

**UKUROVA NİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

Ahmet ERENLER

**KNN VE YAPAY SİNİR AĞLARI KULLANARAK SİSTEM
ETKİNLİĞİ VE KALİTE KAYBI TAHMİNİ**

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

ADANA-2019

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**KNN VE YAPAY SİNİR AĞLARI KULLANARAK SİSTEM ETKİNLİĞİ
VE KALİTE KAYBI TAHMİNİ**

Ahmet ERENLER

YÜKSEK LİSANS TEZİ

ENDÜSTRİ MÜHENDİSLİĞİ BÖLÜMÜ

Bu Tez .../.../2019 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından
Oybirliği/Oyçokluğu ile Kabul Edilmiştir.

.....
Doç. Dr. Oya Hacire YÜREĞİR
DANIŞMAN

.....
Prof. Dr. Arzu UZUN
ÜYE

.....
Dr. Öğr. Üyesi Metin ÖZŞAHİN
ÜYE

Bu Tez Enstitümüzün Endüstri Mühendisliği Anabilim Dalında hazırlanmıştır.

Kod No:

**Prof. Dr. Mustafa GÖK
Enstitü Müdürü**

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirimlerin, çizelge ve fotoğrafların
kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere
tabidir.

ÖZ

YÜKSEK LİSANS TEZİ

KNN VE YAPAY SİNİR AĞLARI KULLANARAK SİSTEM ETKİNLİĞİ VE KALİTE KAYBI TAHMİNİ

Ahmet ERENLER

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

Danışman : Doç. Dr. Oya H. YÜREĞİR
Yıl: 2019, Sayfa: 83
Juri : Doç. Dr. Oya H. YÜREĞİR
: Prof. Dr. Arzu UZUN
: Dr. Öğr. Üyesi Metin ÖZŞAHİN

Tez çalışmasında, otomasyona dayalı seri üretim yapan sistemlerde oluşan kalite kayıplarının önceki veriler kullanılarak ve analiz edilerek tahmin edilmesi ve çıkan sonuçların çalışanların performans değerlendirme sistemi için girdi sağlaması amaçlanmıştır. Bu çalışma sistemin verimliliği artırılacak ve sistemin devamlılığını güçlü bir şekilde sürdürmesine katkı sağlanacaktır.

Çalışma sırasında geriye dönük 650 günlük veri kullanılmış olup bu veriler; KNN ve Yapay Sinir Ağları algoritmalarının MS Excel programına entegre edilmesi ile kalite kaybı tahminlemesi yapılmıştır. Yapılan tahminlemeler sonucu oluşan sapmalar incelenmiştir. Oluşan sapmalar ile ilgili karşılaştırma tabloları oluşturulmuş ve sonuç olarak en az sapma ile tahminleme yapan yöntemin Yapay Sinir Ağları algoritması olduğuna karar verilmiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, KNN, MS Excel Solver, Kalite Kaybı.

ABSTRACT

MSc THESIS

FORECAST OF THE EFFICIENCY AND LOSS OF QUALITY BY KNN AND ARTIFICIAL NEURAL NETWORKS METHODS

Ahmet ERENLER

**ÇUKUROVA UNIVERSITY
INSTITUTE OF NATURAL AND APPLIED SCIENCES
INDUSTRIAL ENGINEERING DEPARTMENT**

Supervisor : Assoc. Doç. Dr. Oya H. YÜREĞİR
Year: 2019, Pages: 83
Jury : Assoc. Doç. Dr. Oya H. YÜREĞİR
: Assoc. Prof. Dr. Arzu UZUN
: Assoc. Dr. Metin ÖZŞAHİN

In this thesis, It is aimed to analyze the quality losses occurring in automation based mass production systems by using the previous data and to provide input for the employees' performance evaluation system. This study will increase the efficiency of the system and contribute to the continuity of the system.

During the study, retrospective 650-day data were used, this data; KNN and Artificial Neural Networks algorithms are integrated into MS Excel program. Then, quality loss estimation is performed. The deviations of the predictions are examined. As a result, it has been decided that the artificial neural networks algorithm gives better results.

Keywords: Artificial Neural Networks, KNN, MS Excel Solver, Loss of Quality.

GENİŞLETİLMİŞ ÖZET

Üretim ortamında oluşan ürün hatası kaynaklı kalite kontrol verilerini baz alarak sistem etkinliği ve kalite kaybı tahmini yapmak için birçok yöntem kullanılmaktadır. Bu tahminleme ihtiyacı, sistem etkinliği ve kalite kaybı kayıtlarının insanlar tarafından tutulmasından kaynaklanmaktadır. İnsana ve tecrübeye bağlı sistem etkinliği kayıtları, bu kayıtların güvenilirliğinin sorgulanmasını da beraberinde getirmektedir. Yapay sinir ağları (YSA) gibi sayısal karar verme teknikleri bu tahminlerin daha rasyonel olmasını ve daha az sapma içermesini sağlamaktadır. Yapay sinir ağlarının girdiler ile çıktılar arasındaki karmaşık doğrusal olmayan ilişkilendirmeleri ortaya çıkarmadaki başarısı ilgili metodun bu çalışmada kullanılmasına neden olmuştur.

Çalışmanın verileri 650 günde yapılan 1950 vardiyaya ait 1950 adet üretim verileridir. Bunlara ek olarak 200 farklı vardiyadan alınan 200 farklı veri tahmin yöntemlerinin test edilmesi için kaydedilmiştir. Her vardiyada üretim kaybına neden olan hata adetleri, brüt ve net ürün miktarları, üretim kayıplarına neden olan arıza gibi faktörler dikkatle kayıt altına alınmıştır ve verimlilik hesabı tüm bu kayıtlara göre düzenli olarak yapılmıştır. Çalışmanın metodu ise yapay sinir ağları ve KNN metotlarıdır. Çalışmada çözümleme programı olarak MS Excel kullanılmıştır. MS Excel kullanılmasının en önemli nedeni diğer birçok işletmede olduğu gibi çalışmanın yapıldığı işletmede de MS Excel'in yaygın olarak kullanılmasıdır. Ayrıca MS Excel'in Solver eklentisinin olması çalışmanın şirketler tarafından herhangi bir yazılım yatırımına ihtiyaç duyulmadan hayata geçirilmesine olanak sağlaması diğer bir tercih nedeni olmuştur. Bu çalışmanın amacı, yapay sinir ağlarının ve makine öğrenmesi sezgisellerinin sistem etkinliği ve kalite kaybı tahminindeki başarısını sınamaktır. Bu çalışmada kullanılan KNN ve YSA yöntemleri ile kurumlar veya işletmeler mevcut verilerini kullanarak Excel dışında herhangi bir programa ihtiyaç duymadan değişen koşullardaki talepleri, hammadde ihtiyaçlarını ve üretim kapasitelerini sayısal verilere dayanarak tahmin edebileceklerdir.

Tez çalışmasında KNN ve YSA yöntemleri kullanılarak kalite kaybı tahminlemenin nasıl kolayca yapabileceği, KNN ve yapay Sinir Ağları algoritmalarının MS Excel programına entegre edilmesi ile hazırlanan programın görselleri ile anlatılmıştır. 650 günlük veri ile yapılan kalite kaybı tahminlemelerinin her iki yöntemle oluşan sapmaları incelenerek karşılaştırma tabloları oluşturulmuştur ve en az sapma ile tahminleme yapan yöntemin “Yapay Sinir Ağları” algoritması olduğuna karar verilmiştir.



TEŞEKKÜR

Tüm çalışmam süresince yardımlarını ve desteğini hiç esirgemeyen çok değerli danışman hocam Doç. Dr. Oya H. YÜREĞİR'e teşekkürlerimi ve saygılarımı sunarım.

Bu süreçte beni yalnız bırakmayan sevgili eşim Bahar ERENLERE'e, annem ve babam Gülsen ve Mustafa ERENLER'e desteklerinden ötürü teşekkür ederim.



İÇİNDEKİLER

SAYFA

ÖZ	I
ABSTRACT.....	II
GENİŞLETİLMİŞ ÖZET	III
TEŞEKKÜR.....	V
İÇİNDEKİLER	VI
ÇİZELGELER DİZİNİ	VIII
ŞEKİLLER DİZİNİ	X
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR	5
2.1. Kalite Kaybı ve Sistem Etkinliği Tahmini ve Hesaplarında İnsan Hataları ..	5
2.2. İlgili Çalışmalar	7
2.3. Performans Kriterleri, Performans Değerlendirmesi Önceki Çalışmalar	14
3. MATERYAL VE METOT	27
3.1. Materyaller.....	27
3.2. Metotlar	27
3.2.1. Yapay Sinir Ağları Nedir.....	28
3.2.2. KNN-Algoritması Nedir	28
3.2.3. Bu Çalışmada Kullanılan YSA Yapısı	29
3.3. Metodoloji: Tahminleme Operasyonu	30
3.3.1. Yapay Sinir Ağları ile Tahminleme Adımları.....	30
3.3.2. Ortalama Tahmin Hatasının Minimizasyonu ve YSA Eğitimi.....	32
3.3.3. KNN Algoritması ile Sistem Etkinliği Tahmini.....	34
4. BULGULAR.....	37
4.1. Yapay Sinir Ağları Çözümü	39
4.2. Excel Solver Çözümü	44
4.3. Yapay Sinir Ağları ile Tahmin.....	46
4.4. KNN Uygulanması	52

4.5. Yöntemlerin Karşılaştırılması.....	56
4.5.1. Test Veri Seti için YSA Hata Performansı	56
4.5.2. Test Veri Seti için KNN Hata Performansı.....	57
4.6. Bulguların Literatür ile Karşılaştırılması.....	59
5. SONUÇLAR VE ÖNERİLER	63
5.1 Sonuçlar.....	63
5.2 Öneriler.....	64
KAYNAKLAR	67
ÖZGEÇMİŞ	71
EKLER.....	73
Ek 1: Oluşturulan Genel Hücre Yapısı	75
Ek 2: Tüm Verilerin YSA Optimizasyonu Test Veri Seti Analizi.....	76
Ek 3: YSA Optimizasyonu Sonucu Tahmini ve Fiili Kalite Kayıpları.....	77
Ek 3: YSA Optimizasyonu Sonucu Tahmini ve Fiili Kalite Kayıpları.....	77
Ek 4: Kullanılan Excel VBA Kodu.....	78

ÇİZELGELER DİZİNİ

SAYFA

Çizelge 4.1. Kullanılan 3 Sütunluk Hücre Grubu Yapısı.....	40
Çizelge 4.2. Saklı Katman Nöronlarının Hücre Grubu Yapısı.....	41
Çizelge 4.3. Ağırlıklara Değer Verilmesi	42
Çizelge 4.4. Fiili ve Tahmin Edilen Kalite Kaybı Değerlerinin Gösterilmesi	43
Çizelge 4.5. Tahmin Hatalarının Tespit Edilmesi.....	44
Çizelge 4.6. Girdi Örnekleri.....	46
Çizelge 4.7. Girdi Katmanını Gizli Katmana Bağlayan Eğitim Öncesi Rastgele Verilmiş Nöronlar	47
Çizelge 4.8. Girilen Girdiler ve Rasgele Verilmiş Ağırlıklar İçin 3 Gizli Katman Nöronunun Çıktıları	47
Çizelge 4.9. Gizli Katman Nöronlarını Çıktı Nöronlarına Bağlayan Rastgele Verilmiş Ağırlıklar.....	48
Çizelge 4.10. YSA Tahmin Hatasının Gösterilmesi	48
Çizelge 4.11. Eğitim Sonrası Ağırlık Değerleri	49
Çizelge 4.12. Eğitim Sonrası Gizli Katman Nöronları Çıktıları	49
Çizelge 4.13. Eğitim Sonrası Tahminler.....	50
Çizelge 4.14. İndirgenmiş Tahmin Çizelgesi	53
Çizelge 4.15. Ortalama Hata Tahminleme Performansı	55
Çizelge 4.16. Ortalama Sapma Değerleri.....	56
Çizelge 4.17. Tüm Verilerin KNN Tahminlemesi Test Veri Seti Analizi	58
Çizelge 4.18. Veri Seti Analizi Ortalama Sapma Değerleri.....	58
Çizelge 4.19. Bulguların Literatür ile Karşılaştırılması	59



ŞEKİLLER DİZİNİ

SAYFA

Şekil 3.1. Yapay Sinir Ağı Şematik Gösterimi.....	29
Şekil 4.1. YSA modelinin eğitimi için MS Excel Solver kullanımı.....	45
Şekil 4.2. Eğitim Öncesi Filli ve Tahmini Sistem Etkinliği Değerleri.....	50
Şekil 4.3. Eğitim Sonrası Filli ve Tahmini Sistem Etkinliği Değerleri.....	51
Şekil 4.4. KNN algoritması için yazılan kodlar, 1. Safha.....	54





1. GİRİŞ

Üretim sırasında kalite kontrol cihazına gelen malzeme cihaz tarafından analiz edilmekte ve veriler üretim hattına gönderilmektedir. Ana makine, kalite spektleri dışında kalan kısımları imha etmekte ve spektler içindeki malzemeyi ürüne dönüştürmektedir. Malzemeyi ürüne çeviren üretim hattı, personel tarafından yönlendirildiği için ürüne dönüşen malzeme oranı hata sayıları aynı olsa dahi farklılık gösterebilmektedir. Operatörün üretim hattını çok iyi takip etmesi, değişen üretim koşullarına hızlı tepki vererek üretim hattını ve diğer yardımcı personeli doğru yönlendirmesi sayesinde personel verimliliğine doğrudan katkı sağlayabilmektedir. Doğrudan hata sayısına, tonaja ve kalite dağılım göstergesine bağlı olan kayıplar üretimi yönlendiren operatöre göre değişkenlik göstermektedir. Doğrudan hata sayısına, tonaja ve kalite dağılım göstergesine bağlı olan kayıp verilerini analiz edip daha sonra verileri YSA eğitimi tekniği ile işleyip, yine YSA tahminleme tekniği ile de veriler arasında ilişki kurarak mevcut şartlarda oluşabilecek kayıpları tahmin ettirmek amaçlanmıştır. YSA tekniği ile tahmin edilen kayıp değerleri fiili değerler ile karşılaştırılarak operatörün performansı sayısal veriler ile objektif olarak değerlendirilebilecektir. Üretim kayıplarının mevcut koşullara göre anlık olarak analiz edilebilmesi; personelin performansının net bir şekilde sayısal veriler ile ortaya konulabilmesine olanak sağlayacaktır. Bu sistem operatör için denetleme mekanizması olarak çalışacak ve bu şekilde operatör hatasına bağlı kayıplar ciddi oranda azalacaktır. Operatör hatasına bağlı kayıpların azalması, işletmedeki verimliliğin ve kapasitenin artmasını buna bağlı olarak maliyetlerin azalmasını ve sonuç olarak da karlılığın artmasını sağlayacaktır.

Tahminleme yöntemleri temel olarak nicel ve nitel yöntemler olarak ikiye ayrılabilir (Ataseven, 2013). Nicel yöntemler, veriler arasındaki sayısal ilişkiyi ele alırken; nitel yöntemler, öngöründe uzman görüşüne dayalı bir tutum sergiler. Buna göre proseslerin erken süreçlerinde, dönemsel sayısal verileri baz alarak yapılan tahminler nicel olarak sınıflandırılabilir. Yapay sinir ağlarındaki tahmin girdileri ile

tahmin çıktıları arasındaki matematiksel ilişkilendirme bu durumda nicel bir yöntem olmaktadır. Nicel yöntemler bu makalede insan faktörlerini enazlamada kullanılacaktır. Çalışmanın ilerleyen bölümlerinde yapay sinir ağlarının eğitiminde kullanılacak verilerin tutarlılığı sezgisel olarak sınanacak, bu sınanma sonucu tutarsız kabul edilen veriler çalışma dışı tutulacak ve kabul gören veriler ile belirli üretim hatası girdileri ve sistem etkinliği çıktıları ile çalışma için tasarlanan yapay sinir ağı eğitilecektir. Bu eğitim sonucunda, yapay sinir ağının girdiler ile çıktılar arasında kurduğu sayısal ilişkilendirme incelenecektir. Yapılan tahminler farklı performans ölçüleri ile sınanacaktır. Yapılan çalışmanın sonucu tahmin hataları üzerinden değerlendirilecek ve tahmin kesinliğinin sinir ağı yapısındaki nöron sayısına tepkisi sınanarak duyarlılık analizi yapılacaktır. Bu çalışmada girdi olarak kalite dağılım göstergesi, fire yaratacak kalite hatası adedi ve brüt hata miktarı olmak üzere 3 çeşit girdi kullanılacaktır ve tahmin çıktısı sistem etkinliği ve kalite kaybıdır.

Çalışmanın Amacı: Bu çalışmanın amacı otomasyona dayalı seri üretim yapan işletmelerde üretim sırasında oluşacak kalite kayıplarının öğrenen bir sistem ile tahmin edilmesi ve bu kayıplara olan insan etkilerinin düzenli olarak hesaplayabilmesidir. Üretim sırasında insana bağlı olmayan değişken parametrelere göre oluşan kalite kayıpları ve insan faktörü nedenleri ile oluşan kayıpların vardiya sonlarında anlık olarak ayırt edilebilmesi sayesinde otomasyon sistemini takip eden ve yönlendiren insanların yetkinlik veya konsantrasyon eksikliklerinin hızlıca tespit edilebilmesi ve buna bağlı olarak da hızlı önlem alınmasının sağlanmasıdır.

Çalışmanın Yöntemi: Çalışmanın adımları şu şekildedir:

1. Problemin saptanması,
2. Geçmişe dönük verilerin toplanması,
3. KNN ve YSA algoritmalarının incelenmesi,
4. KNN ve YSA algoritmalarının MS Excel programına entegre edilmesi,
5. Toplanan verilerin KNN ve YSA algoritmaları kullanılarak hazırlanan MS Excel programında analiz edilmesi,

6. Verilerin tümünün K-Means algoritması ile sınıflandırılmaları sonrasında en büyük grupta toplanan verilerin, KNN ve YSA algoritmaları kullanılarak hazırlanan MS Excel programında analiz edilmesi,
7. K-Means algoritması ile sınıflandırılmaları sonrasında en büyük grupta toplanan verilerden rastgele seçilen 200 adet verinin belli bir oranda artırılması sonucu elde edilen verilerin, KNN ve YSA algoritmaları kullanılarak hazırlanan MS Excel programında analiz edilmesi,
8. Tüm analiz sonuçlarının karşılaştırılarak en uygun yöntemin belirlenmesi.

Çalışmanın Önemi: Küreselleşen dünyada, ülkeler arasında yapılan ticaret anlaşmalarının da etkisi ile şirketler arasındaki rekabet son yıllarda çok fazla artmıştır. Bu nedenle şirketlerin varlıklarını sürdürebilmeleri için iş yapış şekillerini yeniden değerlendirerek kaliteli ürünleri en ucuza üretebilme kabiliyetlerini geliştirmeleri zorunlu hale gelmiştir. Otomasyona dayalı seri üretim tesislerinde üretim sırasında oluşan kalite kayıplarında insan etkisinin oranı az olsa da kümülatif üretim miktarının çok fazla olması nedeni ile bu oran uzun vadede şirketler için finansal bakımdan çok büyük kayıplara neden olmaktadır. Bu çalışma insan hatası nedeni ile oluşan kayıpları önce ölçülebilir daha sonra yönetilebilir hale getirilecektir. Bu kazanımlar firmalar için uzun vadede rekabet avantajı yaratacak ve şirketin varlığını güçlenerek sürdürmesinde etkili olacaktır.

Çalışmanın Sınırlılıkları: Bu çalışmada kullanılan veriler; çalışmanın yapıldığı işletmenin 2017-2018 yılları içinde tuttuğu 650 günlük raporlarından elde edilmiştir.

Varsayımlar: Değerlendirmeye alınan tüm verilerdeki kalite kayıplarının veri girişi sırasında oluşan insan hatalarından arındırılmış olduğu varsayılmıştır.

Çalışmanın Planı: Çalışmanın bölümleri şu şekildedir:

1. Bölümde çalışma ile ilgili “Önceki Çalışmalar” ele alınırken bu bölümde literatür taranarak dünyada, ülkemizde YSA ve KNN metotları kullanılarak daha önce sistem etkinliği üzerine yapılmış çalışmalardan bahsedilmiştir.
2. Bölümde “Materyal ve Metot“ bölümünde verilerin nasıl elde edildiği ve tahminleme için hangi yöntemlerin kullanıldığı anlatılmış, kullanılan tahminleme yöntemleri ve algoritmalarından bahsedilmiştir.
3. Bölümde KNN ve YSA algoritmalarının MS Excel programına nasıl entegre edildiğinden ve her iki yöntemin verileri işleyerek kalite kaybı tahminlemesini ne kadar sapma ile yapabildiğinden bahsedilmiştir.
4. Bölümde KNN ve YSA algoritmalarının tahminleme performansları karşılaştırılmış ve en başarılı tahmin yöntemi belirlenmiştir. Tahmin performansları ve bu yöntemler literatürdeki sonuçlar ile karşılaştırılmıştır.

