrum ortogonal sinyal düzeltme) yöntemlerinin kullanılarak tahmin edilmeye çalışıldığı bir çalışmada (Saad vd., 2014), TSS bu çalışmada elde edilen regresyon değerlerine benzer değerler ile tahmin edilirken ($R^2=0,82$), pH bu çalışmada elde edilen tahmin değerlerinden daha iyi bir değerle tahmin edilmiştir.

Bu çalışma ile benzer amaçları olan bir çalışmada (İğdeci, 2020) domates içsel kalite kriterlerinden olan sertlik, suda çözülür kuru madde (SÇKM) ve pH özelliklerini tahmin

etmek için VIS-NIR spektral ölçümleri ve PLS regresyon analiz yöntemi kullanılmıştır. Sonuçta sertlik $R^2=0,83$ (RMSEP=268,42), SÇKM $R^2=0,592$ (RMSEP=0,657) ve pH ise $R^2=0,75$ (RMSEP=0,11) regresyon değerleri ile tahmin edilmiştir. Bu çalışmada sertlik ve SÇKM kalite kriterleri için elde edilen tahmin değerleri önceki çalışmada elde edilen değerlerden daha iyi regresyon değerleri ile tahmin edilirken, pH özelliğinin tahmini önceki çalışmaya göre daha düşük regresyon değeri ile gerçekleşmiştir.

Yukarıda daha detaylı olarak verilmiş olsa da, bu çalışma ile aynı verileri kullanarak domateste aynı kalite parametrelerini PLS analiz yöntemini kullanarak tahmin etmeyi hedefleyen önceki bir çalışmada (Selen, 2021) elde edilen tahmin sonuçları ile bu çalışmada elde edilen sonuçlar kıyaslanacak olursa; bu çalışmada, sertlik ve pH özelliklerinin tahmin edilmesinde elde edilen regresyon değerleri önceki çalışmada elde edilen regresyon değerlerine göre yüksek (sertlik için $R^2=0,85$ ve RMSEP=225,80; pH için $R^2=0,65$ ve RMSEP=0,11) olurken, SÇKM için elde edilen regresyon tahmin değerleri her iki çalışmada da aynı olmuştur ($R^2=0,83$ ve RMSEP=0,38).

Bu çalışmada geliştirilen YSA-Regresyon modelleri ile kiraz domates örneklerinin içsel özellikleri olan sertlik ve pH için elde edilen tahmin sonuçlarında, özellikle bir önceki çalışmada (Selen, 2021) PLS yöntemi ile elde edilen tahmin sonuçlarına göre önemli derecede iyileşme görülmüştür. SÇKM özelliği için elde edilen tahmin sonuçları ise her iki modelde de benzer olmuştur. Sertlik ve pH fiziksel özelliklerinin tahmini için elde edilen iyi sonuçlar umut verici olmakla birlikte, YSA gibi yapay zeka teknolojilerinin deneme-yanılma ile geliştirilmeye açık olmasından dolayı daha fazla çalışmanın daha iyi sonuçlar verecek modeller geliştirilmesine olanak tanıyacağı da aşikardır. Özellikle, YSA mimarisinde ya da giriş değerleri yapısında denenecek farklılıklar arttıkça daha iyi sonuçlar alma olasılığı da artmaktadır. İleriki çalışmalar bu yönde şekillendirilerek daha iyi tahmin sonuçları için denemelere devam edilebilir.

Bu çalışmada daha önceki çalışmada (Selen, 2021) öne çıkan sonuçların alındığı veri grupları ele alınarak, bu çalışmada geliştirilen YSA-Regresyon modellerinde bu veri grupları kullanılmış ve önceki çalışmada elde edilen sonuçlar ile kıyaslanmıştır. Bunun yanında, geliştirilen ve iyi sonuçlar veren YSA-Regresyon modellerinde bu çalışmada kullanılmamış farklı dalga boyu aralığı ve farklı spektrum ön işleme tekniklerine maruz kalmış spektral veri grupları denenerek daha iyi tahmin sonuçlarına ulaşma çalışmalarına devam edilebilir.