2. ÖNCEKİ ÇALIŞMALAR

2.1. Kalite Kaybı ve Sistem Etkinliği Tahmini ve Hesaplarında İnsan Hataları

Kalite kaybı, üretilen ürün miktarından belirlenen kalite koşullarına uymayan ürünlerin üretim sırasında fireye ayrılması ile oluşmakta ve dolayısıyla üretim ortamında üretilmesi gereken kaliteli final ürün miktarını azaltmaktadır. Üretim sırasında oluşan fire miktarı nedeni ile üretim maliyetleri artmakta bu şekilde şirketler rekabet avantajlarını kaybetmektedir. Süreç sırasında süreci kontrol eden ve yöneten insanların hatalarının artması kalite kayıplarının da doğru orantılı olarak artmasına neden olmaktadır. Stanton ve Baber (2005), üretim ve servis ortamlarında insan hatalarını miktarsal olarak tahmin etmek için yaygın olarak kullanılan tahmin yöntemlerinin doğrulama ve geçerlemesini incelemiştir (Stanton ve Baber, 2005). Stanton ve Baber (2005), insan kaynaklı hataların tespiti için belirli yöntemler sunmuştur, bu yöntemler görev analizi yöntemleridir. Görev analizi metotlarının çıktıları olan hata durumlarından başka durumlara geçişleri geçiş matrisleri ile göstermiştir. Yapılan işin üzerinde insan tecrübesi ile yapılan hata miktarı arasında güçlü bir ilişki olduğunu öne sürmüştür. Buna ek olarak tekrarlı yapılan işlemlerde tecrübeden bağımsız olarak ergonomi kaynaklı hataların da bulunduğunu belirtmiştir.

Stanton ve Baber (2005), araştırmalarında hataların belirlenmesi için görev analizi (TAFEI: Task Analysis for Error Identification) ve insan hatası analizi (HEI: Human Error Identification) metotlarını kullanmış ve bu görev analizlerinin insan hatasını belirleyebilmedeki performanslarını çeşitli senaryolar altında ölçmüşlerdir. Stanton ve Baber (2005), yaptıkları araştırmanın sonuçlarına göre HEI daha çok insan aktivitelerini sorgulama konusuna odaklanırken, TAFEI insan aktiviteleri ve sistem ara yüzü konularını sorgulamada daha başarılı olmuştur. Fakat HEI içerisinde insan ve malzemenin bulunduğu gerçel bir deney ortamı gerektirmemektedir.

Yanar (2008), çalışmasında üretilmesi planlanan parçaların alt ve üst kalite limitlerinin optimize edilmesinde Taguchi Dizaynı metodunu incelemiştir. Anahtar

performans indeksini parça kesme parametrelerinin optimizasyonu olarak belirlemiştir. Çalışmada da üretim hattı parametrelerinin hatalara etkisi incelenmiş fakat taguchi dizaynı yerine tahminleme ile önlem alınmaya çalışılmıştır. Kesimde oluşan istatistiki sapmaların kalite kaybına etkisini araştırmıştır. Araştırmaya göre artan sapmalar optimizasyon metotlarından ziyade dizayn metotlarının sağladığı önleyici özelliklerin kalite kaybı üzerinde pozitif etkilerinin olduğu belirlenmiştir (Yanar, 2008). Wenwen ve ark. (2011), tarafından yapılan çalışmalarda insan hatalarının kontrolünü ve analizini incelemiştir. Yapılan literatür taramasının sonucunda, tarım alanında kalite kaybının toplam maliyete etkisinin incelenmiş olduğu görülmüştür. Başka bir araştırmada demir yolları operasyonlarındaki jenerik görevlerde insan hatalarına değinilmiş ve bu insan hatalarının oluşmalarına rassal değerler atanarak, olasılıksal bir çalışma yapılmıştır (Thommesen ve ark, 2012). Hodges (2012), araştırmasında kalite kaybı performans ölçüsünün değerlendirilmesinin tonaj kaybı performans ölçüsünün değerlendirilmesine göre gelir açısından daha önemli olduğu sonucunda varmıştır. Tonaj kaybı hesabının, kalite kaybı hesabından daha kolay olmasının tonaj kaybı hesabına daha fazla odaklanılmasına sebep olduğunu öne sürmüştür. Bunun nedeninin ise tonaj kaybına kolayca finansal değerler biçilebilirken kalite kaybına finansal değerler yansıtmanın daha karmaşık olduğundan bahsetmiştir. Bu bulguları göz önüne alarak bilgi işlerini insan hatasından kurtarabilecek ya da hataları öngörülebilir sistemler işletmeler için önemli olabilmektedir. Şen ve Yağcı (2016), çalışmalarında tüplü asma fidanı yetiştirilmesinde kök lokasyonlarının yetiştirilen ürünlerin randımanı ve kalitesi üzerine etkilerini araştırmıştır. Bu çalışma farklı tekniklerin ürün kalitesine ve üretim verimine olan etkisi incelenmiştir. Bu çalışmadaki üretim veriminin ölçüsü sistem etkinliği olarak verilmiştir. Çalışma randımanın finansal boyutunu çıkan net ürün miktarı ve bu miktarın yüzde cinsinden kalitesi ile ilişkilendirilmiştir (Şen ve Yağcı, 2016).

2.2. İlgili Çalışmalar

Teknoloji ilerledikçe üretim ve servis ortamındaki belirsizlikleri gidermeye ya da belirsizlikleri tahmin edilebilir belirsizliklere dönüştürmeye yönelik çalışmalar da teknoloji ve bilgi gelişimine paralel olarak ilerlemiştir. Bu çalışma yapılırken daha önce üretim ve servis ortamlarında YSA'nın kullanımına yönelik bazı çalışmalar araştırmalarımıza ışık tutmuştur. Myers ve Hutchinson (1989) araştırmalarında parçalı doğrusal aktivasyon fonksiyonlarının YSA'nın tahmini için kullanımlarını incelemişlerdir. Doğrusal olmayan programlamanın bir dezavantajı da içbükey olmayan setlerde eniyilemenin zor olmasıdır. Myers ve Hutchinson (1989), ve diğerleri bu çalışmada doğrusal olmayan aktivasyon (lojistik) fonksiyonlarının yerine yaklaşımlarla parçalı fonksiyonlar haline getirilmiş aktivasyon fonksiyonları kullanmanın avantajlarını değerlendirmişlerdir. Aktivasyon fonksiyonu bir nöronun girdisini alıp bir fonksiyon eşliğinde çıktıya dönüştüren ve takip eden katmandaki nöronlara girdi olarak gönderen (literatürdeki deyimi ile ateşleyen) yapıya denir. Kısacası biyolojik beyindeki nöronların biyolojik işlevlerini taklit eden fonksiyonlardır (Myers ve Hutchinson, 1989). Doğrusal olmayan eğrileri parçalı fonksiyonlar haline getirme yaklaşımı, sürekli bir eğri üzerinde kırma noktaları belirlenerek gerçekleştirilmiştir. Bu kırma noktaları eğrinin içbükey konumlarında doğrudan tanımlanırken dışbükey kısımlarında ikili değişkenlerle desteklenmiştir. Bu çalışmada doğrusal olmayan aktivasyon fonksiyonu olarak sigmoid aktivasyon (lojistik, transfer) fonksiyonu kullanılmıştır. Bahsedilen sigmoid fonksiyonunun formülasyonu $1/(1 + e^{-x})$ şeklindedir. Bu denklemdaki "x" terimi nöronun (aktivasyon fonksiyonunun) girdisidir. Yani önceki katmandaki nöronların çıktılarının ağırlıklı toplamıdır. $1/(1 + e^{-x})$ denklemi ise nöronun (aktivasyon fonksiyonunun) çıktısıdır. X girdisi eksi sonsuz ile artı sonsuz arasında sürekli değerler alabilir. Eksi sonsuza yaklaşırken 0'a yaklaşan değerler döndürürken, x sıfır değerini aldığı anda 0,5 değerini döndürmekte ve artı sonsuza yaklaşırken ise sigmoid fonksiyonu 1'e yaklaşan değerler döndürmektedir. Myers ve Hutchinson (1989), bu sürekliliği x değerini +8 ile -8 değeri arasına indirgeyerek, -

8 girdisi için fonksiyonun 0 döndürdüğünü ve +8 için fonksiyonun 1 döndürdüğünü varsaymışlardır. Sigmoid eğrisini +8 ile -8 arasında 8 farklı değerle parçalı fonksiyonlar haline getirmişlerdir. Bu kırma değerli 2'nin kuvvetleri ile tanımlanmıştır. Bu çalışma YSA'nın üzerindeki doğrusal olmayan programlama yükünü hafifletmiştir ve içbükey doğrusal eniyileme programlama haline getirmiştir ve YSA eğitimi sonunda çıktıların kesinliğinden ödün verilmediği çıkarımına varılmıştır (Myers ve Hutchinson, 1989). Çalışmada doğrusal aktivasyon fonksiyonları kullanılmıştır. Bu fonksiyonlar birçok katmanda kullanıldığı için YSA yapısı doğrusal olmayan bir yapıya sahiptir.

Hecht-Nielsen (1992), çalışmasında YSA'nın eğitimi (geri yayılımı) üzerinde durmuştur ve geri yayılım teorisini incelemiştir. Başlamadan önce belirtmek gerekir ki MS Excel Solver kullanmanın ve öngörülen paternlerin düşük karmaşıklığının bir avantajı olarak geri yayılım algoritmaları çalışmada kullanılmamıştır. Bu çalışmada YSA hiyerarşik bir yapıda anlatılmıştır. Çalışmada ise tanıtılacak olan matematiksel model ile oluşturulan YSA tümleşik olarak incelenmiştir. Bu hiyerarşi katmanlardan ve satılarla tanımlanan verilerden oluşmuştur. YSA yapısı bu çalışmada ileri beslemeli aşamalardan ve geri beslemeli düzeltmelerden oluşmaktadır. Bu yapı uzay vektörleri ile matematiksel olarak ifade edilmiştir. İleri besleme aşamasında bu vektörlerin çıktıların türevlenebilir olarak açıklanmış ve türevin, hata fonksiyonu üzerinde bir eğimi açıkladığı belirtilmiştir. Bu eğim iyileştirmeye neden olacak ilerleme yönünün tersinde işaret aldığı anlatılmıştır. Eğimin -1 ile çarpılması iyileştirmenin yapılacağı ilerleme yönünü vereceği ve çıktıyı oluşturan vektörlerin bu yönde artırılmasının bir geri yayılım adımını gerçekleştirdiğine kanıt sunmuşlardır. Bu adımın defalarca tekrarlanması durumun çıktıların gerçek verilere yaklaştırmaya başlayacağını belirtmişlerdir ve bunun öğrenme tanımına uyduğundan bahsetmişlerdir. Bu köklü çalışmada anlatılan geri yayılım teorisi çalışmada daha önce de anlatıldığı gibi kullanılmamıştır. Onun yerine bir doğrusal olmayan model çözme aracı olan "GRG-Nonlinear Solver" kullanılmıştır.

Huang ve Babri (1998), ileri beslemeli tek gizli katmana sahip YSA'ların gizli katmanındaki nöron sayısını kararlaştırmak üzerine çalışmışlardır. Bahsedilen yapay sinir ağı yapısı bu çalışmada kullanılan yapıyla aynı yapıdır. Bu çalışmada Huang ve Babri (1998), N adet nöron kullanımının en fazla N adet paterni öğrenebileceğine kanıt sunmuşlardır. Nöronların aktivasyon fonksiyonlarının da düşünülmesi gerektiğini belirtmişlerdir. Aktivasyon fonksiyonları için doğrusal olmayan fonksiyonları seçmişlerdir. Bu çalışmada 3 adet literatürde geçen aktivasyonu fonksiyonu ve 6 adet düzenli olmayan yazarların geliştirdiği fonksiyonlar kullanmışlardır. Nöronların eğitimi için herhangi bir optimizasyon aracı değil, literatürde kabul görmüş geri besleme tekniklerini kullanmışlardır. Çalışmanın sonucu olarak N adet rasgele seçilmiş paterni eğitim için kullanmışlardır. Bu eğitim veri seti N adet rasgele patern ile tanımlanıyor demektir. Böyle bir veri setinin her bir spesifik paternini tanımak için N adet nöronun aynı doğrusal olmayan aktivasyon fonksiyonu tanımlamak gerektiğini kanıtlamışlardır. N adet spesifik paterne üst sınır koyan bu çalışma YSA'nın eğitim safhasındaki CPU sorununa da bir ışık tutmuştur çünkü CPU'ya (ya da GPU'ya) yüklenen hesap yükünü sınırlayıcı bir etkisi olmuştur. Fakat bu metodun olursuz olması nöron sayısı seçimi konusuna kesin bir nokta koymamıştır. Yayında da belirtildiği gibi paternlerin yapısının önceden bilinmemesi sorunsalı ortaya çıkmıştır ve genel vakalarda patern sayısı bilinmedikçe nöron sayısı seçiminin olursuz bir problem olduğu ve fizibilitesinin sorgulanması gerektiğine değinilmiştir. Çalışmada 3 adet gizli katman nöronu seçilmiştir. Bu seçim rastgele yapılmıştır. Seçimin arkasında bir dayanak olmamasının sebebi ile Huang ve Babri'nin (1998), çalışmalarını olursuz olarak değerlendirmelerinin sebebi aynıdır; spesifik paternlerin bilinmemesidir. Her ne kadar spesifik paternler bilinmese de öngörülen paternlerin sayısı 3 adet olmuştur. Bu paternlerin sistem etkinliği değerleri incelendiğinde, sistem etkinliği değerleri %70 ile %80 aralığına düşenler kötü paternler, sistem etkinliği %81 ile %92 aralığına düşenler ortalama üstü paternler ve sistem etkinliği %92 üstü olanlar ise iyi paternlerdir. Fakat bunların sadece öngörü olması tam fizibilite sağlayamayacağı

için bu çalışmada 3 adet gizli katman nöronu seçilmesine bir neden bağlamamaktadır ve bilimsel tutarsızlıktan kaçınmak için 3 adet nöron seçimine rasgele demek en doğrusudur.

Jiang ve Zhou (2004), YSA ve KNN girdilerindeki gürültüleri temizlemek için bir çalışma yapmışlardır. Bu çalışmada gürültü gerçekçi olmayan ya da veri setinin genel paternine uymayan veriler olarak tanımlanmıştır. Bu gürültü oluşturan verilerin YSA'nın ve KNN'nin tahminleme veya sınıflandırma performansına kötü etkisi olabileceğinden bahsetmiştir. Li ve Guo (2007), gibi Jiang ve Zhou (2004), da problem kompleksliğinden bağımsız olarak KNN'nin uygulanmasının kolaylığı açısından çok verimli bir yöntem olarak görmüştür. Bu çalışmada tahminin gürültüden kötü etkilenmemesi için girdilerin düzenlenmesinden bahsedilmiştir. Bu çalışmada yaygınca kullanılan depürasyon (temizleme) ve yeniden etiketleme teknikleri ile Jiang ve Zhou (2004), tarafından geliştirilen teknik karşılaştırılmıştır. Geliştirilen gürültü temizleme tekniği ile depürasyon ve yeniden etiketleme tekniği karşılaştırıldığında depürasyonun bazı kümelerde yeniden etiketlemeyi baskıladığı ve yeni geliştirilen tekniğin de ikisini de baskıladığı gözlemlenmiştir. Çalışmada gürültüler temizlenirken konunun uzmanları olan Kalite Güvence Şefliği ve Üretim Şefliği gözetiminde veriler incelenmiş ve gürültüye neden olacak tutarsız veriler temizlenmiştir. Bu çalışmada gürültü, sistem etkinliği ile tutarlı olmayan girdi verileri olarak belirlenmiştir. Bu gürültüler, çalışanların performansları değerlendirilirken kilit rol oynayacaktır. Performans değerlendirmede gürültüye neden olan veri girdilerine sebep olan personelin çalışması incelenecek ve puanlandırma sistemi de bu incelemeden etkilenecektir.

Li ve Guo (2007), araştırmalarında IT sistemlerinde saldırı ve spam algılamada KNN yönteminin kullanımını denetlemişlerdir. Bu çalışmada KNN'in anomalileri ortaya çıkarmadaki başarısının saldırı algılama konusunda başarılı olabileceği tezi ileri sürülmüştür. Ağ güvenliği için tutulan kayıtlardaki anomalilerin güvenliğe tehdit unsuru olduğu varsayımından KNN yola çıkarak bu çalışma yapılmıştır. Probleme bir veri madenciliği yaklaşımı sunan Li ve Guo (2007), IT için

bu yaklaşımın güvenlik amaçlı kullanılabileceği üzerinde durmuştur. Şunu unutmamak gerekir ki Ağ teknolojileri alanı için IT verinin üretilebildiği, kaydedildiği, saklandığı ve kullanıma geçirildiği bir alandır ve bir üretim ortamı gibi düşünülebilir. Li ve Guo (2007), bu problemi bir sınıflandırma problemi olarak görmüştür ve bu sınıflandırma KNN ile sınıfların tahmin edilmesi ile başarılıdır. Li ve Guo (2007), bu çalışma için bir anomali formülasyonu geliştirmiş ve bu formülasyonun çıktısının nümerik değeri büyüdükçe kaydın güvenlik tehdidi seviyesinin de büyümekte olduğunu savunmuştur. Bu çalışmada anomali algılama, çok adımlı bir algoritma ile sağlanmıştır. Adımları genel olarak veri tabanının KNN sezgiseli süzgecinden geçirilmesi, bu süzgecin sonuçlarından bir sorgu yapılması ve bu sorgu sonuçlarının belirlenen bir formülasyon ile test edilmesidir. Bu çalışmanın sonucu olarak KNN yöntemi birçok gelişmiş anomali algılama tekniğine baskın gelmiştir. Sadece anomali algılama konusunu ele almayıp aynı zamanda hesaplama kompleksliğini ele alan bu çalışma, KNN ve diğer anomali algılama tekniklerinin verimliliğini de ölçmüştür. Gerek deneysel kümelerde gerek ise reel kümelerde KNN daha kısa sürelerde daha yüksek kesinlikte anomali algılayabilmiştir. Bu yüzden hem verimlilik açısından hem de pratiklik açısından, KNN metodu da bu çalışmada başarılı bir teknik olarak görülmüştür (Li ve Guo, 2007). Bunlara ek olarak birçok teknik gibi KNN varsayımlardan bağımsız bir yöntem olmasından dolayı reel örneklerde konunun uzmanlarının öngörülleri ile diğer yöntemlere göre daha çok kesişmiştir. Çalışmada KNN için sonuçların K değerine göre değişkenliğinin duyarlılığı ölçülmüştür. Artan K değeri için algoritma aşırı uyum göstermeye (overfitting) eğimli olurken azalan K değerleri için ise yetersiz uyum (underfitting) problemi ile karşılaşmıştır. Li ve Guo (2007), bu çalışmada K değerinin doğru seçiminin daha düzlenmiş (smoothed) sınıflandırma tahminleri oluşturabildiğini gözlemlemiş ve K değerinin seçiminin kritik bir problem olduğundan bahsetmiştir.

Ekincioğlu ve ark. (2017), çalışmalarında saatlik üretim miktarlarının mermer yüzey sertliği gibi bazı kalite kontrol ölçülerine bağlı tahminini incelemiştir. Bu inceleme için Schmidt ve Shore sertlikleri adı verilen bazı kalite

ölçüleri kullanmışlar ve bunların üretim miktarlarına etkisini araştırmışlardır. Tahminleme için YSA ve Regresyon Analizinin performansları karşılaştırılmış ve hata performansında YSA'nın daha iyi sonuçlar verdiğini gözlemlemişlerdir (Ekincioğlu ve ark, 2017). Başka bir araştırmada ise üretim araçlarının nümerik kontrol parametrelerine bağlı oluşabilecek kalite hataları tahmin edilmiştir. Bu kalite hatası yüzey pürüzlülüğüdür. Yüzey pürüzlülüğündeki artış ürün kalitesini düşürmekte ve ikincil bir operasyona neden olabilmektedir. Çalışmada YSA ve Regresyon Modelleri tahmin performansı açısından karşılaştırılmış ve YSA'nın deneysel verilere, Regresyon Modelleri'ne göre daha yakın sonuçlar verdiği gözlemlenmiştir (Taşdemir, 2011).

Ravinder (2013), araştırmasında Excel Solver'ın doğrusal olmayan optimizasyondaki başarısı sınamak için yaptığı çalışmada, üssel düzleme tahmin metotlarının parametrelerinin karar verilmesini modelleştirmiş ve Excel Solver aracılığı ile global optimaya ulaşip ulaşamayacağını görmek istemiştir. Çalışmada üssel düzleme yöntemlerinin tahmin hatalarında global optimaya ulaşan parametreler önceden karar verilmiş ve Excel Solver'ın bu değerleri bulup bulamayacağı ya da alternatif çözümlerden birini saptayıp saptamayacağını ölçülmüştür. Ravinder (2013), bu çalışmasında Simple Exponential Smoothing, Holt'un Metodu (Double Exponential Smoothing) ve Winter' ın Metodu (Triple Exponential Smoothing) zaman serileri tahminleme metotlarını kullanmıştır. Simple Exponential Smoothing için tek parametre olan alfa, Holt'un Metodu için iki parametre olan alfa ve beta ve Winter'ın Metodu için 3'lü parametreler olan alfa, beta ve gamma parametrelerinin tahmin hataları üzerine etkisinden bahsetmiştir. Bu parametreler doğru verildiğinde tahmin hatalarını ölçmek için kullanılan MSE (hataların karelerinin ortalaması) ve MAD (sapmaların mutlak değerlerinin ortalaması) performans ölçülerinin minimize olduğundan bahsetmiştir (Ravinder, 2013). Bu çalışmada parametrelerin başlangıç değerleri 0 olarak atanmış ve Excel Solver'ın bu değerleri uygun ataması beklenmiştir. Çalışmada da yapılacağı gibi Ravinder de (2013), "GRG-Nonlinear Solver" kullanılmıştır. Bu çözücü MS

Excel'in doğrusal olmayan programlama eniyileme modülüdür. Bu araştırmada Ravinder (2013), tahminleme için verilerini ve tahminleme yöntemlerinde kullanılan formülasyonları Excel Solver'a girdi olarak vermiştir ve parametreleri değişken olarak göstermiştir. Çalışmada bulunan parametre değerlerinin global optima değerleri olmadığı saptanmıştır. Çalışmada bulunan değerlerin ise lokal optima değerleri olduğu saptanmıştır. Ravinder (2013), bu çalışmasında zaman serileri tahminlere metotları için MS Excel GRG-Nonlinear Solver kullanmanın lokal optimada takılması gibi bir riskin bulunabileceği sonucuna varmıştır. Buradan çıkarılabilecek sonuç gerek üretim gerek servis sektörlerinde doğrusal olmayan optimizasyon çalışmalarında içbükey olmayan optimizasyon konularında Excel Solver kullanımında bazı ödünleşimler olabileceği konusunun düşünülmesi gerektiğidir. Biz de çalışmada YSA eğitimi sırasında GRG-Nonlinear Solver kullanırken bu çıkarımı dikkate alacağız. Sonuçların (tahmin hatası ölçülerinin) lokal optimada takılıp takılmadığından ziyade yüzde kaç kesinlikle tahminleme yapılabildiği konusu üzerinde durulacaktır.

Balaghi ve ark. (2008), Fas buğday veriminin tahmini için NDVI, yağış ve sıcaklık verilerini kullanan ampirik regresyon modelleri ile çalışma yapmışlardır.

Ataseven (2013), Box-Jenkins ARIMA zaman serileri öngörüleme modellerini YSA modelleri ile karşılaştırmıştır. Bu çalışma için materyal olarak bir şirketin 4 ürününe ait 11 yıllık satış verileri kullanılmıştır. Öngörü modellemesi bu çalışmada nitel ve nicel yöntemler olarak iki sınıfa ayrılmış ve nicel yöntemler incelenmiştir. Bu nicel yöntemler YSA tahminleme performansı ile karşılaştırılmıştır. YSA öngörü performansına etki eden unsurlar arasında plan ufku uzunluğu, verilerin temizliği ve eğitim algoritması gibi birçok unsur bulunmaktadır. Ayrıca zaman serilerindeki kabul görmüş kurallar YSA'da bulunmamaktadır. Bu YSA'nın esnekliğini artırmaktadır. Huang ve Babri, (1998), gibi Ataseven'de YSA'nın gizli katmanlarında bulunan nöronların sayısını belirlemenin bir problem olduğunu belirtmiştir. Bu çalışmada Ataseven, YSA eğitimi için geri yayılım algoritmalarını kullanmıştır. Ataseven bu geri yayılım algoritmalarını "negatif geri

beslemeli kapalı döngü sistemi” olarak sunmuştur. Öğrenme kurallarından algılayıcı öğrenme kuralına, delta öğrenme kuralına, genişletilmiş delta öğrenme kuralına ve geri yayılımlı öğrenme kurallarına değinilmiştir. Geri yayılımlı öğrenme kuralı kullanılacağı belirtilmiş ve burada bir geri yayılımlı öğrenme kuralı olan denetimli öğrenme kuralından bahsetmiştir. Geri yayılımlı öğrenme kuralı çalışmada MS Excel Solver kullanımı gibi tahmin hatasını enazlamak için kullanılmaktadır. Geri yayılımlı öğrenme kuralları için öğrenme katsayısı seçimi de problemin önemli elementlerinden biri olmuştur. MS Excel Solver’da öğrenme katsayısı seçimi bir problem değildir çünkü bir model çözücü kullanılmaktadır. Ataseven YSA haricindeki öngörü modellerinden Box-Jenkins, AR modelleri, MA modelleri ve ARMA ve ARIMA zaman serileri öngörüleme modellerini kullanmıştır. Uygulama sonucunda bir çıkarım olarak, zaman serilerinden farklı biçimde YSA’nın girilen verinin yapısını ve eğilimini öğrenerek öngörüleme yaptığı gözlemlenmiştir. Bu öğrenme aktivitesi insan beyninin öğrenme sisteminin bir taklididir. Bu çalışmada YSA tahminlemesinin hataları düşük olarak görülse de bazı problemler sunulmuştur. Bunların en önemlisi olarak verinin sayısallığının bir zorunluluk olduğu vurgulanmıştır. Ne yazık ki öngörüsü yapılması gereken paternler her zaman sayısal olmayabilir ve sayısallaştırma gibi bir önışlem gerekebilir. Çalışmada bütün girdiler ve çıktıların sayısal olması böyle bir adımı gerektirmemektedir. Bu çalışmada zaman serileri ile yapay zekânın YSA karşılaştırılmıştır. Çalışmada ise iki yapay zekâ algoritması olan YSA ve KNN karşılaştırılmıştır.

YSA hakkındaki literatür taraması bitmiştir ve önümüzdeki bölümlerde materyallerden, metotlardan, yöntemlerin uygulanmasından ve karşılaştırmadan bir sonuca varılmasını ele alacağız.

2.3. Performans Kriterleri, Performans Değerlendirmesi Önceki Çalışmalar

Kurumların ürünlerinin, personellerinin, hizmetlerinin veya işlemlerinin yerine getirilmesinde görevlerin nasıl yerine getirildiğinin tarafsız ve objektif bir program aracılığı ile değerlendirilmesine performans ölçümü denir (Yüregir ve

Nakıboğlu, 2007; Neely ve ark, 1995). Şirketlerin misyonlarının gerçekleşmesinde önemli rollerden birini performans ölçüleri oynamaktadır. Ayrıca personelin ve diğer şirket birimlerinin şirketin amacına katkısı da performans ölçüleri ile incelenebilmektedir (Grady, 1991). Performans ölçüleri aynı zamanda şirket faaliyetlerinin amaca yönelik olup olmadığının ve bu faaliyetlerin amaca katkısının ölçülmesinde önemli rol oynamaktadır. Şirketin bulunduğu pazardaki rekabetteki başarısı ürünlerinin ya da hizmetlerinin yüksek kalitesi, kısa sürede üretilmesi ve düşük maliyetli oluşuyla doğru orantılıdır (Martinsons ve ark, 1993).

Etkin performans ölçülerine sahip işletmelerin, sahip olmayanlara göre dinamiklik açısından daha güçlü olduğu görülmektedir (Zerenler, 2005). Zerenler (2005), çalışmasında performans ölçülerinin tasarımı konusunun üzerinde durmuştur.

Performans ölçüsü olarak belirlenecek değer(ler) makro seviyeden mikro seviyeye indirgenebilir. Çalışmada ise şirketler seviyesinde fabrika içine indirgenmiş hiyerarşik seviyelerin altlarında bulunmaktadır. Bu seviye üretim hattı seviyesinin de altında, hattın son noktasında alınan sistem etkinliği değeri seviyesidir. Mikro seviyede bir değer olan sistem etkinliği bir performans ölçüsü seçilmiştir. Çalışmanın amacı (karar kriteri) sistem etkinliğinin maksimizasyonu değil çalışanların sistem etkinliğine katkılarının maksimizasyonudur. Bunun için performans ölçüsüne katkısı yüksek olan personele motivasyon sağlamak diğer personel için de rekabetçi bir ortama giriş sağlayacaktır. Bu bağlamda karar kriteri personel tarafından sağlanan sistem etkinliğinin ve öngörülen sistem etkinliği farkının en büyüklenmesi, sistem etkinliği performans ölçüsüne bir karar kriteri sağlayacak ve bu belirlenecek stratejiler yardımı ile en büyüklenebilecektir. Bu enbüyüklemenin sadece hiyerarşide belirlenen bölgeye sağladığı katkı sistemin etkinliğinin artırılmasına katkı sağlayacak, sistemin etkinliğinin artırılması fabrikaya katkı sağlayacak ve fabrikaya sağlanan katkı ise aynı zamanda şirkete de sağlanmış olacaktır.

Yüregir ve Nakıboglu (2007), çalışmalarında Mükemmellik Modeli, Performans Prizması, Kurumsal Karne gibi performans ölçme tekniklerini karşılaştırmış ve bunların birbirlerine göre dezavantajlarını ve avantajlarını incelemiş ve sunmuşlardır. Faydalı bir seçim olarak, karşılaştırmaları da dikkate alarak kurumlarının yapılarını da dikkate alarak bu performans ölçüm tekniklerinin birini ya da karışımlarını kullanmaları yazarlar tarafından önerilmiştir. Yazarlar bu çalışmada performans ölçümünün kurumlar ve organizasyonlar açısından önemini ve faydalarını incelemiş ve sunmuşlardır. Performans ölçme sistemlerinin etkinliği ve etkililiği ölçmede fayda sağlayan ölçüm sistemleri kümesi olduğu belirtilmiştir (Neely ve ark, 1995). Çalışmada performans ölçüm istemlerinden yeni nesil ve geleneksel olanlar incelenmiştir. Bu inceleme gelenekselden yeni nesile doğru tarihsel bir bakış açısı sunmuştur. Çalışmada geleneksel olanların daha finansal bazlı yöntemler olduğundan bahsedilirken, yeni nesil olanlarının ise daha stratejik ve süreçsel olduğundan bahsedilmiştir. Bu yöntemlerin rekabete zarar vermemesi gerektiği de vurgulanmıştır. Bu araştırmada bazı performans ölçüm yöntemleri incelenmiştir. Bunlar yatırımın geri dönüş oranı (ROI), sink ve tuttle modeli, marka değerlendirme, müşteri değer analizi, paydaş değer analizi, faaliyet tabanlı değerlendirme (ABC analizi), ekonomik katma değer, performans piramidi ve daha önce bahsedildiği gibi performans prizması, kurumsal karne ve mükemmellik modelidir. Bu performans ölçüm yöntemleri, belirli sınıflar altında toplanmıştır. Bu sınıflar Geleneksel, Finansal, Süreçsel, Strateji Bağlantısı, Kalite Yönetimi Bağlantısıdır (Yüregir ve Nakıboglu, 2007). Çalışmada personel performansı değerlendirme ve bu değerlendirme sonucu ödül ve destekleme ile motivasyon sağlama odaklı olduğundan ve bu odak ise paydaşlardan biri olan personel üzerinde kurulduğundan süreçsel ve kalite yönetimi bağlantısı sınıfında değerlendirilmelidir. Bu sınıf incelendiğinden sınıfın özellikleri odak noktaları belirtilmiştir. Bunlar: paydaş ve strateji odaklı, strateji, yetenekler, paydaş katılımı, paydaş memnuniyeti, çalışanlar, müşteri hissedarlar, tedarikçi, bankalar, toplum, devlet ve teknolojidir. Çalışmanın odak noktası ise motivasyon ve çalışan performansı bakımından, bu

sıralananlar açısından; yetenekler, paydaş katılımı, paydaş memnuniyeti ve çalışanlardır. Paydaşların ölçüme katılımı incelendiğinde bu katılım çalışmanın sonuçlarını da ilgilendirdiği görülmektedir, katılım en yoğun performans prizmasında yaşanmaktadır (Yüregir ve Nakıboğlu, 2007). Çalışmada Yüregir ve Nakıboğlu (2007), bunun nedeni olarak Performans Prizmasının çıkış noktasının paydaşların memnuniyeti ve sisteme katkısı olduğunu belirtmişlerdir. Çalışmanın sonuç ve değerlendirme kısmında kurumların ve organizasyonların hedeflerini, önceliklerini ve stratejilerini belirlemesi ve kritik başarı endekslerini buna göre belirlemesi gerekmektedir. Bu çalışmanın avantajı, karşılaştırmalar sağlayarak en uygun performans ölçüm yöntem(ler)inin seçilmesi konusunda kurumlara ve organizasyonlara ışık tutucu bir yönünün olmasıdır. Bu konuda organizasyonlar ve kurumlar yol haritalarını belirlerken bu çalışmadaki karşılaştırmaları ve sınıflandırmaları kullanabilmesi açısından belirleyici olmuştur. Bunlara ek olarak detaylı literatür araştırması daha sonraki çalışmalar için bir altyapı olmayı amaçlamıştır (Yüregir ve Nakıboğlu, 2007). Çalışmada kritik başarı endeksi çalışanın verimliliğinin yükselmesine (kalite kaybının düşüşüne) sağladığı katkıdır. Çalışmada performans ölçümü sistem etkinliğinin (%100 - %Kalite Kaybı Ölçüsü) öngörebilen bir yapay sinir ağının sağladığı öngörü verisinden çalışanın çalıştığı vardiyada elde ettiği sapmanın derecesi ve yönüne göre yapılmıştır.

Zerenler (2005), çalışmasında performans ölçülerinin tarihsel gelişimini incelemiş ve bu inceleme de çalışmada belirlediğimiz performans ölçüsünün ölçülebilirlik açısından doğruluğunu ve kesinliğini anlaşılmasında katkı sağlamıştır. Bu bağlamda şu söylenebilir ki performans ölçüsü somut ölçülebilir bir skalada seçilmelidir ve sistemin etkinliği ölçülebilir ve öngörülebilir bir skaladır. Zerenler (2005)'in çalışmasına göre maliyetin düşüklüğüne dayalı performans ölçüleri geleneksel performans ölçüleri arasında bulunurken müşteri tatminine yönelik performans ölçüleri ise yeni gelişen, çağdaş ölçüler arasındadır. Sistem etkinliğinin yükseltilmesi hem kalite kaybının şirkette oluşturduğu maliyeti düşürmektedir hem de müşteriye ulaşan malzemenin belirli bir kriterinin üzerinde oluşunu

garantilemektedir. Çünkü müşterinin kriterlerini sağlamayan ürünler şirketlerde kayıp olarak görülmektedir. Bu bağlamda sistem etkinliği, hem geleneksel hem de yeni olarak ortaya konulan performans ölçüleri sınıfının bir karışımı olarak görülebilir. Zerenler (2005), çalışmasında 17 farklı performans ölçüsünü incelemiştir. Bunlardan kalite tutarlılığı ve üretkenlik sistem etkinliği performans ölçüsü ile doğrudan ilişkilidir, ayrıca çalışmasında sunduğu iş gücü üretkenliği performans ölçüsü çalışmanın ana odak noktası ve iş gücü üretkenliğinin en büyüklmesi de çalışmada karar kriteridir.

Çalışma performans ölçülerinin belirlenmesi ve somut hedeflerin tespit edilmesi safhasının sonraki adımları olan bilginin elde edilmesi ve bilginin raporlanması ve iyileşmeye yönelik önlemlerin alınması adımlarını içermektedir. Belirtilen adımların esinlenme kaynağı Grady'nin (1991), çalışmasıdır. Bu çalışmada aynı zamanda bilginin elde edilmesi ve bilginin raporlanması adımlarının arasına bilginin işlenmesi ve tutarlılığının sorgulanması adımı da eklenmiştir. Bu inceleme ve sorgulama K-Means algoritması ile verilerin sınıflandırılması ve sınıfların incelenmesi ile sağlanmıştır. Zerenler (2005), çalışmasında sürekli geribildirim de sürece dahil edilip, sadece amaç fonksiyonlarının değil aynı zamanda yöntemlerin de geliştirilmesinden bahsetmiştir. Yazar, bu çalışmasında performans ölçülerinin belirlenmesinde bazı özelliklerin varlığının önemini açıklamıştır. Bunlar kısaca şu şekildedir: Tutarlılık, açıklık ve kesinlik, meydan okuma, ölçülebilir, ulaşılabilir, kabul edilebilir, zamanla ilişkilendirilebilir, takım çalışması odaklı. Bunlara ek olarak yazar katma değer odaklı bir faaliyetin performans ölçüsüne pozitif etkilerinden bahsetmiştir. Bu bağlamda belirlediğimiz sistem etkinliği performans ölçüsü maliyeti düşürme ve müşteriye kriterlere uygun ürün ulaştırma açısından katma değeri ölçülebilir ve yüksek bir performans ölçüsüdür.

Arslan (2007), çalışmasında Türkiye'deki kamu sektörüne bağlı şeker fabrikalarındaki etkinlik düzeylerinin tespit edilebilmesi ve geliştirilebilmesi için Veri Zarflama Analizinin (VZA) kullanımı üzerinde çalışmıştır. Yapılan çalışma

sonucunda bazı şeker fabrikalarının etkinlik seviyelerinin düşük olduğunu gözlemlenmiştir. Bu çalışmada Veri Zarflama Analizi fabrikaların girdi ve çıktı değişkenleri incelenerek etkin kaynak dağılımı yapıp yapılmadığının anlaşılması için kullanılmıştır. Etkinliğin analizi belirli miktarda girdi ile maksimum çıktı ya da hedeflenen bir çıktının minimum miktarda girdisi ile yapılmıştır. Çalışmada VZA ile uygulanabilecek analizlere 3 örnek verilmiştir, bunlar: çıktı odaklı, girdi odaklı ve tahsistir. Çıktı odaklı sabit girdilerle çıktının en büyüklmesi, girdi odaklı verilen sabit bir çıktı hedefi için girdinin en küçüklmesi ve tahsis ise çıktıları minimum maliyete ulaştırmak için girdilerin fiyatlarının hesaba katılarak modellenmesidir ve bu çalışmada etkinliği %100'ün altında olan değerler “etkinsiz” olarak değerlendirilmiştir (Arslan, 2007). Burada performans ölçüsünün karar kriterini belirleme çalışma ile benzerlikler barındırmaktadır. Çalışmada iş gücü kantitatif olarak sabit tutulup aynı iş gücü ile daha fazla verim alınmaya çalışılmıştır. Tabii ki bunun için kantitatif politikalar yerine kalitatif motivasyon yöntemleri kullanılmıştır.

Arslan (2007), çalışmasında farklı hipotezler test edilmiştir. Analizler için seçilen karar birimlerine sadece kamu dahil edilmiştir ve özel sektör ele alınmamıştır. Girdiler fiilen işlenen pancar miktarı, nümerik fiili personel toplamı ve toplam yakıt tüketimidir. Çıktı değişkenleri ise, satılan şeker miktarı, melas üretim, şeker üretimi ton cinsinden ve net gelir ise TL/ton cinsinden belirlenmiştir. Bu girdiler arasında otokorelasyon olup olmadığı incelenmiştir ve herhangi bir otokorelasyon tespit edilememiştir. Çalışmanın girdileri olan KDG, FHA ve BUM arasında da otokorelasyon bulunmamaktadır. Girdi değişkenlerinin ve çıktı değişkenlerinin sayısı VZA performansının düşmemesi açısından sınırlı tutulmuştur. Bu girdi ve çıktı değişkenlerinin sayılarına bir sınırlama getirmek için bir kriter olarak da karar birimlerinin sayısı bir üst sınır olarak belirlenmesi ilkesi kullanılmıştır. Çalışmada bu ilkeye uyulmuştur. Bu çalışmada kullanılan modelin amaç fonksiyonu çıktının en büyüklmesidir. Modelin çalıştırılması sonucu çıktılar analiz edilmiştir. Bu çalışmada VZA kullanımı çalışmanın aksine makro bir bakış sunmuştur. Bu çalışmada araştırılan yıllar 2003 ve 2004'tür. Sonuca göre bu yılların

toplan etkinlik ortalaması %98 ve teknik etkinlik ortalaması ise %99 olarak hesaplanmıştır. Ölçek etkinliği ise yine %99'dur. Bu sonuçlar incelendiğinde daha önce de belirtildiği üzere %100 olmadıkları için bazı fabrikalar etkinsiz çalışmaktadırlar. Bu yüzde 1 ve 2'lik farklılıklar bu fabrikalarda hala iyileştirme yapılabileceğini göstermektedir (Arslan, 2007). Çalışmanın aksine bu çalışma makro düzeyde olsa da girdilerin sabitli ve çıktının en büyüklenmesi açısından benzerlikler bulunmaktadır. Çalışmanın dayanaklarından biri de çıktı odaklı bir kontrol mekanizması olduğunu savunabilmemizdir.