KAYNAKÇA

- Aida Shomali, S. A. (2023). Artificial neural network (ANN)-based algorithms for high light stress phenotyping of tomato genotypes using chlorophyll fluorescence features. *Plant Physiology and Biochemistry*.
- Angileri, M., Woltering, E., & Mishra, P. (2021). Identifying the best rice physical form for non-destructive prediction of protein content utilising near-infrared spectroscopy to support digital phenotyping. *Infrared Physics & Technology*(116).
- Arf, C. (1959). Makine Düşünebilir mi ve Nasıl Düşünebilir ? Atatürk Üniversitesi Üniversite Çalışmalarını Muhite Yayma ve Halk Eğitim Yayınları Konferanslar Serisi 1 (s. 91-108). Erzurum: Atatürk Üniversitesi.
- Arruda de Brito, A., Campos, F., dos Reis Nascimento, A., Damiani, C., Alves da Silva, F., Henrique de Almeida Teixeira, G., & Carlos Cunha Júnior, L. (2022). Non-destructive determination of color, titratable acidity, and dry matter in intact tomatoes using a portable Vis-NIR spectrometer. *Journal of Food Composition and Analysis*.
- Ayter, N. G., Olgun, M., Başçiftçi, Z. B., Kutlu, İ., Akın, A., & Karaduman, Y. (2013). Ekmeklik Buğday (*Triticum aestivum* L.) Çeşitlerinde Protein Oranının Üç Farklı Analiz Yöntemine Göre Karşılaştırılması Üzerine Bir Araştırma. *Süleyman Demirel Üniversitesi Ziraat Fakültesi Dergisi*, 2(8), 80-87.
- Blount, C. (2018). *Near infrared reflectance in Anura*. Manchester: University of Manchester.
- Büyükcan, M. B. (2008). Kayısıda Bazı İçsel Kalite Kriterlerinin Fourier Dönüşümlü Yakın Kızıl Ötesi (FT-NIR) Spektroskopi Kullanarak Belirlenmesi. Çanakkale: Çanakkale Onsekiz Mart Üniversitesi.
- Byrnes, J. (2009). *Unexploded Ordnance Detection and Mitigation*. Springer.
- Carvalho, L. C. (2019). Assessment of macadamia kernel quality defects by means of near infrared spectroscopy (NIRS) and nuclear magnetic resonance (NMR). *Food Control*, 106695.
- Cheng, X., Vella, A., & Stasiewicz, M. J. (2019). Classification of aflatoxin contaminated single corn kernels by ultraviolet to near infrared spectroscopy. *Food Control*(98), 253-261.

- Çavuşlu, M. A. (2023). Geriye Yayılım ve Levenberg Marquardt Algoritmalarının YSA Eğitimlerindeki Başarımlarının Dinamik Sistemler Üzerindeki Başarımı.
- Dariouchy, A., Aassif, E., Lekouch, K., & Bouirden, L. (2009). Prediction of the intern parameters tomato greenhouse in a semi-arid area using a time-series model of artificial neural networks. *Measurement*, 456-463.
- Debroy, P., & Lalu, S. (2022). A Tomato Fruit Biomass Prediction Model for Aquaponics System Using Machine Learning Algorithms. *IFAC-PapersOnLine*, 55(1), 709-714.
- Diane, A., Saffaj, T., & Ihssane, B. (2023). Enhancing tomato leaf nitrogen analysis through portable NIR spectrometers combined with machine learning and chemometrics. *Chemometrics and Intelligent Laboratory Systems*.
- Dowell, F. E., Throne, J. E., & Baker, J. E. (1998). Automated Nondestructive Detection of Internal Insect Infestation of Wheat Kernels by Using Near-Infrared Reflectance Spectroscopy. *Journal of Economic Entomology*.
- Fang, Y., Huang, F. S., Jiang, X., Li, P., Liu, Q., Hu, Q., & Liu, X. (2020). On-line prediction of hazardous fungal contamination in stored maize by integrating Vis/NIR spectroscopy and computer vision. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*(229).
- Flores, C. A. (2016). Development And Validation Of A Near Infrared Specular Reflectance Flow Cell For Online Monitoring Of Microalgal Cultures. Alberta, Kanada: University of Alberta.
- Galvin-King, P., Haughey, S. A., & Elliott, C. T. (2021). Garlic adulteration detection using NIR and FTIR spectroscopy and chemometrics. *Journal of Food Composition and Analysis*(96).
- Gislum, R., Shrestha, S., Knapič, M., Žibrat, U., & Deleuran, L. C. (2016). Single seed near-infrared hyperspectral imaging in determining tomato (*Solanum lycopersicum* L.) seed quality in association with multivariate data analysis. *Sensors and Actuators B: Chemical*(237), 1027-1034.
- Haiyan, C., & Yong, H. (2007). Theory and application of near infrared reflectance spectroscopy in determination of food quality. *Trends in Food Science & Technology*, 2(18), 72-83.