Albayrak ve Erkut (2005), banka performanslarının değerlendirilmesine hiyerarşik bir yaklaşım sunmuştur. Çalışmada amaç olarak hizmet sektöründe finansal olan ve finansal olmayan performans ölçülerinin bir arada kullanıldığı çok amaçlı bir model kurularak, bankaları örnek bir hizmet sistemi olarak değerlendirip modeli geliştirmektir. Çalışmada Analitik Hiyerarşi Performans Modeli olarak adlandırılan bir model kullanılmıştır. Bu model risk ve karlılık gibi kantitatif performans ölçülerinin yanında hizmet kalitesi, müşteri memnuniyeti gibi kalitatif performans ölçülerini de yapısına dahil etmektedir ki bu kalitatif ve kantitatif performans ölçülerinin birbirlerinden bağımsız ya da birinin eksik değerlendirilmesi sonucu ortaya çıkacak sonuçların yetersiz ve eksik olabileceği savunulmuştur (Albayrak ve Erkut, 2005). Çalışmada hizmet sistemlerine hiyerarşik bir bakış açısı sunulduktan sonra hizmet sistemlerinde performans yönetimi incelenmiştir. Bu bağlamda hizmet kalitesi kavramı açıklanmıştır. Bankalardaki performans değerlendirilmesi açıklanmış ve örnekler sunulmuştur. Ardından Analitik Hiyerarşi Performans Modeli (AHPM) açıklanmıştır. Seçilen örnek bankalar sektörde sıralamaya göre ilk 5 bankadır. Çalışma için performans ölçüsü AHPM ile belirtildikten sonra karar kriterler ve alt kriterler belirlenmiştir. Bu örneklerin risk ve karlılıklarının hesaplanması için analiz edilecek değişkenler sermaye yeterliliği, aktif kalitesi, likidite, karlılık, gelir- gider yapısı, grup payı ve sektör payıdır. Bu değişkenler karlılığın hesaplanması için kullanılırken risk kriterleri ve alt kriterler için likidite riski, kredi riski, sermaye riski ve faiz riski kullanılmıştır. Bu değişkenler

çalışmada modelin kurulması safhasında formülize edilmiştir. Çalışmanın problem tanımı ise bankaların performans değerlendirilmesi yapılabilmesi için bir ön araştırma yapılmasıdır. Çalışmada hiyerarşik yapı yukarıdan aşağıya şu şekildedir: amaç, karar vericiler, kriterler, alt kriterler ve alternatif seçeneklerdir. Çalışma için bir uzman müşteri grubu oluşturulmuş ve sonuçlar onlara sunulmuştur. Grubun oluşturulma safhası da çalışmada detaylı olarak anlatılmaktadır. Sonuçlarda performans ölçümünün imalat sektöründe elde ediniminin hizmet sektörüne göre daha kolay olduğunu belirttikten sonra talep gibi rassal olayların performans ölçülerinin hesaplanmasının zorlaşmasına neden olduğundan bahsedilmiştir. Çalışmada bu durum gözlenmemektedir ki sistem etkinliği talep ile doğrudan bağlı değildir. Albayrak ve Erkut (2005), çalışmanın amacı olarak hizmet sektöründe (bankacılıkta) finansal olmayan ölçülerin de kullanımının çok yönlü bir değerlendirme sağlayacağını gösterilmesidir. Bir başka önemli nokta da finansal performans ölçülerinin kriz gibi dönemsel olaylara karşı duyarlılığının araştırılmasıdır, bunun yanında finansal olmayan müşteri memnuniyeti performans ölçüsünün bankaların sunduğu müşteriye özel tekliflere karşı olan duyarlılığı da ölçülmesidir (Albayrak ve Erkut, 2005).

Elitaş ve Ağca (2006), firmalarda çok boyutlu performans değerlendirmede kavramsal bir bakış açısı sunmuşlardır. Bu çalışmanın bir gerekçesi olarak firmalarda finansal değerlendirmelerin eksik kaldığı noktaları incelemiş ve örgütsel performans değerlendirmelerinin de dahil edilerek çalışılmasına bir taban sağlamışlardır. Bu çalışmada çok boyutlu performans değerlendirmelerinin hem finansal hem de örgütsel yapıdaki esnekliğini kullanmışlardır. Çalışmada karlılık, kalite, müşteriler, insan kaynakları (İK), yenilik ve esneklik gibi kavramlar da performans ölçümüne dahil edilmiştir. Yüregir ve Nakıboğlu (2007), çalışmalarında kullanılan Performans Prizması ve Performans Piramidine ek olarak bu Dengeli Ölçüm Kartı Değerleme (Balanced Score Card) ve Paydaş Temelli Performans Değerleme (The Stakeholder Card) kullanılmıştır. Çalışmada ise bunlardan farklı olarak personel puanlama sistemi oluşturulmuştur. Çalışmanın detayları ise bulgular

bölümünde daha detaylı anlatılmıştır. Performans ölçümü alanında yapılan çalışmalar sadece finansal ölçülerin yetersiz kaldığını göstermiştir (Elitaş ve Ağca, 2006). Bu çıkarım literatürde sıkça desteklenen bir çıkarımdır (Albayrak ve Erkut, 2005, Arslan, 2007, Zerenler, 2005, Yüregir ve Nakıboglu, 2007). Yüregir ve Nakıboglu (2007), gibi bu çalışmada da geleneksel ve yeni nesil performans ölçümüne değinilmiş ve aynı şekilde geleneksel yöntemlerin müşteri odaklı olmadığı vurgulanmıştır.

Elitaş ve Ağca (2006), yeni nesil performans değerlendirmede amaç olarak genellikle yüksek verimlilik, etkinlik ve kâr enbüyüklenmesi, maliyet enküçüklenmesi, müşterinin memnuniyet seviyesi, büyüme ve saygınlık ve çalışma yaşamının kalitesi gibi performans ölçülerinin de dahil edildiğini belirtmiştir. Bu bağlamda şunu diyebiliriz ki performans göstergelerinin bir eylem ya da faaliyet sonucu ortaya çıkan göstergelerin nicel ya da nitel tanımlamalarıdır ve yeni nesil finansal olmayan performans göstergelerinin temelinde başarılı bir geri yayılım ve geri bildirim bulunmaktadır (Elitaş ve Ağca, 2006). Bu çalışmada makro düzeyde bir performans ölçümü sunulmuştur. Elitaş ve Ağca (2006), yukarıda belirtine 4 yöntemi finansal, müşteri, ürün ve süreçlerin kalitesi, ürün ve süreçlerin hızı (responsiveness), kaynaklar/altyapı ve yetenekler, öğrenme ve gelişme ve yenilik, çalışanlar, vizyon ve strateji ve rekabet açısından değerlendirmiş ve bu sayılan öğelerden hangileri hangi yöntem tarafından incelenmiş olduğu sunmuştur. Çalışmada aynı anda hepsini dahil eden bir performans ölçümü bu dördü arasında yer almamaktadır. Fakat finansal, müşteri, ürün ve süreçlerin kalitesi ve ürün ve süreçlerin hızı dört yöntem tarafından da incelenen öğeler olmuştur. Elitaş ve Ağca (2006), çalışmasında esneklik, yenilik, öğrenme ve gelişme öğelerini ele alan bir tek Dengeli Ölçüm Kartı Tekniği bulunduğunu belirtmiştir. Çalışmada, çalışan performanslarını değerlendirirken iş gücü kalitesine ek olarak bu öğelerden ürün ve süreçlerin kalitesine de değinmekte ve sistem etkinliği sayısal mikro performans ölçüsü ile çalışmaya ölçülebilir bir dayanak oluşturmuştur.

Özsever ve ark. (2009), Verimlilik ölçüm modeli olarak David J. Sumanth Modeli, Kurosawa Modeli, Veri Zarflama Analizi, M. R. Ramsay Modeli, Jackson ve Petterson Yaklaşımlarını incelemiş veri analizlerini Kurusawa'nın "Oranlarla İşgücü Verimliliği Modeli" ile yapmıştır.

Çağdaş yaklaşımların sadece finansal olayları değil bunlara ek olarak finansal karakterde olmayan olayları da değerlendirmesi gerekmektedir ve finansal karakterde olmayan olayları veya faaliyetleri de hesaba katması ve finansal faaliyetler kadar önemsemesi gerekmektedir (Elitaş ve Ağca, 2006).

Işığışık (2008), performans ölçümünü teorik olarak incelemiş ve çalışmasında ham bir şekilde performans puanlarının hesaplanmasını, bu puanların oluşumuna katkıda bulunan faktörleri, bağıl performans ölçüsünün değerlendirilmesini ve bu bağıl değerlendirme sonucu puanların bir performans notuna dönüştürülmesinin bir süreç şeklinde anlatımını yapmıştır. Çalışmada 4 farklı bağıl performans dönüştürme yöntemi incelenmiş ve bir çalışan grubunun buna göre ortaya çıkan puanları incelenmiştir. Işığışık (2008), performans yönetiminde amaçların iyi belirlenmesi, ölçülebilir olması ve objektif yaklaşımlar ile çalışılması gerektiğini belirtmiş ve ardından insan değerlendirmesinin hatalar ile sonuçlanabileceğine değinmiştir. Çalışmada performans ölçümü öncesinde kriterler karar destek sistemi ile belirtilmiş ve insana bağlı kriter belirleme ortadan kaldırılmaya çalışılmıştır. Çalışmada belirli yapay zekâ metotları kriterleri belirlemeye çalışmıştır ve başarılı olmuştur. Buna bağlı anlatımlara ilerleyen bölümlerde değinilecektir. Bu bağlamda çalışma Işığışık'un (2008), insan hatası vurgulamasından etkilenmiştir. Çalışmada ölçüm iş gücü kalitesi iken değerlendirme karar destek sistemleri tarafından öngörülen ve hedeflenen bir sistem etkinliği planına uyum ile gerçekleştirilmektedir. Performans ölçümümüz ardından Işığışık (2008), da çalışmasında bahsettiği "Beklenen sonuca ne düzeyde ulaşılmıştır?", "Doğru yönde iyiye doğru gidiliyor mu?" ve "Gerçekleştirilen işlerin amaçlara katkısı olmuş mudur?" sorularına cevap alabilecek duruma gelinmesi hedeflenmiştir. Bunun için çalışmada performans değerlendirilmesi yapılacak personel grubuna iş

tanımlarının eksiksiz ve anlaşılır olarak duyurulduğu garanti altına alınmıştır. Işığışık (2008), performans kriterleri SMART özellikleri ile belirtmiştir. Bu özellikler spesifik (belirli ve somut), measurable (ölçülebilir), achievable (ulaşılabilir), reasonable (gerçekleştirilebilir) ve time-bound (zamanla sınırlı) şeklinde belirtilmiştir. Çalışma ise incelendiğinde sistem etkinliği performans kriteri belirli ve somuttur, belirli kalite hataları ve üretim miktarları üzerinden ölçülebilir metriklerle belirtilmiştir, karar destek sistemi gerçel kalite değerlerini ve üretim miktarlarını hesaba kattığından ulaşılabilir ve gerçekleştirilebilirdir. Bunlara ek olarak verimliliğe etki eden üretim çıktıları vardiya bazında elde edilip öngörüldüğünden zamanla sınırlıdır. Bu bağlamda çalışmada belirtilen performans kriteri SMART özellikleri ile uyumludur. Organizasyonların performans yönetimine geçişlerinde rol oynayan önemli faktörleri göz önünde bulundurmak gerekmektedir. Bunlardan bazıları gelişmelere ayak uydurabilmek, geleceğe yönelik vizyonu sağlayabilmek, iş gücü planlaması yapmak, dönemsel sürekli objektif değerlendirmelerde bulunmak, çalışanların şirket ilerlemesine katkılarına motivasyon sağlamaktır. Performans yönetiminin şirkete faydaları arasında vizyon ve strateji doğrultusunda çalışanların hedeflere entegrasyonu, departman katkıları ile bireysel katkıların ayırt edilebilmesi, eğitim ve gelişim planlaması ile beraber işgücü planlamasının da sistemin bir girdisi haline gelmesidir (Işığışık, 2008). Işığışık bu sisteme geçişin akışını dört aşamada açıklamıştır. Bunlar sırasıyla, hedef belirleme süreci, performans izleme, performans değerlendirme ve ödül, prim, ücret motivasyon belirleme sürecidir. Bu bağlamda çalışmada hedef iş gücü kalitesini yükseltmek, performans sayısal ölçülerle izlenebilir hale getirmek, sayısal ölçülerle izlenebilen performansın objektif değerlendirilmesi ve başarı kriterleri sağlandığı takdirde ödüllendirme şeklindedir. Işığışık (2008), Ham performansın hesaplanması safhası için bir formülizasyon oluşturmuş ve bu formülizasyon hedef ile başarıların farkını temel almıştır. Çalışmada başarılan verimlilik ile hedeflenen verimlilik arasındaki fark bir ham puandır. En başarılı öge ise hem en yüksek puanları alan ve bunu sürekli olarak yapabilen olacaktır. Çalışmada puanları etkileyen faktörler

mikro faktör yani yönetici ve makro faktör yani çevredir ve bu faktörler çerçevesinde her çalışanın başarısı diğerinden bağımsız olarak değerlendirilmelidir (Işığışık, 2008). Çalışmada her çalışan diğerleri ile denk ayrı bir vardiyadan sorumlu olduğu için ve çevresel faktörler kendi sorumluluk alanında minimal olduğu için performans ölçümümüz değerlendirmemiz Işığışık'un önerisine uymaktadır. Puanlama sisteminden sonra değerlendirilmeye geçilmeden önce bir nirengi noktası belirlenmelidir. Işığışık (2008), bir nirengi noktası almak için performans değerlerini merkezileştirmiş ve normal dağılıma uygunluğunu ölçmüştür. Buna göre çalışanlardan en düşük nottan en yüksek nota doğru yüzde ikisi "E" notu, yüzde 10'u "D" notu, yüzde 65' i "C" notu, yüzde 20' si "B" notu, yüzde üçü ise "A" notunu almıştır. Bu sisteme alternatif olarak puanlamaların beklenene sigma uzaklıklarını hesaplamının da kullanılabilir. Harf notları üzerinde kararsız kalan noktalarda sigma hesaplaması yöntemine de başvurulabilir desteklenen ve desteklenmeyen puanlar da araştırılabilir (Işığışık, 2008).

Çakmak ve Ocaklı (2014), performans ölçümü ve değerlendirme konusunda, değerlendirmenin gerekliliği konusunu ele almıştır. Gelişen teknoloji ve yaşam şartlarıyla beraber hizmet sektörünün sosyal toplumlardaki yeri üretim sektörünü geçmiş ve günlük yaşamlarımızın bir parçası olmuştur ve hatta bazı alanlarda ihtiyaç haline gelmiştir. Bu ihtiyaç hizmet sektöründe performans artırımını mecbur hale getirmiştir. Karmaşıklaşan sistemler ve yükselen rekabet, gücünü sorgulayan şirketler için performans değerlendirilmesi gerekliliktir. Bu bağlamda hizmet ve çalışmaların performansları değerlendirilmelidir (Çakmak ve Ocaklı, 2014). Bu çalışmada performans değerlendirmesinin faydalarından detaylı olarak bahsedilmiştir. Gelişen çağ yüksek düzeyde bilgi işleme yeteneğine sahip personelleri ve uygulamaları gerektirmektedir. Kurumlara gelişmişlik düzeyi sağlama konusunda katma değer olarak değerlendirilebilecek bu elemanlar, sürekliliğin sağlanmasında önemli rol oynamaktadır. Performans çok boyutlu olarak değerlendirilmelidir. Performans tanımlanmak gerekirse kurumun (şirketin) maddi ve manevi bütün kaynaklarından yararlanma derecesidir. Nitel ya da nicel olarak

sınıflandırma fark etmeksizin, performans ölçümü ve değerlendirmesi şirketin vizyon ve stratejilerine uygun amaçlarına ve hedeflerine ulaşabilmek için performans göstergelerinden faydalanarak örgütün bütün bileşenleri hakkında bilgi toplama, ölçüm yapma ve değerlendirme sürecidir (Çakmak ve Ocaklı, 2014).

Performans ölçümü ve değerlendirmesi ve performans kriterlerinin belirlenmesi konusundaki bu literatür taraması çalışmaya dayanak oluşturacak bakış açıları sunmuştur. Çalışmaya kalitatif ve kantitatif bakış açıları kazandıran bu araştırma aynı zamanda “doğru performans ölçüleri belirleme” ve “gerçekçi performans kriterleri ile çalışma” konusunda aydınlatıcı olmuştur. Literatür taraması, mikro düzeyde yaptığımız çalışanların performanslarının değerlendirilmesi konusunda yol gösterici bilgiler kazandırmıştır. Bunlar performans belirlemede izlenecek adımlar ve kriter belirlemede “ulaşılabilir” ve “gerçekleştirilebilir” hedeflerin konulmasına teşvik edicidir. Ayrıca spesifikklik (belirleyici) ve ölçülebilirlik konularında çalışmayı destekleyici bilgiler içermektedir. Sistem etkinliği (%100-kalite kaybı) öngörülmesi ve hesaplanması, yapay zekadaki spesifik konular ve performans ölçüleri ve değerlendirme konusunda yaptığımız araştırmaların kazanımları, çalışmaya güçlü bir şekilde yansımıştır ve literatürde uygun görülen çalışmalar, yapılan çalışmaya birçok noktada esin kaynağı olmuştur.

Önceki çalışmalar incelendiğinde kalite kaybının YSA ve KNN ile tahmin edilmesi ile ilgili herhangi bir spesifik çalışmaya rastlanmamıştır. YSA ve KNN algoritmaları ile yapılan birçok çalışma detaylı olarak incelenmiş ve yapılan çalışmaya güçlü bir şekilde katkı sağlamıştır.

3. MATERYAL VE METOT

3.1. Materyaller

Çalışmada, günde 3 vardiya kesintisiz üretim yapan bir üretim tesisine ait veriler kullanılmıştır. 650 güne ait 1950 vardiyada toplanan ve çalışmanın temelini oluşturan veriler; münferit zamanlarda ortaya çıkan fire yaratacak kalite hatası sayısı, kalite dağılım göstergesi, brüt üretim miktarı ve tüm bunlara bağlı olarak değişen kalite kaybı (ya da yüzdelik verim) miktarıdır. Bu veriler dışında üretim verimliliğini doğrudan etkileyen arıza kaybı, enerji kesintisi vb. gibi operatörden bağımsız kayıpların verileri de toplanmıştır ancak bu veriler çalışmaya dahil edilmemiştir.

Çalışmada kullanılan; münferit zamanlarda ortaya çıkan fire yaratacak kalite hatası sayısı, kalite dağılım göstergesi ve brüt üretim miktarı verileri vardiya bazında değerlendirilerek tahmin etmeye çalıştığımız yine vardiya boyunca oluşan kalite kaybına etkileri analiz edilmiştir. Yapılan analizlerin sonucunda her bir faktörün kalite kaybına belirli bir oranda etki ettiği gözlemlenmiştir. Değişen koşullara göre oluşan kalite kayıplarının yeni bir değerlendirme öncesinde ana veriye otomatik olarak dahil edilebiliyor olması yani sistemin YSA ile öğrenebiliyor olması üzerinde çalışılan sistemin sürekli kendini güncellemesini sağladığından zaman içerisinde operatör hatalarının azaltılması yönünde sürekli gelişimi teşvik edici bir etki yaratacağı beklenmektedir. İlerideki anlatılan yöntemlerin performanslarının karşılaştırılması için 200 farklı vardiyadan 200 adetlik veri seti de toplanmıştır. Toplanan 1950 veri YSA eğitimi için kullanılacakken 200 adetlik veri seti ise iki tahmin yönteminin performanslarının karşılaştırılması için kullanılacaktır.

3.2. Metotlar

Bu çalışmada kullanılan metotlar Yapay Sinir Ağları ve KNN sınıflandırma algoritmasıdır. KNN sınıflandırma algoritması ağırlıklı toplam algoritması ile entegre edilip tahminleme yöntemi olarak kullanılmıştır.


3.2.1 Yapay Sinir Ağları Nedir

Yapay sinir ağları, makine öğrenmede kullanılan ana araçlardan biridir. Adının önerdiği gibi, insanların öğrenme biçimini örneklemeyi amaçlayan beyinden ve sinirsel sistemlerden esinlenilmiş sistemlerdir. Sinir ağları, giriş ve çıkış katmanlarının yanı sıra (bazı durumlarda) girdiyi, çıkış katmanının kullanabileceği bir sayısal ifadeye dönüştüren birimlerden oluşan gizli bir katmandan oluşur. Bir insanın makineyi eğitmesini ve etrafını (verileri) tanımayı öğretmesini sağlamak için çok karmaşık kalıpları tanımlayabilen araçlardır (Hecht-Nielsen, 1992). Yapay sinir ağları girdi olarak verilen veriyi bir takım ağırlıklı toplam metodu silsilesi ile gizli katmandan geçirerek çıktı katmanına aktarmaktadır. YSA'nın işleyişi kabaca böyledir fakat Yapay Sinir Ağlarının detaylı işleyişi matematiksel olarak "3.3 METODOLOJİ: Tahminleme Operasyonu" başlığı altında detaylı olarak anlatılmıştır.

3.2.2. KNN-Algoritması Nedir

K en yakın komşular, mevcut tüm vakaları depolayan ve yeni vakaları benzerlik ölçütüne göre (örneğin mesafe) sınıflandıran bir algoritmadır. Bir vaka, komşularının çoğunluk oyuyla sınıflandırılır; vaka, uzaklık fonksiyonu ile ölçülen en yakın komşuları arasında en yaygın olan sınıfa atanır. $K = 1$ ise, vaka en yakın komşusunun sınıfına atanır. Ayrıca, üç mesafe ölçüsünün de sadece sürekli değişkenler için geçerlidir. K için en uygun değeri seçmek, verileri inceleyerek yapılır. Genel olarak, büyük bir K değeri, genel sapmaları azalttığı için daha hassastır, ancak bunun garantisi yoktur. Tarihsel olarak, çoğu veri kümesi için en uygun K 3-10 arasında olmuştur. Bu 1NN'den yani K'nin 1 seçildiği bir yapıdan daha iyi sonuçlar vermektedir (Jiang ve Zhou, 2004).

3.2.3. Bu Çalışmada Kullanılan YSA Yapısı



Şekil 3.1. Yapay Sinir Ağı Şematik Gösterimi

Yapay sinir ağları girdi nöronlarının bulunduğu girdi katmanı, girdilerin iletilmesinde kullanılan saklı katmanlar ve tahminin hesaplandığı çıktı katmanından oluşur. Bu katmanlardaki nöron sayısı çalışmalara özel olarak değişkenlik gösterebilmektedir. Giriş bölümünde anlatıldığı üzere bu çalışma üç çeşit girdi içermektedir. Bu girdiler kalite dağılım göstergesi, fire yaratacak kalite hatası adedi ve brüt hata miktarıdır, yani üç adet girdi tipi sınıflandırılmıştır. Yapay sinir ağı tasarlanırken bu girdiler göz önünde bulundurularak 3 adet girdi nöronu kullanılacaktır, çünkü 3 adet girdi tipi bulunmaktadır. Bir adet saklı katman, girdilerin iletilmesi için kullanılmış ve bu katmandaki nöron sayısı üç adet olarak belirlenmiştir. Sistem etkinliği tahmini için çıktı katmanında bir çıktı nöronu kullanılmıştır. Birer çıktı nöronu kullanılmasının sebebi tahmin edilecek özelliğin birer adet olmasındandır. Şekil 3.1 her iki tahmin işlemi için de kullanılacak olan yapay sinir ağının şematik gösterimidir. Şekil 3.1. için KDG: Kalite dağılım göstergesi, FHA: Fire yaratacak kalite hatası adedi, BUM: Brüt üretim miktarıdır.

3.3. Metodoloji: Tahminleme Operasyonu

3.3.1. Yapay Sinir Ağları ile Tahminleme Adımları

Şekil 3.1.'de gösterilen yapay sinir ağının kullanımı Microsoft Office Excel programı yardımıyla açıklanmıştır. Şekil 3.1.'de gösterilen düğümler nöronları, oklar ise nöronlar arasındaki iletişimi sağlayan sinapsisleri temsil etmektedir. Sinapsisler üzerinde şekilde $w_{i,j}$ sembolü ile gösterilen değişkenler sinapsislerin iletişim ağırlığını belirtmektedir. Bu iletişim sayısal tahminlemenin temelini oluşturmaktadır. Tahminleme işlemi 6 adımdan oluşmaktadır. Gerekli adımlar aşağıda açıklandığı gibidir.

1. Adım: Girdi Katmanı Organizasyonu;

Çalışmada N adet girdi grubu kullanılacağını varsayalım. Her girdi grubu 3 adet veri içermektedir bu veriler ikinci bölümde açıklanan hata verileridir bunlara ek olarak bir sütun da bias nöronu verisi için gerekmektedir. Her bir grup bir satıra yerleştirilmelidir. Dolayısıyla N satır ve 4 sütunluk bir bölgeye sinir ağı eğitimi için kullanılacak veriler yerleştirilmelidir. Her satır sinir ağına girdi olarak girilecektir. Bu satır girdiler Şekil 3.1.'deki X_i sembolü ile gösterilmiştir.

2. Adım: Saklı Katman Nöronları Organizasyonu;

Bu çalışmada 3 adet gizli katman nöronu kullanılmıştır. Bu nöronlar N satırlık girdinin her birini bir fonksiyon yardımı ile bir çıktı nöronuna iletecektir. Dolayısıyla her bir saklı katman nöronu için bir hücre gerekmektedir ve bunlara ek olarak bir hücre de bias nöronu için gerekmektedir. Saklı katman nöronlarının olduğu bölgede her bir nöronun işlemlerini temsilen 4 sütun bulunmalıdır.

3. Adım: Çıktı Katmanı Organizasyonu;

Tahmin edilmesi gereken özellik Şekil 3.1.'de Sistem etkinliği (Kalite Kaybı) olarak gösterilmiştir. Tek bir özellik tahmin edileceğinden bir adet çıktı nöronuna ihtiyaç duyulmuştur. N satırlık girdi ve N satırlık nöron işlemlerinin

tahmine dönüştürülmesi için yine N satırlık ve bir sütunluk bir hücre yapısı gerekmektedir.

4. Adım: Sinapsis Ağırlık Değerlerinin Organizasyonu;

Sinapsisler nöronları birbirine bağlayan ve nöronlar arasındaki iletişimi sağlayan matematiksel ağırlık değerleridirler. Girdi katmanındaki 3 sütunluk veriyi ve bir adet bias değerini gizli katmandaki 3 sütunluk nöron işlemlerine bağlamak için 12 adet ağırlık değeri gerekmektedir. Gizli katmandaki 3 adet işlem ve 1 adet bias değerini çıktı nöronuna bağlama için ise 4 adet ağırlık değeri gerekmektedir. Sinapsis ağırlıkları için 4 satırlık ve 4 sütunluk bir hücre yapısına ihtiyaç duyulmaktadır.

5. Adım: Sistem Etkinliği ve Tahmin Hatası Değerlerinin Organizasyonu;

Her girdi grubu sonucu bir adet çıktı değeri oluşmaktadır. Her tahmin için bir adet gerçek fark edilen sistem etkinliği (kalite kaybı) değeri bulunmaktadır. Dolayısıyla tahminler ve hatalar için N satırlık ve iki sütunluk bir hücre yapısı gerekmektedir. Bunlara ek olarak bir hücre de hataların ortalamasını tutmak için gerekmektedir.

6. Adım: Tahminlerin ve Tahmin Hatalarının Elde Edilmesi;

Tahminleme süreci girdi nöronlarına girdi gruplarının girilmesi ile başlamaktadır. Bu girdi değerleri, girdi katmanları ile saklı katman nöronları saklı katman nöronları arasında bulunan ağırlık değerleri ile çarpılır ve bu çarpımlar saklı katman nöronları önünde toplanır. Bu temel bir ağırlıklı toplam işlemidir. Elde edilen ağırlıklı toplamlar iletilen nöronlar tarafından bir fonksiyonun girdisi olarak kullanılır ve bu fonksiyonun çıktı değeri ilgili nöronun çıktı değeridir. Bu çıktı değerleri ilerleyen katmanlara tekrar sinapsisler yardımı ile ağırlıklı toplama işlemleri ve dönüştürme işlemleri tekrarlanarak taşınır. Çıktı katmanında dönüştürülen değerler yapay sinir ağı sisteminin tahminidir. Nöronlar içinde dönüşümü sağlayan fonksiyonlara aktivasyon fonksiyonu denmektedir (Huang and Babri, 1998).

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}^T * \begin{bmatrix} w_{1,1} & w_{1,2} & w_{1,3} \\ w_{2,1} & w_{2,2} & w_{2,3} \\ w_{3,1} & w_{3,2} & w_{3,3} \end{bmatrix} + \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}^T = \begin{bmatrix} z_1 \\ z_2 \\ z_3 \end{bmatrix}^T \quad (3.1)$$

$$\begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix}^T * [w_{a,1,0} \ w_{a,2,0} \ w_{a,3,0}]^T + b_2 = 0 \quad (3.2)$$

Denklem 3.1’de girdi nöronlarından alınan girdilerin saklı katman nöronlarına iletimi matris çarpımı olarak gösterilmiştir. Denklem 3.2’de saklı katman nöronlarının çıktılarının çıktı nöronuna iletimi gösterilmiştir. Şekil 3.1. de belirtilen $A(x)$ fonksiyonu doğrusal aktivasyon fonksiyonudur ve doğrusal aktivasyon fonksiyonun girdisi ve çıktısı eşittir (Myers ve Hutchinson, 1989). Dolayısıyla Denklem 3.1’deki z_j değeri ile a_j değeri birbirine eşittir.

Eğer yapay sinir ağını matematiksel bir model olarak yazmak istersek N satırlık girdiler ve N satırlık sistem etkinliği değerleri değiştirilemeyen parametreler olarak ele alınabilir. Bir yapay sinir ağının eğitimi için gereken değişimin sinapsisler üzerindeki sayısal ağırlıklar olduğunu ele alırsak bu modelin değişkenlerini sinir ağının ağırlıkları olarak ele alabiliriz.

3.3.2. Ortalama Tahmin Hatasının Minimizasyonu ve YSA Eğitimi

Yapay sinir ağlarının tahminlerin kesinliği ortalama tahmin hatasının seviyesi ile ölçülecektir. 6. adımda belirtildiği üzere kullanılan hata ölçme tekniği hataların karesidir ve en küçüklenmesi hedeflenen değer hataların karesinin ortalamasıdır. Hataların karesinin ortalamasının en küçüklenmesinin tahmin kesinliğini artıracak bir etki yaratması beklenmektedir. Hata fonksiyonu hedeflenen değer (gerçekte oluşan sistem etkinliği) ile tahmin edilen değer farkının karesinin alınması ile bulunmuştur. Bu hata değerlerinin ortalaması maliyet fonksiyonu olarak belirlenmiştir. Hata fonksiyonu denklem 3.3, maliyet fonksiyonu ise denklem 3.4’te belirtilmiştir.

$$\text{Hata} = (\text{Hedef} - \text{Tahmin})^2 \quad (3.3)$$

$$\text{Maliyet} = \sum_{k=1}^N \text{Hata}_k * 1/N \quad (3.4)$$

Maliyet fonksiyonun en küçükleme ile tahminin ortalama hatasının en alt düzeye indirilmesi beklenmektedir. Bu işleme yapay sinir ağının eğitimi demektir. Yapay sinir ağlarının eğitilmesinde geri yayılım algoritması kullanılmaktadır (Hecht-Nielsen, 1992).

3. bölümde bahsedilen matematiksel modeli kurmak istediğimizde amaç fonksiyonunu maliyet fonksiyonu olarak belirleyebiliriz. Bu maliyet minimizasyonu matematiksel modeli aşağıda gösterildiği gibidir. Denklem 3.1 ve 3.2'den anlaşılacağı üzere bu doğrusal olmayan en küçükleme bir modelidir.

Setler:

k: veri satırı sayısı 1, 2, 3, ... ,N

i: girdi katmanındaki nöronlar 1,2,3

j: saklı katmandaki nöronlar

Parametreler:

$X_{i,k}$: k satırındaki i'nci girdi

R_k : k satırındaki girdilere ait randıman değeri

Karar Değişkenleri:

$w_{i,j}$: girdi katmanındaki i nöronunu gizli katmandaki j nöronuna bağlayan ağırlık

$w_{j,o}$: gizli katmandaki j nöronunu çıktı katmanındaki çıktı nöronuna bağlayan ağırlık

O_k : k satırındaki girdiler için çıktı nöronunun tahmini

$z_{j,k}$: k satırı için gizli katmandaki j nöronunun çıktısı

b_1 = girdi katmanının sapması

b_2 = gizli katmanın sapması

Model:

$$\text{Enküçükle } z = \frac{1}{N} * \sum_{k=1}^N (R_k - O_k)^2$$

Öyle ki;

$$\begin{bmatrix} x_{1,k} \\ x_{2,k} \\ x_{3,k} \end{bmatrix}^T * \begin{bmatrix} w_{1,1} & w_{1,2} & w_{1,3} \\ w_{2,1} & w_{2,2} & w_{2,3} \\ w_{3,1} & w_{3,2} & w_{3,3} \end{bmatrix}^T + b_1 = \begin{bmatrix} z_{1,k} \\ z_{2,k} \\ z_{3,k} \end{bmatrix}^T \quad \text{Her } k = 1, 2, 3, \dots, N. \quad (3.5)$$

$$\begin{bmatrix} z_{1,k} \\ z_{2,k} \\ z_{3,k} \end{bmatrix}^T * [w_{1,0} \ w_{2,0} \ w_{3,0}]^T + b_2 = O_k \quad \text{Her } k = 1, 2, 3, \dots, N. \quad (3.6)$$

$z_{j,k}$: sınırlandırılmamış değişken	Her $k = 1, 2, 3, \dots, N$. ve Her $j = 1, 2, 3$
$O_k \geq 0$	Her $k = 1, 2, 3, \dots, N$.
$w_{i,j}$: sınırlandırılmamış değişken	Her $i = 1, 2, 3$. ve Her $j = 1, 2, 3$
$w_{j,0}$: sınırlandırılmamış değişken	Her $j = 1, 2, 3$

Bahsedilen modelde amaç fonksiyonu tahmin hatalarının karelerinin ortalamasının en küçüklenmesi, kısıt 3.5 gizli katman nöronlarının çıktılarının hesaplanması ve kısıt 3.6 ise çıktı katmanının çıktısının (tahminin) hesaplanmasıdır.

3.3.3. KNN Algoritması ile Sistem Etkinliği Tahmini

En yakın komşu sezgiseli bu çalışmada sistem etkinliği tahmini için kullanılmıştır. K-En yakın komşu algoritması tahmin için kullanılacak olan veri grubunun veri tabanındaki verilere olan Öklid mesafesi, hipotenüs cinsinden yakınlığını test etmektedir. Bu algoritma ile yapılan tahmin metodu tahmin edilecek olan veri grubuna özellik bakımından en yakın veri tabanındaki K'ıncı sıradaki veri grubuna kadar olan çıktı değerlerini tahmin olarak vermektedir. Bu çalışmada tek bir tahmin istendiğinden bu algoritma kullanımı esnasında çalışmaya göre modifiye edilmiştir. Bu modifikasyon aşağıda gösterildiği gibidir;

1_k : tahmini yapılacak olan veri grubuna en yakın grubun çıktısı

2_k : tahmini yapılacak olan veri grubuna en yakın 2. grubun çıktısı

3_k : tahmini yapılacak olan veri grubuna en yakın 3. grubun çıktısı

...

5_k : tahmini yapılacak olan veri grubuna en yakın 5. grubun çıktısı

K_k : tahmini yapılacak olan veri grubuna en yakın K. grubun çıktısı

T_k : Elde edilen tahmin

$$T_k = \sum_k k/15 * K_k \quad (3.7)$$

Yukarıdaki formülizasyonda gösterildiği üzere algoritmanın K adet tahmini ağırlıklı toplam kullanılarak 1 adet tahmine indirgenmiştir.



4. BULGULAR

Örnek uygulamanın yapıldığı üretim tesisi 3 farklı bölümden oluşmaktadır. Birinci bölümde ergitme ikinci bölümde şekillendirme ve üçüncü bölümü olan işleme tesisinde optimizasyon, kesim ve paketleme yapılmaktadır. İşletmenin üretim takip raporları incelenerek çalışmada kullanılacak veri setleri elde edilmiştir. Örnek uygulamanın yapıldığı işletme 7 gün 24 saat günde 3 vardiya ile üretime ara vermeden çalışan bir üretim tesisi olması nedeni ile üretim raporlarından yaklaşık 21 aylık süreçte oluşan 1950 veriye ulaşılmıştır.

Elde edilen veriler analiz edildiğinde, verimliliği doğrudan etkileyen faktörlerin aşağıdaki gibi olduğu tespit edilmiştir;

- Brüt Üretim Miktarı
- Kalite Dağılım Göstergesi
- Fire Yaratacak Kalite Hatası Sayısı
- Üretim Kaynaklı Kayıplar
- İkincil İşlem Kaynaklı Kayıpları
- Arıza Kayıpları

Verimlilik üretim tesisinde her periyod için (Net Üretim) / (Brüt Üretim Miktarı) olarak hesaplanmaktadır. Brüt üretim miktarı ile net üretim arasındaki fark verimliliği diğer bir göstergesi olarak ifade edildiğinde bu farkı oluşturan etmenlerin iyileştirilmesi durumunda doğrudan verimliliği ve üretkenliği artacaktır.

Brüt üretim miktarı üretim tesisinin ergitme ve şekillendirme bölümleri tarafından işleme tesisinden bağımsız olarak üretim süreci sırasında değiştirilebilmektedir. Brüt üretim miktarının artması kalite problemi yaratmadığı sürece üretim tesisi için maliyetlerin azalması, satışların ve karlılığın artması yönünde olumlu etki göstermektedir. Brüt üretim miktarının yapılan çalışmada girdi-

veri olarak kullanılması verimliliği doğrudan etkilemesi nedeni ile uygun bulunmuştur.

Kalite dağılım göstergesi ergitme ve şekillendirme prosesinden, işleme prosesine gelen yarı mamulün kesim parametrelerinin eniyilemesi sırasında otomatik sistemlerle tespit edilen ve kalite kaybına neden olabilen hataların toplam üretim miktarına oranı olarak ifade edilebilir. Kalite dağılım göstergesi yapılan çalışmada girdi-veri olarak kullanılması verimliliği doğrudan etkilemesi nedeni ile uygun bulunmuştur.

Fire yaratacak kalite hatası kayıpları parametre eniyilemesi sırasında tespit edildiğinde, bu eniyilemeye bağlı olarak işlem yapan makine ilgili alanı doğrudan fireye ayırmakta ve bu tür hata sayısına bağlı olarak kalite kaybı artmakta ve azalmaktadır. Fire yaratacak kalite hatası kayıpları yapılan çalışmada girdi-veri olarak kullanılması verimliliği doğrudan etkilemesi nedeni ile uygun bulunmuştur.

Üretim kaynaklı kayıpların, ergitme ve şekillendirme prosesinin bir gerekliliği olması ve muhtelif zamanlarda oluşması nedeni ile çalışma kapsamında girdi-veri olarak kullanılması uygun görülmemiştir.

İkincil işlem kaynaklı kayıpların, işleme prosesinin bir gerekliliği olması ve muhtelif zamanlarda oluşması nedeni ile çalışma kapsamında girdi-veri olarak kullanılması uygun görülmemiştir.

Arıza kaynaklı kayıpların, üretim prosesinin tamamı için bir problem olması ve muhtelif zamanlarda oluşması nedeni ile çalışma kapsamında girdi-veri olarak kullanılması uygun görülmemiştir.

Çalışmanın amacı; girdi-veri olarak kullanılan verilerin kalite kaybına etkisi arasında matematiksel ilişkinin kurulması ve böylece farklı girdi-veri oluştuğunda kalite kaybının tahmin edilmesidir. Çalışma kapsamında fiili veriler sisteme dahil edilmiş olup bir sonraki tahminlemede kullanılması sağlanarak sürekli öğrenen bir sistem kurulmuştur.

Kalite kaybının önceki verilere göre tahmin edilebilmesi sayesinde ise tahmini kalite kaybının fiili kalite kaybı ile kıyaslanması mümkün hale getirilmiş ve

bu kıyaslama ile birlikte üretim hattında görevli personelin performans değerlendirme sistemi için veri oluşturulmuştur. Çalışmada YSA ve KNN metotları ile ilgili detaylı literatür araştırması yapılmış olup örnek uygulamada kalite kaybı her iki yöntemle de tahminlenmiştir.

4.1. Yapay Sinir Ağları Çözümü

YSA'nın çözümü için tanımlanan 6 adım bu çalışmada uygulanmış ve Excel Hesap Çizelgeleri üzerinden bu 6 adım için bir ara yüz oluşturulmuştur.

1. Adım: Çalışmada 1950 adet girdi grubu kullanılmıştır. Bu adımda 1950 satır 3 sütunluk bir hücre grubu ayrılmalıdır. Bu yapı aşağıda Çizelge 4.1.'de gösterilmiştir. Bu yapıdaki değerler YSA'nın girdi nöronlarının alacağı değerlerdir. Çizelge 4.1.'deki KDG: Kalite Dağılım Göstergesi, FHA: Fire Yaratacak Kalite Hatası Adedi, BU: Brüt Üretim Miktarıdır.