- Haynes, W. N. (2011). CRC Handbook of Chemistry and Physics (92 b.). CRC Press.
- İğdeci, A. (2020). Kiraz Domateste Bazı Kalite Kriterlerinin VIS/NIR Spektroskopi ile Yansıma ve Etkileşim Yöntemlerini Kullanarak Tahmin Edilmesi. Çanakkale: Çanakkale Onsekiz Mart Üniversitesi.
- Johnson, J. B. (2020). An overview of near-infrared spectroscopy (NIRS) for the detection of insect pests in stored grains. *Journal of Stored Products Research*(80).
- Júnior, L. C., Teixeira, G. H., Nardini, V., & Walsh, K. B. (2016). Quality evaluation of intact açai and juçara fruit by means of near infrared spectroscopy. *Postharvest Biology and Technology*(112), 64-74.
- Kamruzzaman, M., Malvandi, A., Kapoor, R., & Feng, H. (2022). Non-destructive measurement and real-time monitoring of apple hardness during ultrasonic contact drying via portable NIR spectroscopy and machine learning. *Infrared Physics & Technology*, 122. doi:<https://doi.org/10.1016/j.infrared.2022.104077>.
- Kartakoullis, A., Comaposada, J., Cruz-Carrión, A., Serra, X., & Gou, P. (2019). Feasibility study of smartphone-based Near Infrared Spectroscopy (NIRS) for salted minced meat composition diagnostics at different temperatures. *Food Chemistry*(278).
- Kavdır, İ. (2020). Kiraz domateste bazı kalite kriterlerinin VIS/NIR ve FT-NIR spektroskopi kullanarak hasarsız olarak tahmin edilmesi. TÜBİTAK. Ankara: TÜBİTAK.
- Kavdır, İ., Büyükcan, M. B., & Kurtulmuş, F. (2018). Classification of olives using FT-NIR spectroscopy, neural networks and statistical classifiers. *Journal of Food Measurement and Characterization*(12), 2493-2502.
- Kavdır, İ., Büyükcan, M. B., Kocabıyık, H., Şeker, M., & Lu, R. (2009). Prediction of olive quality using FT-NIR spectroscopy in reflectance and transmittance modes. *Biosystems Engineering*, 3(103), 304-312.
- Kılıç, H., Tekdal, S., Kendal, E., & Aktaş, H. (2012). Augmented Deneme Desenine Dayalı İleri Kademe Makarnalık Buğday (*Triticum turgidum* ssp durum) Hatlarının Biplot Analiz Yöntemi İle Değerlendirilmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Doğa Bilimleri Dergisi*, 4(15), 18-25.