Çizelge 4.1. Kullanılan 3 Sütünlük Hücre Grubu Yapısı

	A	B	C	D
	No	Kalite Dağılım Göstergesi	Fire Yaratacak Kalite Hatası Sayısı	Brüt Üretim Miktarı
1				
2	1	3,89	279	309,5
3	2	3,96	255	306,6
4	3	3,87	283	309,0
5	4	3,83	289	310,0
6	5	3,88	218	307,7
7	6	3,81	202	308,1
8	7	3,87	213	309,4
9	8	4,16	252	309,9
10	9	4,65	280	310,9
11	10	4,65	205	309,7
12	11	4,64	244	308,7
13	12	5,04	289	308,6
14	13	5,29	282	308,5
15	14	4,71	209	308,8
16	15	3,83	177	307,2
17	16	3,64	201	307,9
18	17	4,13	232	309,4
19	18	4,88	206	309,5
20	19	15,85	216	309,5
21	20	13,67	199	310,2
22	21	5,86	187	309,6

2. Adım: Bu adımda saklı katman nöronları için bir hücre yapısı kararlaştırılmıştır. 3 adet gizli katman nöronumuz bulunduğu için 3 sütun yer ayrılmış ve bu sütunlar da 1950 satır boyunca devam etmiştir. 1 adet hücre ise “K” sütununda bias nöronu için ayrılmıştır. Bu yapı aşağıdaki Çizelge 4.2.’ de gösterilmiştir. Bu hücrelerdeki formüller şu şekildedir:

$$\text{SUMPRODUCT}(B2:D2; \$E\$2: \$G\$2) \quad (4.1)$$

“B2:D2” hücre aralığı 1. adımda girilen girdilerin değerlerini almakta ve 3. adımda anlatılacak olan sabit ağırlıklarla çarpılmaktadır. “E2:G2” aralığı 3. adımda

gösterilen ağırlık hücreleridir. Bu işlem bir bakımdan ağırlıklı toplama işlemidir (Myers ve Hutchinson, 1989).

Çizelge 4.2. Saklı Katman Nöronlarının Hücre Grubu Yapısı

H	I	J	K
Noron 1	Noron 2	Noron 3	Bias Noronu
-152,475	-23,867	-350,959	1
-145,746	-32,815	-342,439	
-153,328	-21,903	-351,461	
-155,078	-19,813	-353,842	
-136,875	-49,530	-334,641	
-133,011	-56,749	-331,203	
-136,077	-52,508	-334,970	
-145,924	-35,541	-344,726	
-153,184	-23,372	-352,150	
-134,266	-55,381	-332,980	
-143,662	-37,955	-341,435	
-154,841	-17,973	-352,009	
-153,108	-20,727	-350,123	
-135,010	-53,129	-333,042	
-126,562	-67,139	-324,303	

3. Adım: 2. adımda oluşturulan nöronlar 1. adımda girilmiş olan girdiler ile bağlanmalıdırlar. Bu bağlanma eylemi sinapsisler aracılığı ile gerçekleştirilir ve her sinapsisin bir ağırlık değeri vardır. Bu adımda ise ağırlıkların hücre yapısı oluşturulmuştur. Bu adım uygulandıktan sonra 2. adımdaki formül incelendiğinde aslında 2. adımda yapılan işlemin bir ağırlıklı toplam işlemi olduğu daha net anlaşılmaktadır.

4. Adım: 3. adımda oluşturulan ağırlıkların değer alması bu adımda gerçekleşmektedir. Ağırlıklara ilk değerler rastgele verilmektedir. Yukarıdaki Çizelge 4.3.' deki hücrelerdeki formül şu şekildedir:

$$= \text{RAND}() * 2 - 1 \quad (4.2)$$

Çizelge 4.3. Ağırlıklara Değer Verilmesi

E	F	G
W1	W2	W3
-0,11040	-0,24799	-0,26772
W1	W2	W3
0,97136	0,43444	-0,48097
W1	W2	W3
0,46000	-0,24093	-0,92259
W1	W2	W3
0,12266	0,03888	-0,05579
		W-BIAS
		1,02744

Ağırlıklar ilk aşamada rastgele verilmekte ve hata minimizasyonu ile değiştirilmektedir (Hecht-Nielsen. 1992).

5. Adım: Sistem Etkinliği (Kalite Kaybı) Çıktı Değerlerinin ve Gerçek Sistem Etkinliği Değerlerinin Organizasyonu: 5. adımda anlatıldığı gibi 1950 satırlık ve 2 sütunluk yapı burada oluşturulmuştur. Aşağıda Çizelge 4.4’de görünen “L” sütunundaki formülün bir örneği şu şekildedir:

$$\text{SUMPRODUCT}(\$E\$8:\$G\$8; H2: J2) + \$K\$2 * \$G\$10 \quad (4.3)$$

Bu formüldeki “E8:G8” aralığı gizli katman nöronlarını çıktı nöronuna bağlayan ağırlıklar, “H2:J2” aralığı ise 2. Adımda Çizelge 4.2.’de gösterilen nöron hücrelerinin değerleridir. “+K2*G10” ifadesi ise bias nöronu ile Çizelge 4.3.’te görülen “W-BIAS” bias ağırlığının çıktıya katkısıdır. Yani “L” sütunundaki değerler çıktı nöronun değerleridir. Bu değerleri gerçek değerler ile karşılaştırmak için hemen yanına “M” sütununa gerçek sistem etkinliği değerleri yerleştirilmiştir.

Çizelge 4.4. Fiili ve Tahmin Edilen Kalite Kaybı Değerlerinin Gösterilmesi

L	M
Y:Tahmin	Hedef
0,9758	0,9755
0,9780	0,9775
0,9755	0,9751
0,9749	0,9747
0,9814	0,9810
0,9829	0,9825
0,9817	0,9815
0,9778	0,9776
0,9745	0,9744
0,9813	0,9811
0,9779	0,9774

6. Adım: Tahmin Hatalarının Elde Edilmesi: Bu adımda 5. adımda görülen tahmin değerleri ile hedef (gerçek verimlilik değerleri) karşılaştırılmış ve hatalar hesaplanmıştır. Aşağıda Çizelge 4.5.’de görülen hücre yapısı bu adım için oluşturulmuştur. Hata hesabı için örnek bir formül şu şekildedir:

$$(M2 - L2)^2 \quad (4.4)$$

Bu formül “N2” hücresine yerleştirilmiş ve yukarıda Çizelge 4.4.’de görülen “M” ve “L” sütunlarının farklarının karesini yani hatanın karesini hesaplamaktadır. “O2” hücresindeki ortalama hata hücresi ise 1950 satırlık tahminlerin hatalarının ortalamasıdır. Bu çalışmada en küçüklenmesi hedeflenen değer burada oluşmaktadır.

Çizelge 4. 5. Tahmin Hatalarının Tespit Edilmesi

L	M	N	O
Y:Tahmin	Hedef	FarkxFark	(FarkxFark) Ortalama
0,9758	0,9755	0,000000060	0,000002227
0,9780	0,9775	0,000000217	
0,9755	0,9751	0,000000114	
0,9749	0,9747	0,000000060	
0,9814	0,9810	0,000000140	
0,9829	0,9825	0,000000152	
0,9817	0,9815	0,000000053	
0,9778	0,9776	0,000000034	
0,9745	0,9744	0,000000004	
0,9813	0,9811	0,000000040	
0,9779	0,9774	0,000000179	
0,9733	0,9729	0,000000113	


Tüm veriler gereken formüller ile hücrelere yerleştirildikten sonra hatanın en küçüklenmesi adımı gelmektedir. Ek 1’de görülebileceği gibi yukarıda anlatılan tüm adımlar tek bir tabloda formülize edilerek gösterilmiştir. En küçükleme ile tahminin tamamlanması 4.2 Excel Solver bölümünde anlatılmıştır.

4.2. Excel Solver Çözümü

3.2.2’nci bölümde bahsedilen en küçükleme modeli aynı zamanda 4.1’inci bölümde anlatılan YSA çözümü için MS Excel Solver kullanılabilir. Excel’in doğrusal olmayan modelleri çözen modülü GRG-Nonlinear’dır. Bu çalışmada GRG-Nonlinear Solver kullanılacaktır. GRG-Nonlinear Solver kullanımı kullanılırken dikkat edilmesi gereken unsur, kullanımında bir ödünleşim bulunduğudur. Bu ödünleşim kurulan modelin değişken sayısı ile GRG-Nonlinear Solver çözücünün çözüm kapasitesi ve optimal sonuca ulaşabilmesi arasındadır. Modelin değişken sayısı arttıkça çözümün global optimale ulaşabilmesi için gereken süre uzamaktadır ya da verilen çözüm lokal bir optimale takılmıştır. 3.2.2’nci bölümde YSA (yapay

sinir ağırları) modelinde bahsedilen modelimizin değişkenlerini göz önünde bulundurduğumuzda, sinapsis ve buna bağlı nöron sayısının artması elde edilen çözümün global optimal olup olmadığının sorgulanmasını gerektirebilir (Ravinder, 2013).

YSA modelinin eğitimi ve optimal sinapsis ağırlıklarının bulunması için Excel Solver kullanımı aşağıda Şekil 4.1.'de gösterildiği gibidir.



Şekil 4.1. YSA Modelinin Eğitimi İçin MS Excel Solver Kullanımı

İlk adım Çizelge 4.5.'da gösterilen ortalama hatanın amaç fonksiyonu olarak seçilmesidir. 2. adım değişken olarak sinapsis ağırlıklarının seçilmesidir. "By Changing Variable Cells:" kısmındaki hücreler daha önceden Çizelge 4.3.'te gösterilen sinapsis ağırlıklarıdır. Bu adıma başlamadan önce sinapsis ağırlıkları

rasgele belirlenmelidir. 3. adım ise solver seçimidir. Daha önce bahsedildiği üzere bu çalışmada GRG-Nonlinear Solver kullanılmıştır.

4.3. Yapay Sinir Ağları ile Tahmin

Tahminleme yapmadan önce çalışmada baz alınan Ek 1’de B, C, D sütunlarındaki girdi değerlerine göre oluşan fiili kalite kaybı değerleri Q sütununda verilmiştir. Solver çalıştırılmadan önce girdi katmanını gizli katmana bağlayan nöronlar, $= \text{RAND}() * 2 - 1$ formülüne göre rastgele seçilmişlerdir. Çizelge 4.8.’da gizli katman nöronlarının çıktısı, Çizelge 4.9.’da gizli katman nöronlarını çıktı nöronuna bağlayan ağırlıklar ve Çizelge 4.10.’de ise YSA tahmini, tahmin hatasının karesi ve hataların karesinin ortalaması görülmektedir. Bu değerler nöronların eğitimleri öncesi durum için gösterilmiştir.

Çizelge 4.6. Girdi Örnekleri

	A	B	C	D	M
	No	Kalite Dağılım Göstergesi	Fire Yaratacak Kalite Hatası Sayısı	Brüt Üretim Miktarı	Hedef
1					
2	1	3,89	279	309,5	0,9755
3	2	3,96	255	306,6	0,9775
4	3	3,87	283	309,0	0,9751
5	4	3,83	289	310,0	0,9747
6	5	3,88	218	307,7	0,9810
7	6	3,81	202	308,1	0,9825
8	7	3,87	213	309,4	0,9815
9	8	4,16	252	309,9	0,9776
10	9	4,65	280	310,9	0,9744
11	10	4,65	205	309,7	0,9811
12	11	4,64	244	308,7	0,9774
13	12	5,04	289	308,6	0,9729

Çizelge 4.7. Girdi Katmanını Gizli Katmana Bağlayan Eğitim Öncesi Rastgele Verilmiş Nöronlar

E	F	G
W1	W2	W3
-0,91132	-0,51648	0,04409
W1	W2	W3
-0,85361	-0,19605	-0,14461
W1	W2	W3
0,17014	0,79861	0,14709

Çizelge 4.8. Girilen Girdiler ve Rasgele Verilmiş Ağırlıklar İçin 3 Gizli Katman Nöronunun Çıktıları

H	I	J	K
Nöron 1	Nöron 2	Nöron 3	Bias Nöronu
-271,103	136,152	170,553	1
-267,626	137,542	165,762	
-270,840	135,374	170,941	
-271,945	135,153	172,230	
-267,215	142,656	160,570	
-266,984	144,797	158,266	
-268,430	144,160	160,477	
-270,233	139,857	166,799	
-271,852	137,264	171,759	
-267,890	145,796	159,887	
-268,561	140,461	165,386	
-269,997	135,152	172,434	
-269,485	136,113	171,492	
-267,204	144,830	160,147	

Çizelge 4.9. Gizli Katman Nöronlarını Çıktı Nöronlarına Bağlayan Rastgele Verilmiş Ağırlıklar

E	F	G
W1	W2	W3
-0,68132	-0,18273	-0,14951
		W-BIAS
		-0,09770

Çizelge 4.10. YSA Tahmin Hatasının Gösterilmesi

L	M	N	O
Y:Tahmin	Hedef	FarkxFark	(FarkxFark) Ortalama
-122,0490	0,9755	15135,0444	1186759,664
-108,1047	0,9775	11898,9344	
-124,5180	0,9751	15748,5388	
-127,9772	0,9747	16628,5804	
-85,8848	0,9810	7545,6554	
-76,3042	0,9825	5973,2330	
-82,6699	0,9815	6997,5435	
-105,7507	0,9776	11390,9249	
-122,1139	0,9744	15150,7427	
-77,5066	0,9811	6160,3068	
-100,9394	0,9774	10387,0385	
-127,6427	0,9729	16541,9755	

MS Excel Solver ile ağırlıklar ve bias değerleri optimal tahmini verecek şekilde değiştirildiğinde yeni bias değeri 1,02744 değerini almıştır. Ağırlıkların yeni değerleri ise Çizelge 4.11.'de görülmektedir.

Çizelge 4.11. Eğitim Sonrası Ağırlık Değerleri

E	F	G
W1	W2	W3
-0,11040	-0,24799	-0,26772
W1	W2	W3
0,97136	0,43444	-0,48097
W1	W2	W3
0,46000	-0,24093	-0,92259
W1	W2	W3
0,12266	0,03888	-0,05579
		W-BIAS
		1,02744

Değişen ağırlıklar ve bias değerleri için gizli katman nöronlarının çıktıları Çizelge 4.12.'de gösterilmiştir. Bu ağırlıklar ve yeni bias değerleri için oluşan tahminler, tahmin hatasının karesi ve hataların karesinin ortalaması değerleri ise Çizelge 4.13.'te bulunmaktadır.


Çizelge 4.12. Eğitim Sonrası Gizli Katman Nöronları Çıktıları

H	I	J	K
Noron 1	Noron 2	Noron 3	Bias Noronu
-152,475	-23,867	-350,959	1
-145,746	-32,815	-342,439	
-153,328	-21,903	-351,461	
-155,078	-19,813	-353,842	
-136,875	-49,530	-334,641	
-133,011	-56,749	-331,203	
-136,077	-52,508	-334,970	
-145,924	-35,541	-344,726	
-153,184	-23,372	-352,150	
-134,266	-55,381	-332,980	
-143,662	-37,955	-341,435	
-154,841	-17,973	-352,009	
-153,108	-20,727	-350,123	


Çizelge 4.13. Eğitim Sonrası Tahminler

L	M	N	O	Q
Y:Tahmin	Hedef	Farkx Fark	(Farkx Fark) Ortalama	Fiili Kalite Kaybı
0,9758	0,9755	0,00000006	0,000002227	2,448
0,9780	0,9775	0,00000022		2,246
0,9755	0,9751	0,00000011		2,487
0,9749	0,9747	0,00000006		2,532
0,9814	0,9810	0,00000014		1,902
0,9829	0,9825	0,00000015		1,753
0,9817	0,9815	0,00000005		1,853
0,9778	0,9776	0,00000003		2,242
0,9745	0,9744	0,00000000		2,558
0,9813	0,9811	0,00000004		1,893
0,9779	0,9774	0,00000018		2,256

Çizelge 4.10. ve Çizelge 4.13. karşılaştırıldığında tahmin hatalarının karelerinin ortalamaları 141215,718'den 0,000002227'e düşmüştür. Şekil 4.2 ve Şekil 4.3 eğitim öncesi ve sonrası tahminlerin durumunu göstermektedir.



Şekil 4.2. Eğitim Öncesi Fiili ve Tahmini Sistem Etkinliği Değerleri
Turuncu: Fiili Değerler, Mavi: Tahminler



Şekil 4.3. Eğitim Sonrası Fiili ve Tahmini Sistem Etkinliği Değerleri
Turuncu: Fiili Değerler, Mavi: Tahminler

Tahmin MS Excel Solver ile hata minimizasyonu öncesindeki tahminleri ve gerçek sistem etkinliği değerlerini gösteren Şekil 4.2’de görüldüğü üzere, istenilen tahmin değerlerinin 0 ile 1 (%0 ile 100%) arasında olması gerekirken eğitilmemiş YSA tahminleri 1(%100) değerinin üzerinde göstermiştir. Matematiksel olarak imkânsız sistem etkinliği değerlerini tahmin olarak sunmuştur. Hatta tahmin değerlerinin (mavi renk) 200’ün üzerinde bir eğilim gösterdiği söylenebilir ki bu imkânsız bir sistem etkinliği değeridir. Sistem etkinliği 0 ile %100 arasında olmaktadır. Şekil 4.2’de gerçek sistem etkinliği değerleri (turuncu renk) tam olarak gözlemlenemese de aradaki farkın çokluğu gözden kaçmamaktadır. Gerçek sistem etkinliği değerlerini görmek için Şekil 4.2 incelenebilir.

Şekil 4.3’e baktığımızda tahmini verimlilik değerleri (mavi renk) fiili verimlilik değerlerine (turuncu renk) yaklaşmışlardır. Şekil 4.2’de görülen tahminler ile fiili verimlilik değerleri karşılaştırıldığında ortalama tahmin hatası 141215,718 iken Şekil 4.3’de eğitim sonrası durumda ortalama tahmin hatası 0,000002227’ye düşmüştür.

4.4. KNN Uygulanması

KNN uygulaması için gereken adımlar YSA için gereken adımlar ile benzerlik göstermektedir. İlk adım verilerin girileceği bir girdi hücresi grubu oluşturmaktır. Bu adımdaki girdilerimiz, hedef değerler olan sistem etkinliği, kalite dağılım göstergesi, fire yaratacak kalite adedi ve brüt üretim miktarıdır.

1.Adım: Bu adımda 1950 satır ve 4 sütunluk veri grubu için bir hücre grubu ayrılmıştır. Bölüm 3.2.3'te de anlatıldığı gibi bu 4 sütunluk veri grubunun 3 ü yakınlık (mesafe) hesaplaması için kullanılacaktır. Bu adım içi oluşturulan hücre yapısı aşağıda Çizelge 4.1.'de gösterilmişti aynı veriler KNN tahminlemesinde de kullanılmıştır. Çizelge 4.14.'de KNN tahminleme metodunun tüm adımları tek bir tabloda formülize edilerek gösterilmiştir.

En yakın komşu sezgiseli bu çalışmada sistem etkinliği tahmini için kullanılmıştır. En yakın komşu algoritması tahmin için kullanılacak olan veri grubunun veri tabanındaki verilere olan Öklid mesafesi, hipotenüs cinsinden yakınlığını test etmektedir. Bu algoritma ile yapılan tahmin metodu tahmin edilecek olan veri grubuna özellik bakımından en yakın veri tabanındaki 5'inci sıradaki veri grubuna kadar olan çıktı değerlerini tahmin olarak vermektedir. 5 adet tahmini ağırlıklı toplam kullanılarak 1 adet tahmine aşağıdaki Çizelge 4.14.'de formülleri görüldüğü şekle indirgenmiştir.

Çizelge 4.14. İndirgenmiş Tahmin Çizelgesi

	B	C	D	E	F	I	J	L	M	N	O	P	Q	R	S
2	Tüm Dataların KNN Optimizasyonu														
3		Kalite Dağılım Göstergesi	Fire Yaratacak Kalite Hatası Sayısı	Brüt Üretim Miktarı	Kalite Kaybı			Mesafeler	Rank	Kalite Kaybı	K Değeri	Hata Yüzdesi	Ağırlıklı Ortalama		Tahmini Kalite Kaybı %
4		3,89	279	309,5	2,448	Sorgu		24,1786	128	2,448	1,000	2,246	0,333		2,1866
5		3,96	255	306,6	2,246	HY	3,96	0,0000	1	2,246	2,000	2,009	0,267		
6		3,87	283	309,0	2,487	K5	255,0	28,1047	164	2,487	3,000	2,287	0,200		
7		3,83	289	310,0	2,532	BRUT	306,6	34,1714	279	2,532	4,000	2,289	0,133		
8		3,88	218	307,7	1,902			37,0186	327	1,902	5,000	2,096	0,067		
9		3,81	202	308,1	1,753			53,0240	597	1,753		Toplam	1,000		
10		3,87	213	309,4	1,853			42,0951	408	1,853					
11		4,16	252	309,9	2,242			4,5103	9	2,242					
12		4,65	280	310,9	2,558			25,3836	140	2,558					
13		4,65	205	309,7	1,893			50,1038	545	1,893					
14		4,64	244	308,7	2,256			11,2238	35	2,256					
15		5,04	289	308,6	2,706			34,0778	274	2,706					

2.Adım: Çizelge 4.14.'de önceki verilere göre yeni oluşan şartlar için tahminlemenin nasıl yapıldığı detaylı olarak KNN metoduna göre gösterilmiştir. 1950 adetlik veri grubunun KNN ve YSA metotları ile elde edilen kalite kaybı tahminlemelerindeki sapmaların kıyaslanabilmesi için tahminleme algoritmasının kurulması gerekmektedir. Bu algoritma Excel Macro VBA ile kodlanmıştır. 2. adımın ilk safhası mesafe hesaplama adıdır. Mesafenin hesaplanması aşağıda denklem 4.3.1' de gösterilmiştir.

KDG: Kalite Dağılım Göstergesi

FHA: Fire Yaratacak Kalite Hatası Adedi


BUM: Brüt Üretim Miktarı

Mesafe (4.3.1)

$$= \sqrt{(KDG_{\text{test}} - KDG_{\text{veri}})^2 + (FHA_{\text{test}} - FHA_{\text{veri}})^2 + (BUM_{\text{test}} - BUM_{\text{veri}})^2}$$

Bu mesafe hesabında kullanılan yöntem Öklid mesafesi yöntemidir (Jiang ve Zhou, 2004). Test grubundaki her bir verinin, veri grubundaki her bir veriye olan uzaklığı hesaplanmalı ve en yakın olan K adet verinin verimliliği kaydedilmelidir. Bu çalışmada K değeri 5 olarak seçildiği daha önce belirtilmişti. 5 adet en yakın verinin kalite kayıpları Bölüm 3.2.3'te anlatıldığı gibi $T_k = \sum_{k=1}^K K_k$ (3.3.3)

denklemleri ile tek bir tahmine indirgenmiştir. Çalışma için Yazılan ve Ek 4’de detayları verilen VBA kodları için kurulan algoritmanın yapay kodu aşağıdaki Şekil 4.2’deki gibidir.



Şekil 4.4. KNN Algoritması İçin Yazılan Kodlar

Şekil 4.2.’deki gibi hazırlanan algoritmanın Excel Macro VBA kodları EK-1 de verilmiştir.

Yukarıda görüldüğü üzere kurulan modülde, verilerin yakınlığının test edilmesi, mesafelerin hesaplanması ve tahminleme için kullanılan değişkenler sıfırlanmış ya da gereken değerleri almışlardır. Ardından mesafeler hesaplanmıştır. Hesaplanan mesafelerin yakınlıkları sınanmış ve en yakın 5 adet veri bulunup kaydedilene kadar bu işlem devam etmiştir. En yakın (K adet veri satırı) 5 adet veri satırı bulunduktan sonra tahminleme yapılmıştır. Bu işlem 1950 adetlik test verisinin her birinin tahminlemesi bitene kadar devam etmiştir. Aşağıda Çizelge 4.15’de yukarıdaki yapay kodun çalışması sonucu ortaya çıkan tahminleme değerleri görülmektedir.

Aşağıdaki Çizelge 4.15’de görülen ortalama hata tahminleme performansdır. Tahminlemenin uygulaması ve performansı Bölüm 4.5’te açıklanmıştır.

Çizelge 4.15. Ortalama Hata Tahminleme Performansı

No	Kalite Kaybı	Kalite Dağılım Göstergesi	Fıe Yaratacak Kalite Hatası Sayısı	Brüt Üretim Miktarı	KNN Tahminle	Test Verileri	Kalite Dağılım Göstergesi	Fıe Yaratacak Kalite Hatası Sayısı	Brüt Üretim Miktarı	Kalite Kaybı	Kalite Kaybı Tahmini	Fark x Fark	(Farkx Fark) Ortalama
1	2,448	3,89	279	309,5		1	3,89	279	309,5	2,448	2,449	0,0000	31,411
2	2,246	3,96	255	306,6		2	3,96	255	306,6	2,246	2,187	0,0035	
3	2,487	3,87	283	309,0		3	3,87	283	309,0	2,487	2,512	0,0006	
4	2,532	3,83	289	310,0		4	3,83	289	310,0	2,532	2,495	0,0014	
5	1,902	3,88	218	307,7		5	3,88	218	307,7	1,902	1,821	0,0065	
6	1,753	3,81	202	308,1		6	3,81	202	308,1	1,753	1,723	0,0009	
7	1,853	3,87	213	309,4		7	3,87	213	309,4	1,853	1,800	0,0028	
8	2,242	4,16	252	309,9		8	4,16	252	309,9	2,242	2,126	0,0135	
9	2,558	4,65	280	310,9		9	4,65	280	310,9	2,558	2,534	0,0006	
10	1,893	4,65	205	309,7		10	4,65	205	309,7	1,893	1,865	0,0008	
11	2,256	4,64	244	308,7		11	4,64	244	308,7	2,256	2,182	0,0055	

1950 veri baz alınarak YSA ve KNN metotları ile yapılan kalite kaybı tahminlemedeki fiili kalite kaybı değeri ile tahmin edilen kalite kaybı değerlerinin farklarının karelerinin ortalamaları arasında çok ciddi farklılık olduğu gözlemlenmiştir. YSA ile yapılan tahminlemede 0,000854 olarak hesaplanan bu değer KNN metodu ile yapılan tahminlemede 31,411 olarak hesaplanmıştır. Sadece bu verilere bakarak bu iki yöntemi kıyaslamak bu iki tahmin metodunun çok farklı sistematlere dayalı tahmin yapmaları nedeni ile doğru bir değerlendirme olmayacaktır. Daha doğru bir değerlendirme yapabilmek için çalışmada kullanılan tüm veriler büyük sapma yaratan verilerin tüm veri grubundan ayıklanması için K-Means metodu ile üçlü ve dördütlü gruplara ayrılmıştır. 4 ve 3 gruba ayrılan işlenmiş veriler YSA ve KNN metotları çalışmada anlatılan yöntemler ile yeniden test edilmiş olup Çizelge 4.16.'da sonuçlar tabloda gösterilmiştir.

Çizelge 4.16. Ortalama Sapma Değerleri

	YSA Testi	KNN Testi
Tüm Veri	0,000002227	31,411
K Means 3 Grup	0,000000068	0,012
K Means 4 Grup	0,000000012	0,020

Çizelge 4.16. incelendiğinde işlenen verilerle yapılan testlerde YSA metodu ile yapılan tahminlerin KNN metodu ile yapılan tahminlerden çok daha iyi sonuç verdiği net olarak anlaşılmaktadır. YSA metodu ile yapılan tahminlemede ise en iyi sonucun K-Means metodu ile 4 gruba ayrılan verilerden elde edildiği anlaşılmaktadır.

4.5. Yöntemlerin Karşılaştırılması

KNN uygulanması 200 satırlık bir test veri grubu üzerinde gerçekleştirilmiştir. YSA eğitimi ise 1950 satırlık bir eğitim veri seti içinde sağlanmıştır. KNN eğitim gerektirmeyen bir yöntem olup YSA'nın eğitim gerektiren bir yöntem olmasından dolayı, YSA'nın eğitimi için kullanılan 1950 satırlık veri grubu üzerinden karşılaştırma yapmak YSA'nın lehine sonuçlanabilirken KNN'nin aleyhine olabilir. Fakat 200 satırlık test grubunda ikisini de karşılaştırmak iki yöntem için de daha doğru bir karşılaştırma olacaktır. Literatürde yapay zekâ tahmin metodlarının performanslarının sınanması için ayrı bir test verisi setinin tutulması yaygın olarak görülmektedir (Ataseven, 2013; Nielsel, 1989; Hodges ve ark, 2014; Jiang ve Zhou, 2004).

4.5.1. Test Veri Seti için YSA Hata Performansı

Bu çalışmada YSA 1950 satırlık bir veri seti ile eğitilmiştir. 200 satırlık hiç eğitilmediği bir veri seti ile de test edilecektir. Bu çalışmadaki beklenti hiç eğitilmediği 200 veri için de aynı performansı gösterebilmesidir. Çünkü 1950 satırlık veri de 200 satırlık veri de aynı üretim ortamına ait olup aynı karakteristik özelliklere sahiptir.

Eđitimi 1950 satırlık veri ile yapılan eđitilmiş YSA'ya 200 satırlık test veri seti girdi olarak girdiğinde tahminlerinin kesinliđi test edilmiştir. Bu testin ölçüsü de ortalama tahmin hatasıdır. Bu 200 veri için ortalama tahmin hatası 0,000472'dir. Bu deđer verileri sađlayan işletme tarafından kabul edilebilir karşılanmıştır. Çalışma için ise Excel Solver'ın lokal optimalarda takılma riski deđerlendirildiğinde bu sonuç tatmin edicidir. Bu deđer aynı zamanda KNN algoritmasının ortalama tahmin hatasının karşılaştırılması için de kullanılacaktır. Tüm deđerler ve hesapların yapıldığı Excel hesap çizelgesi Ek 2'de görülebilir. Bu tablodaki gösterimler uygulamanın bir örneğidir. Tüm veriler için uygulanan bu test, K Means metodu ile 3'lü ve 4'lü gruplara ayrılan veriler için de aynı mantıkla oluşturulan test veri seti için de yapılmıştır. Test sonuçlarının karşılaştırılması Çizelge 4.18.'de gösterilmiştir.

4.5.2. Test Veri Seti için KNN Hata Performansı

KNN algoritması eğitim gerektirmeyen bir algoritma olmasından ötürü 1950 adetlik eğitim verisi KNN için kullanılmayacaktır ve KNN'in 200 verilik test setindeki başarısı sınanacaktır. Bu çalışma yapılmış olup Çizelge 4.17. üzerinden görüldüğü üzere ortalama hatası 25,4'dür. Bu şirketin verileri ve bu çalışmalar ışığında YSA algoritması test verilerinde KNN algoritmasına karşı bir baskınlık özelliđi göstermiştir. Bu deđerler, hem YSA'nın kullanım kolaylığı açısından hem de tahmindeki kesinliğinden dolayı, şirketlerin kullanımını daha çok teşvik edecektir. Bu deđer aynı zamanda YSA algoritmasının ortalama tahmin hatasının karşılaştırılması için de kullanılacaktır. Bu tablodaki gösterimler uygulamanın bir örneğidir. Tüm veriler için uygulanan bu test, K Means metodu ile 3'lü ve 4'lü gruplara ayrılan veriler için de aynı mantıkla oluşturulan test veri seti için de yapılmıştır. Test sonuçlarının karşılaştırılması Çizelge 4.18.'de gösterilmiştir.

Çizelge 4.17. Tüm Verilerin KNN Tahminlemesi Test Veri Seti Analizi

No	Kalite Kaybı	Kalite Dağılım Göstergesi	Fire Yaratacak Kalite Hatası Sayısı	Brüt Üretim Miktarı	KNN Tahminle	Test Verileri	Kalite Dağılım Göstergesi	Fire Yaratacak Kalite Hatası Sayısı	Brüt Üretim Miktarı	Kalite Kaybı	Kalite Kaybı Tahmini	Fark x Fark	(Farkx Fark) Ortalama
1	2,448	3,89	279	309,5		1518	3,6	210,6	528,9	1,3	2,084	0,56	25,4
2	2,246	3,96	255	306,6		1237	3,366	239,4	559,0	1,5	2,188	0,47	
3	2,487	3,87	283	309,0		272	5,508	318,6	480,5	2,7	2,934	0,06	
4	2,532	3,83	289	310,0		468	4,356	289,8	514,3	2,2	2,628	0,20	
5	1,902	3,88	218	307,7		1787	4,014	448,2	564,9	3,5	4,428	0,95	
6	1,753	3,81	202	308,1		290	5,544	297	481,1	2,5	2,794	0,09	
7	1,853	3,87	213	309,4		1323	4,068	302,4	572,2	2,2	2,733	0,32	
8	2,242	4,16	252	309,9		307	4,59	327,6	482,2	2,7	2,921	0,07	
9	2,558	4,65	280	310,9		1417	4,086	291,6	582,9	2,0	2,641	0,38	
10	1,893	4,65	205	309,7		372	4,662	261	512,0	2,0	2,263	0,07	

Çizelge 4.18. Veri Seti Analizi Ortalama Sapma Değerleri

	YSA Testi	KNN Testi
Tüm Veri	0,000472361	25,3725
K Means 3 Grup	0,000473944	0,5695
K Means 4 Grup	0,000000268	1,2822

Çizelge 4.16. ve Çizelge 4.18. incelendiğinde 2 husus dikkat çekmektedir;

1. K Means metodu ile gruplama yapılmasının ardından yapılan tahminlerin fiili değerlere yaklaşması, şirketten alınan 1950 verinin içerisinde anlamsız verilerin var olduğunu bunların da tahmin hassasiyetini düşürdüğünü göstermektedir. Bu anlamsız verilerin K Means algoritması ile başarılı bir şekilde ayıklanması sonucunda çok daha hassas tahminleme yapılabildiği görülmüştür.
2. Oluşturulan veri setleri ile yapılan testler sonucunda dahi, K means ile 4 gruba ayrılarak ayıklanan veriler ile YSA ile yapılan tahminleme çok iyi sonuç vermektedir.

Bu değerlendirmeler sonucunda; çalışmanın yapıldığı işletme de kalite kaybı tahmininin YSA metodunda K Means ile 4 gruba ayrılmak sureti ile elde edilen verilerin kullanılarak yapılması uygun görülmüştür.

4.6 Bulguların Literatür ile Karşılaştırılması

Çizelge 4.19: Bulguların Literatür ile Karşılaştırılması

Literatürdeki Çalışma	Çalışma Bulguları	Çalışmanın İlgisi ve performans ölçüsü	Sonuçlar
Myers ve Hutchinson (1989)	YSA eğitiminin karmaşık yapısı	YSA çözümüne matematiksel yaklaşımlar	Sonuçlar ile uygun değil
Hecht-Nielsen (1992)	Geri yayılım teorisinde sezgisel yaklaşımlar	Karmaşık modellerin sezgisel çözümleri	Sonuçlar ile uygun değil
Huang ve Babri (1998)	YSA'nın şematik yapısı	Nöron sayısının parametreleştirilmesi	Sonuçlar ile uygun
Jiang ve Zhou (2004)	Gürültü temizlemenin YSA ve KNN performansına etkisi	Tahminleme ve sınıflandırma performans ölçüleri	Sonuçlar ile uygun
Li ve Guo (2007)	KNN'in anomali temizleme (sınıflandırma) performansı	KNN sınıflandırma performans ölçümü	Sonuçlar ile uygun değil
Ekincioğlu ve ark. (2017)	YSA'nın regresyon metotlarına göre performansı	MSE (Mean Squared Error) hata ölçüsüne göre YSA ve regresyon metotları karşılaştırılması	Sonuçlar ile uygun
Ravinder (2013)	Excel Solver'ın doğrusal olmayan optimizasyondaki performansı	MSE, MAD(Mean Absolute Deviation) ve MAPE (Mean Absolute Percentage Error) hata ölçüleri	Sonuçlar ile uygun
Ataseven (2013)	Zaman serileri ve YSA performansı karşılaştırılması	MSE, MAD(Mean Absolute Deviation) ve MAPE (Mean Absolute Percentage Error) hata ölçüleri	Sonuçlar ile uygun
Ataseven (2013)	YSA'nın şematik yapısı	Nöron sayısının parametreleştirilmesi	Sonuçlar ile uygun değil

Doğrusal olmayan programlamanın bir dezavantajı da içbükey olmayan setlerde eniyilemenin zor olmasıdır. Myers ve Hutchinson (1989), ve diğerleri bu çalışmada doğrusal olmayan aktivasyon (lojistik) fonksiyonlarının yerine

yaklaşımlarla parçalı fonksiyonlar haline getirilmiş aktivasyon fonksiyonları kullanmanın avantajlarını değerlendirmişlerdir. Çalışmada ise MSE performans ölçüsünde MS Excel GRG-Nonlinear Solver beklenen performans kriterini sağlamıştır. Sonuçlardaki bu farklılığın sebebinin kurulan YSA yapısının basit ve model büyüklüğünün çözülebilir olmasıdır. Bunlara ek olarak aktivasyon fonksiyonlarının Myers ve Hutchinson (1989)'dan farklı olarak sigmoid yerine doğrusal seçilmesidir. Doğrusal aktivasyon fonksiyonu sigmoid ile karşılaştırıldığında daha az matematiksel olarak karmaşıktır.

Hecht-Nielsen (1992), çalışmasında YSA'nın eğitimi (geri yayılımı) üzerinde durmuştur ve geri yayılım teorisini incelemiştir. Çalışmada ise geri yayılım için Hecht-Nielsen (1992), belirttiği gibi geri yayılım sezgiselleri yerine MS Excel GRG-Nonlinear Solver kullanılması yeterli olmuştur. Bu farklılığın nedeninin model boyutunun ve aktivasyon fonksiyonu karmaşıklığının bir geri yayılım sezgiseline ihtiyaç duyulmayacak kadar çözülebilir olmasıdır. MS Excel Solver kullanmanın ve öngörülen paternlerin düşük karmaşıklığının bir avantajı olarak geri yayılım algoritmaları çalışmada kullanılmamıştır.

Huang ve Babri (1998), ileri beslemeli tek gizli katmana sahip YSA'ların gizli katmanındaki nöron sayısını kararlaştırmak üzerine çalışmışlardır. Bahsedilen yapay sinir ağı yapısı bu çalışmada kullanılan yapıyla aynı yapıdır. Bu çalışmada Huang ve Babri (1998), N adet nöron kullanımının en fazla N adet paterni öğrenebileceğine kanıt sunmuşlardır. Çalışmada öngörülen patern sayısının üç olması (düşük verimlilik, orta seviyede verimlilik ve yüksek verimlilik) ile birlikte üç adet gizli katman nöronu kullanılması uygun görülmüş ve bu yapıyla birlikte elde edilen tahminler tatmin edici bulunmuştur.

Jiang ve Zhou (2004), YSA ve KNN girdilerindeki gürültüleri temizlemek için bir çalışma yapmışlardır. Bu çalışmada gürültü gerçekçi olmayan ya da veri setinin genel paternine uymayan veriler olarak tanımlanmıştır. Bu gürültü oluşturan verilerin YSA'nın ve KNN'nin tahminleme veya sınıflandırma performansına kötü etkisi olabileceğinden bahsetmiştir. Çalışmada kullanılan depürasyon yöntemi

kantitatif bir yöntemdir. Çalışmada ise kalitatif bir yöntem olarak uzman görüşü kullanılmıştır yani Kalite Kontrol Departmanı uzmanlarına danışılmıştır. Gürültü temizlenmesi uzman gözetiminde yapılmıştır ve sonuçlar Jiang ve Zhou (2004) uyumlu görülmüştür çünkü gürültüsü temizlenmiş veriler ile yapılan YSA eğitimi tatmin edici tahminlerle sonuçlanmıştır.

Li ve Guo (2007), araştırmalarında IT sistemlerinde saldırı ve spam algılamada KNN yönteminin kullanımını denetlemişlerdir. Bu çalışmada KNN'in anomalileri ortaya çıkarmadaki başarısının saldırı algılama konusunda başarılı olabileceği tezi ileri sürülmüştür. Çalışmada YSA yöntemi KNN algoritmasından daha iyi tahminler sunduğundan sonuçlar uygun değildir.

Ekincioglu ve ark. (2017), çalışmalarında saatlik üretim miktarlarının mermer yüzey sertliği gibi bazı kalite kontrol ölçülerine bağlı tahminini incelemişlerdir. Bu inceleme için Schmidt ve Shore sertlikleri adı verilen bazı kalite ölçüleri kullanmışlar ve bunların üretim miktarlarına etkisini araştırmışlardır. Tahminleme için YSA ve Regresyon Analizinin performansları karşılaştırılmış ve hata performansında YSA'nın daha iyi sonuçlar verdiğini gözlemlemişlerdir. YSA'nın baskınlığı çalışmada da mevcuttur.

Ravinder (2013), araştırmasında Excel Solver'ın doğrusal olmayan optimizasyondaki başarısı sınamak için yaptığı çalışmada, üssel düzleme tahmin metotlarının parametrelerinin karar verilmesini modelleştirmiş ve Excel Solver aracılığı ile global optimaya ulaşip ulaşamayacağını görmek istemiştir. Çalışmada üssel düzleme yöntemlerinin tahmin hatalarında global optimaya ulaşan parametreler önceden karar verilmiş ve Excel Solver'ın bu değerleri bulup bulamayacağı ya da alternatif çözümlerden birini saptayıp saptayamayacağını ölçülmüştür. Çalışmada da Kullanılan MS Excel Solver local optimada takılma riskini yaşatmış fakat farklı başlangıç noktaları ile YSA optimizasyonuna başlandığında daha iyi local optimalar elde edilmiş ve çalışmada bu daha iyi lokal optimalar kullanılmıştır.

Ataseven (2013), Box-Jenkins ARIMA zaman serileri öngörüleme modellerini YSA modelleri ile karşılaştırmıştır. Bu çalışma için materyal olarak bir şirketin 4 ürününe ait 11 yıllık satış verileri kullanılmıştır. Öngörü modellemesi bu çalışmada nitel ve nicel yöntemler olarak iki sınıfa ayrılmış ve nicel yöntemler incelenmiştir. Bu nicel yöntemler YSA tahminleme performansı ile karşılaştırılmıştır. YSA ile karşılaştırma sonucunda YSA'nın baskınlığı çalışmada da mevcuttur. Ancak Ataseven (2013)'ün çalışmada karşılaştığı gizli katman nöron sayısını belirleme sorunu çalışmada problemlere yol açmamıştır.