- Kurtuluş, N. (2016). TAHİL VE TAHİL ÜRÜNLERİNDE KALİTE. Haziran 9, 2021 tarihinde DOCPLAYER: <https://docplayer.biz.tr/1825924-Tahil-ve-tahil-urunlerinde-kalite.html> adresinden alındı
- Manley, M., & Baeten, V. (2018). Chapter 3 - Spectroscopic Technique: Near Infrared (NIR) Spectroscopy. (D.-W. Sun, Dü.) Modern Techniques for Food Authentication, 51-102.
- Massantini, R., Moschetti, R., Haf, R. P., Saranwong, S., Monarca, D., & Cecchini, M. (2014). Nondestructive detection of insect infested chestnuts based on NIR spectroscopy. *Postharvest Biology and Technology*(87), 88-94.
- Mishra, P., & Lohumi, S. (2021). Improved prediction of protein content in wheat kernels with a fusion of scatter correction methods in NIR data modelling. *Biosystems Engineering*(203), 93-97.
- Moomkesh, S., Mireei, S. A., Sadeghi, M., & Nazeri, M. (2017). Early detection of freezing damage in sweet lemons using Vis/SWNIR spectroscopy. *Biosystems Engineering*, 164, 157-170. doi:<https://doi.org/10.1016/j.biosystemseng.2017.10.009>.
- Nakariyakul, S. (2014). Internal damage inspection of almond nuts using optimal near-infrared waveband selection technique. *Journal of Food Engineering*(126), 173-177.
- Nicolai, B. M., Beullens, K., Bobelyn, E., Peirs, A., Saeys, W., Theron, K. I., & Lammertyn, J. (2007). Nondestructive measurement of fruit and vegetable quality by means of NIR spectroscopy: A review. *Postharvest Biology and Technology*, 99-118.
- Nikbath, A., Hashjin, T., Malekfar, R., & Gobadian, B. (2011). Nondestructive determination of tomato fruit quality parameters using raman spectroscopy. *Journal of Agricultural Science Technology*, 13, 517-526.
- Ninja, B., & Manuj, H. K. (2022). Maturity detection of tomatoes using transfer learning. *Measurement: Food*.
- Öztürk, K., & Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zeka'ya Genel Bir Bakış. *Takvim-i Vekayi*, 25-36.

- Ren, G., Liu, Y., Ning, J., & Zhang, Z. (2021). Assessing black tea quality based on visible–near infrared spectra and kernel-based methods. *Journal of Food Composition and Analysis*(98).
- Rong, D., Wang, H., Ying, Y., Zhang, Z., & Zhang, Y. (2020). Peach variety detection using VIS-NIR spectroscopy and deep learning. *Computers and Electronics in Agriculture*.
- Saad, A., Jaiswal, P., & Jha, S. (2014). Non-destructive quality evaluation of intact tomato using VIS-NIR spectroscopy. *International Journal of Advanced Research*, 2, 632-639.
- Selen, H. (2021, Ağustos). Kiraz domateste bazı kalite kriterlerinin FT-NIR spektroskopi kullanarak hasarsız olarak tahmin edilmesi. Çanakkale, Türkiye: Çanakkale Onsekiz Mart Üniversitesi.
- Sena, M. M., Santos, P. M., Simeone, M. L., & Pimentel, M. A. (2019). Non-destructive screening method for detecting the presence of insects in sorghum grains using near infrared spectroscopy and discriminant analysis. *Microchemical Journal*(149).
- Shen, F., He, X., Zhao, T., Liu, Q., Fang, Y., & Hu, Q. (2021). Online detection of naturally DON contaminated wheat grains from China using Vis-NIR spectroscopy and computer vision. *Biosystems Engineering*(201), 1-10.
- Shomali, A., Aliniaiefard, S., Bakhtiarizadeh, M. R., Lotfi, M., Mohammadian, M., Sadi, M. S., & Rastogi, A. (2023). Artificial neural network (ANN)-based algorithms for high light stress phenotyping of tomato genotypes using chlorophyll fluorescence features. *Plant Physiology and Biochemistry*.
- Siesler, H. W., Ozaki, Y., Kawata, S., & Heise, H. M. (2008). *Near-Infrared Spectroscopy: Principles, Instruments, Applications*. John Wiley & Sons.
- Sirimsonboom, P., Tanaka, M., Kojima, T., & Williams, P. (2012). Nondestructive estimation of maturity and textural properties on tomato ‘Monotaro’ tby near infrared spectroscopy. *Journal of Food Engineering*, 112, 218-226.
- Sönmez, A. C., & Olgun, M. (2019). Ekmeklik Buğdayda (*Triticum aestivum* L.) Ekim Sıklığının Tane İriliği ve Bazı Kalite Parametreleri Üzerine Etkisinin İncelenmesi. *Türk Tarım ve Doğa Bilimleri Dergisi*, 4(6), 729-736.

- Şerment, M. (2020). Öğütülmüş Mısır Numunelerinde Kalite Bileşenlerinin NIR (Yakın Kızılötesi Yansıma) Spektroskopisi İle Tespitinde Farklı Kemometrik Tekniklerin Etkisi. Çanakkale: ÇOMÜ.
- Takayanagi, M., Kajino, A., Bai, W., & Yoshimura, N. (2021). Identification of peach and apricot kernels for traditional Chinese medicines using near-infrared spectroscopy. *Vibrational Spectroscopy*(113).
- Tao, S., Miao, X., Miao, Y., Gong, H., Chen, Z., Wang, J., . . . Chen, Y. (2021). NIR spectroscopy coupled with chemometric algorithms for the prediction of cadmium content in rice samples. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*(257).
- TÜİK. (2022). Tahıllar, 1988-2020. Türkiye İstatistik Kurumu.
- Wang, G., Ram, M., & Dowell, F. (2002). Classification of damaged soybean seeds using near-infrared spectroscopy. *Transactions of ASAE*, 45(6), 1943-1948.
- Wang, W., Ni, X., Lawrence, K. C., Yoon, S.-C., Heitschmidt, G. W., & Feldner, P. (2015). Feasibility of detecting Aflatoxin B1 in single maize kernels using hyperspectral imaging. *Journal of Food Engineering*(166), 182-192.
- Wang, W., Yuan, Y., Chu, X., Xi, M., Yoon, S.-C., & Peng, Y. (2014). Detection of Moldy Single Corn Kernel Based on FT-NIR Spectroscopy and SVM. 2014 ASABE and CSBE/SCGAB Annual International Meeting. Montreal, Quebec: ASABE.
- Williams, P., El-Haramein, F. J., Nakkoul, H., & Rihawi, S. (1986). *Crop Quality Evaluation Methods and Guidelines* (1 b.). Aleppo, Syria: ICARDA.
- Wu, T., Fan, Y., & Ma, S. (2020). Individual wheat kernels vigor assessment based on NIR spectroscopy coupled with machine learning methodologies. *Infrared Physics & Technology*(105).
- Yuping, H., & K, C. (2021, 06 24). Prediction of Firmness Parameters of Tomatoes by Portable Visible and Near-Infrared Spectroscopy - Scientific Figure on ResearchGate. *Journal of Food Engineering*. Haziran 24, 2021 tarihinde https://www.researchgate.net/publication/321246027_Prediction_of_Firmness_Parameters_of_Tomatoes_by_Portable_Visible_and_Near-Infrared_Spectroscopy adresinden alındı

- Zhang, S., Ye, X., & Ishioka, S. (2017). Estimation of the degree of red coloration in flesh of a red-fleshed apple cultivar 'Kurenai no Yume' with a UV–vis-NIR interactance device. *Postharvest Biology and Technology*(124).
- Zhaoyong, Z., Yu, L., Dong, S., Haihi, Z., Dongjian, H., & Chenghai, Y. (2016). Detection of moldy core in apples and its symptom types using transmittance spectroscopy. *International Journal of Agricultural Biology Engineering*, 9(6), 148-155.
- Zhu, F., Yao, H., Hruska, Z., Kincaid, R., Brown, R., Bhatnaar, D., & Celeveland, T. (2015). Visible near-infrared (VNIR) reflectance hyperspectral imagery for identifying aflatoxin-contaminated corn kernels. ASABE Annual Meeting. New Orleans; Louisiana: ASABE.