5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Yapay Sinir Ağları ve KNN metotları ile kalite kaybı tahminlemesi yapılması için girdi olarak kullanılacak veriler tespit edilirken kalite kaybına olan etkileri ölçülebilen veriler tercih edilmiştir. Münferit zamanlarda ortaya çıkan arıza, sürekli hata, enerji kesintisi gibi etkileri ölçülebilen kayıp nedenleri ile ilgili verilerin bütünlüğü bozacak olmaları nedeni ile çalışmada girdi olarak kullanılması uygun bulunmamıştır. Geçmiş günlerde oluşan; kalite dağılım göstergesi, fire yaratacak kalite hatası adeti, brüt üretim miktarı verilerine göre oluşan tüm kalite kayıpları verileri alınmış ve bu çalışmada anlatıldığı şekilde YSA ve KNN metotları kullanılarak MS Excel ile kalite kaybı tahmin modelleri oluşturulmuştur. Çalışmada her iki modelin de öğrenebilen modeller olmaları, tahminlemeyi olabildiğince yakın yapabiliyor olmaları, yaygın olarak kullanılabilme imkânlarının olmaları bu iki modeli oldukça kullanışlı hale getirmiştir.

KNN metodu tahminleme yapacağı girdi değerlerine en yakın K veriyi (Çalışmada K=5 olarak alınmıştır) dikkate alıp diğer verileri yok sayarak tahminleme yaptığı için, tahminleme sırasında tüm verileri dikkate alan YSA metoduna göre dezavantajlıdır. Diğer yandan YSA metodu ile yapılan tahminlerde solver çalıştırıldıktan sonra önceki verilere ihtiyaç duyulmadan sadece eğitilen gizli nöronlar ile tahminleme yapılabilmektedir ancak KNN metodunda en yakın K adet veri seçileceği için tüm verilere ihtiyaç duyulmaktadır. Bu durum tahminlemeyi yapacak MS Excel dosyasının boyutunu artırmakta ve dosyanın boyutuna göre uygulama sırasında bazı teknik problemler yaşanmasına neden olabilmektedir.

YSA ile kalite kaybı tahmini sisteminin devreye alınması ile birlikte vardiya sonlarında önceki veriler dikkate alınarak ilgili vardiya içerisinde oluşan kalite dağılım göstergesi, fire yaratacak kalite hata sayısı ve brüt üretim miktarı değerlerine göre kalite kaybı %99,99 doğrulukta tahmin edilmekte ve tahmin edilen değer mevcut kalite kaybı ile kıyaslanabilmektedir. YSA algoritması test edildikten sonra

yüz binde 1 daha az hata ile tahmin yapması tatmin edici bulunmuştur. Bu karşılaştırmadan sonra YSA ile kalite kaybı tahmini yapılarak fiili kalite kaybı ile tahmin edilen kalite kaybı değeri kıyaslanmaya başlanmıştır. Tahminin KNN ile kesinliği ise %99,98 olmuştur. Gerçekleşen kalite kaybının tahmin edilen kayıp değerinin üstünde veya altında olmasına göre operatörün başarı düzeyi sayısal verilere değerlendirilebilmektedir. Sistem devreye girdikten kısa bir süre sonra operatörler arasında bir rekabet ortamı oluşmuş olup operatörlerin iş yapış şekillerinde olumlu yönde gelişmeler gözlemlenmiştir. Operatörlerin iş yapış şekillerinin olumlu yönde geliştirmeleri kalite kayıplarının önemli ölçüde azalmasını sağlamıştır. Elde edilecek bu veriler ilerleyen günlerde performansa dayalı maaş zammı, terfi gibi kararlarda kullanılabilecek ve işletme içerisindeki adalet algısını güçlendirerek personelin daha verimli çalışmasına imkân sağlayacaktır. Ek 3'de oluşturulan ve performans değerlendirme sistemine veri oluşturacak veri tabanı görünüşü verilmiştir.

Çalışmada anlatılan ve örneklendirilen KNN ve YSA metotları ile talep, hammadde ihtiyacı, arıza zamanı gibi işletmeler için hayati öneme sahip konularda tahminleme yapılabilmesi olabildiğince kolay uygulanabilir bir hale getirilmiştir.

Çalışmada anlatılan sistemin işletmede uygulamaya geçmesi ile birlikte kalite kayıplarının ortalama %0,2 oranında azaldığı gözlemlenmiştir. Bu rakam az gibi görünmekle birlikte üretim kapasitesinin çok yüksek olması nedeni ile işletme için uzun vadede ciddi bir kazanç sağlayacaktır.

5.2 Öneriler

1. Üretim ve servis ortamlarında kalite kontrol müşteri kitlesine doğrudan etki eden faktörlerdendir. Kalite kontrole yapılan yatırımlar müşteriye doğrudan etki edebilmektedir. Ancak kalite kontrol kayıtlarının tutulması ve ölçümlerin yapılması sırasında insan hataları gerek tekrarlı işlerden gerekse ergonomik nedenlerden dolayı oluşabilir (Stanton ve

Baber, 2005). Bu bağlamda kalite kontrol görevlerinin otomatize edilmesi için yapılan yatırımlar bu hataların azaltılmasına katkıda bulunabilir.

2. Kalite kontrol istatistiklerindeki artış üretim (servis) ortamındaki net üretimin (servis kalitesinin) düşüşüne yol açmaktadır. Azaltıcı eylemler yerine önleyici yöntemlerin uygulanması kalite kontrol veriminin daha da artmasına neden olmaktadır (Yanar, 2008). Dolayısıyla kalite kontrol ve sistem etkinliği konusunda teknolojiye ve insana yatırılan yatırımların öngörücü ve önleyici araç ve metotlar üzerine yoğunlaştırılması önerilmektedir.
3. İlerleyen teknoloji ile beraber karmaşık yapıdaki sistemlerin belirli amaçlar doğrultusunda iyileştirilebilirliği artmıştır. Sadece çözüme yönelik algoritmalar, metotlar ve metodoloji gelişmekle kalmamış bu gelişimlerin sergilendiği bilgiye ulaşım da kolaylaşmıştır. İnsan eforu gerektiren bilgi işlem görevleri de dolayısıyla yerini veri otomasyonuna bırakmaya başlamıştır. İşleme hızı ve gücü yüksek ve kesin işlemleri hatasız yapabilen makineler üretim ve servis ortamlarında bilgi işlem için kullanılabilir.
4. Karmaşık matematiksel ve fiziksel yapıya sahip sistemler geliştirilen öğrenme algoritmaları ile daha algılanabilir hale gelmişlerdir. Bu sistemlerin girdileri ve çıktıları makine öğrenmesi ile bir performans ölçüsü dahilinde tanımlanabilmekte ve girdiler ve çıktılar performans kriterlerine göre de değiştirilebilmektedir. Kalite ve verim yönetiminde de aktif olarak kullanılacak olan bu öğrenme metotları sistemlerle entegre olmakta ve sistemlere yön verebilmektedir.
5. Bu çalışmada da olduğu gibi dinamik yapıya sahip üretim ve hizmet sistemlerinin çıktıları zamanla değişen koşullara göre değişebilmektedirler. Bu değişimlere ayak uydurabilmek için bu sistemlerin dinamizmine ayak uydurabilecek kullanımı kolay, hesap

karmaşıklığı düşük ve adaptasyon potansiyeli yüksek yöntemler tercih edilmelidir. Bu çalışmada kullanılan KNN ve Excel Solver destekli YSA' da bu tanıma uymaktadır. Matematiksel karmaşıklığı yüksek olan dinamik sistemlerde performanslarının yüksek olmasından dolayı bu sistemlere uygulanmaları önerilmektedir.

6. Günümüzde öğrenme temelli maliyet gerektirenleri sistemlere adapte edilmeleridir. Bu çalışmada olduğu gibi her şirketin temel araçlarından biri olan MS Excel tahminlemede ve sınıflandırmada kullanılabilecek sistem elemanlarına sahiptir. Bu da yapılan işin teknik altyapısının kurulmasında büyük güçlükler olmayacağını bir göstergesidir. Bu bağlamda çalışmadaki probleme benzer üretim ve servis problemlerine önerilebilecek çözüm yaklaşımlarında kullanımı basit ofis araçlarının bile verimli ve etkili çözüm sunabileceğini düşünmek gerekmektedir.
7. Kullanılan basit ofis araçları her ne kadar düşük maliyetli, hızlı, dinamik, verimli ve etkin çözümler sunabilse de bazı ödünleşimler göz ardı edilmemelidir. Buna bir örnek olarak MS Excel GRG-Nonlinear Solver her ne kadar hızlı çözümler üretse de en büyük dezavantajı global optima garantisi vermemesidir (Ravinder, 2103). Bu da demek oluyor ki her zaman lokal optimada takılma riski vardır. Bu tür çalışma araçlarında parametrelere farklı başlangıç değerleri verilerek kötü lokal optima problemleri aşılabılır ve daha iyi lokal optimalar bulunabilir ve hatta global optimaya ulaşılmış olunabilir.
8. Bu çalışma yapılırken objektifliğin sağlanabilmesi için girdi bilgileri çalışanlardan habersiz olarak toplanmıştır.
9. Hatalı bilgiler ayıklanırken her zaman uzman bilgisine başvurulmuştur. Bunun yanında jenerik olarak çalışabilen sayısal metotlarında denenmesi her zaman bir seçenek olarak önerilebilir. Fakat unutmamak gerekir ki önerilen metotlar nicel (kantitatif) ve nitel (kalitatif) metotların birleşimi olan metotlardır (Ataseven, 2013).

KAYNAKLAR

- Adamson, R., Hobbs, M., Silcock, A., & Montague, G., 2015. Real Time Optimisation of Industrial Gas Supply Networks. IFAC-PapersOnLine, 48(8), 355-360.
- Albayrak, Y. E. & Erkut, H., 2010. Banka Performans Değerlendirmede Analitik Hiyerarşi Süreç Yaklaşımı, İTÜ Dergisi, Cilt 4, Sayı 6, Sayfalar 47-58.
- Aslan, S., 2007. Performans Ölçümünde Kıyaslama Yöntemi Olarak Veri Zarflama Analizinin Kullanımı: Türkiye Şeker Fabrikaları Örneği, Dergipark, Cilt 21, Sayı 1, Sayfalar 383-396.
- Ataseven, B., 2014. Yapay Sinir Ağları ile Öngörü Modellemesi, Sosyal Bilimler Enstitüsü Makale Koleksiyonu,
- Balaghi, R., Tychon, B., Eerens, H., & Jlibene, M. (2008). Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco. International Journal of Applied Earth Observation and Geoinformation, 10(4), 438-452.
- Çakmak, N. & Ocaklı, E., 2006. Performans Değerlendirmesi Gerekli Midir? Neden?, Unak, 6, 406-18.
- Ekincioglu, G., Güney, A., Akbay, D., & Altındağ, R. Dairesel Testereli Kesme Makinelerinin Saatlik Üretim Miktarının Mermer Yüzey Sertliğine Bağlı Olarak Yapay Sinir Ağı (YSA) Ve Regresyon Analizleri (RA) İle Tahmin Edilmesi. Türkiye 9. Uluslararası Mermer ve Doğaltaş Kongresi ve Sergisi (MERSEM2017), S: 87-96, 13-15 Aralık 2017 Antalya – TURKEY.
- Elitaş, C., & Ağca., V., 2006. Firmalarda Çok Boyutlu Performans Değerleme Yaklaşımları: Kavramsal Bir Çerçeve. Sosyal Bilimler Dergisi, <http://hdl.handle.net/11630/3635>.
- Hecht-Nielsen, R., 1992. Theory of the backpropagation neural network. In Neural networks for perception. Academic Press, 65-93.

- Hegazy, T., & Ayed, A. (1998). Neural network model for parametric cost estimation of highway projects. *Journal of Construction Engineering and Management*, 124(3), 210-218.
- Hodges, R., Bernard, M., & Rembold, F., 2014. APHLIS-Postharvest Cereal Losses in Sub-Saharan Africa, Their Estimation, Assessment and Reduction. Luxembourg: Publications Office.
- Huang, G., & Babri, H., 1998. Upper Bounds on The Number of Hidden Neurons in Feedforward Networks With Arbitrary Bounded Nonlinear Activation Functions. *IEEE Transactions on Neural Networks*, 9(1), 224-229.
- Işığık, E., 2008. Performans Ölçümü, Yönetimi ve İstatistiksel Analizi, İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik E-Dergisi (7), 1-23.
- Jiang, Y., & Zhou, Z. H., 2004. Editing Training Data for KNN Classifiers with Neural Network Ensemble. In *International Symposium on Neural Networks*. Springer, Berlin, Heidelberg, 356-361.
- Kumbhakar, S. C., Denny, M., & Fuss, M., 2000. Estimation and Decomposition of Productivity Change When Production Is Not Efficient: A Paneldata Approach. *Econometric Reviews*, 19(4), 312-320.
- Levinsohn, J., & Petrin, A., 2003. Estimating Production Functions Using Inputs to Control for Unobservables. *The review of economic studies*, 70(2), 317-341.
- Li, Y., & Guo, L., 2007. An active learning based TCM-KNN algorithm for supervised network intrusion detection. *Computers & Security*, 26(7-8), 459-467.
- Murray, G. M., & Brennan, J. P., 2009. Estimating Disease Losses to the Australian Wheat Industry. *Australasian Plant Pathology*, 38(6), 558-570.
- Myers, D. J., & Hutchinson, R. A., 1989. Efficient Implementation of Piecewise Linear Activation Function for Digital VLSI Neural Networks. *Electronics Letters*, 25, 1662.

- Neely, A., Gregory, M., & Platts, K., 1995. Performance Measurement System Design: a Literature Review and Research Agenda. *International Journal of Operations & Production Management*, 15(4), 80-116.
- Özsever, Ç., Gençoğlu, T., & Erginel, N. (2009). İşgücü Verimlilik Takibi İçin Sistem Tasarımı ve Karar Destek Modelinin Geliştirilmesi. *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, (018), 45-58.
- Ravinder, H. V., 2016. Determining The Optimal Values of Exponential Smoothing Constants – Does Solver Really Work? *American Journal of Business Education (AJBE)*, 9(1), 1-14.
- Selalmaz, E., Zeyveli, M., 2008. İstatistik Proses Kontrol Tekniklerinin Zincir İmalatı Yapan Bir İşletmede Uygulanması, Karabük Üniversitesi, Teknik Eğitim Fakültesi, Makine Eğitimi Bölümü.
- Stanton Neville A., & Baber C., 2005. Validating Task Analysis For Error Identification: Reliability and Validity of a Human Error Prediction Technique. *Ergonomics*, 48:9, 1097-1113.
- Taşdemir, Ş., 2011. Yüzey Pürüzlülüğünün Yapay Sinir Ağı ve Regresyon Modelleri ile Belirlenmesi ve Karşılaştırılması. *Journal of Selçuk-Technic*, 10(3).
- Thommesen, J., & Andersen, H. B., 2012. Human Error Probabilites (HEPs) for Generic Tasks and Performance Shaping Factors (PSFs) Selected For Railway Operations. Technical University of Denmark., Department of Management Engineering. Engineering Report, No. 3.2012.
- Wenwen, S., Fuchuan, J., Qiang, Z., & Jingjing, C., 2011. Analysis and Control of Human Error. *Procedia Engineering*, 26, 2126-2132.
- Yağcı, A., & Şen, A. 2015. Tüplü Asma Fidanı Üretiminde Farklı Köklendirme Yerlerinin Fidan Randıman ve Kalitesi Üzerine Etkileri. *Meyve Bilimi*, 3(1), 22-28.
- Yanar, N., 2008. Hidrolik Silindir İmalatında Yüzey Pürüzlülüğüne Etkili Parametrelerinin Taguchi Yöntemi ile Belirlenmesi, Doctoral Dissertation, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

- Yüreğir, O. H., & Nakıboğlu G. G., 2007. Performans Ölçümü ve Ölçüm Sistemleri: Genel Bir Bakış. Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 16(2), 545-562.
- Zakwan, M., 2016. Application of Optimization Technique to Estimate IDF Parameters, Water and Energy International, 59(5), 69-71.
- Zakwan, M., Muzzammil, M., & Alam, J., 2017. Developing Stage-Discharge Relations Using Optimization Techniques. Aquademia: Water, Environment and Technology, 1(2), 05.
- Zerenler, M., 2005. The Performance Measurement System Design And a Study on Performance Measurement of Manufacturing Systems. Ekonomik ve Sosyal Araştırmalar Dergisi, 1:1-36

ÖZGEÇMİŞ

Çukurova Üniversitesi Endüstri Mühendisliği Bölümünden 2002 yılında mezun olmuştur, 2003-2005 yılı arasında Özbucacak Tekstil A.Ş.'de planlama mühendisi olarak çalışmış olup, üretim planlama, seri üretim hatları optimizasyon sistemleri, bilgisayar destekli etkin sistem kurulumu ve kendisini yöneten sistemler konularıyla ilgilenmekte olan yazar 2005 yılı itibari ile çalışmaya başladığı Trakya Cam Sanayii A.Ş.'de Soğuk Cam Üretim Şefi olarak çalışmaya devam etmektedir.







EKLER



Ek 1: Oluşturulan Genel Hücre Yapısı

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	Q
No	Kalite Dağılım Göstergesi	Fire Yaratacak Kalite Hatası Sayısı	Brüt Üretim Miktarı	W11	W21	W31	Noron 1	Noron 2	Noron 3	Bias Noronu	Y.Tahmin	Hedef	Farkx Fark	(Farkx Fark) Ortalama	Fihli Kalite Kaybı
1	3.89	279	309,5	-0,11040	-0,24799	-0,26772	-152,475	-23,867	-350,959	1	0,9758	0,9755	0,00000006	0,000002227	2,448
2	3.96	255	306,6	W12	W22	W32	-145,746	-32,815	-342,439		0,9780	0,9775	0,00000022		2,246
3	3.87	283	309,0	0,97136	0,43444	-0,48097	-153,328	-21,903	-351,461		0,9755	0,9751	0,00000011		2,487
4	3.83	289	310,0	W13	W23	W33	-155,078	-19,813	-353,842		0,9749	0,9747	0,00000006		2,532
5	3.88	218	307,7	0,46000	-0,24093	-0,92259	-136,875	-49,530	-334,641		0,9814	0,9810	0,00000014		1,902
6	3.81	202	308,1	W1o	W2o	W3o	-133,011	-56,749	-331,203		0,9829	0,9825	0,00000015		1,753
7	3.87	213	309,4	0,12266	0,03888	-0,05579	-136,077	-52,508	-334,970		0,9817	0,9815	0,00000005		1,853
8	4.16	252	309,9			W-BIAS	-145,924	-35,541	-344,726		0,9778	0,9776	0,00000003		2,242
9	4.65	280	310,9			1,02744	-153,184	-23,372	-352,150		0,9745	0,9744	0,00000000		2,558
10	4.65	205	309,7				-134,266	-55,381	-332,880		0,9813	0,9811	0,00000004		1,893
11	4.64	244	308,7				-143,662	-37,955	-341,435		0,9779	0,9774	0,00000018		2,256
12	5.04	289	308,6				-154,841	-17,973	-352,009		0,9733	0,9729	0,00000011		2,706
13	5.29	282	308,5				-153,108	-20,727	-350,123		0,9735	0,9731	0,00000017		2,687

Ek 2: Tüm Verilerin YSA Optimizasyonu Test Veri Seti Analizi

Tüm Dataların YSA Optimizasyonu Test Veri Seti Analizi

No	Kalite Dağılım Göstergesi	Fine Yaratacak Kalite Hatası	Brüt Üretim Miktarı	W1	W2	W3	Noron 1	Noron 2	Noron 3	Bias Noronu	Y:Tahmin	Hedef	FarkxFark	(FarkxFark) Ortalama
1518	3,6	210,6	528,9	-0,11040	-0,24799	-0,26772	-194,2	-159,4	-537,1	1	0,9673	0,9866	0,000372	0,0004724
1237	3,366	239,4	559,0	W1	W2	W3	-209,4	-161,6	-571,9		0,9630	0,9850	0,000482	
272	5,508	318,6	480,5	0,97136	0,43444	-0,48097	-208,2	-87,3	-517,5		0,9582	0,9731	0,000222	
468	4,356	289,8	514,3	W1	W2	W3	-210,0	-117,2	-542,3		0,9601	0,9782	0,000324	
1787	4,014	448,2	564,9	0,46000	-0,24093	-0,92259	-262,8	-73,1	-627,3		0,9430	0,9655	0,000503	
290	5,544	297	481,1	W1	W2	W3	-203,1	-97,0	-512,9		0,9601	0,9751	0,000226	
1323	4,068	302,4	572,2	0,122663	0,0388752	-0,055788	-228,6	-139,9	-598,9		0,9555	0,9783	0,000521	
307	4,59	327,6	482,2			W-BIAS	-210,8	-85,1	-521,7		0,9586	0,9734	0,000217	
1417	4,086	291,6	582,9			1,0274393	-228,8	-149,7	-606,1		0,9557	0,9797	0,000578	
372	4,662	261	512,0				-202,3	-128,3	-533,1		0,9624	0,9800	0,000309	
255	4,68	198	511,5				-186,6	-155,5	-517,5		0,9681	0,9855	0,000304	

Ek 3: YSA Optimizasyonu Sonucu Tahmini ve Fiili Kalite Kayıpları

TARİH	Vardiya	Brut Üretim Miktarı	Toplam Üretim	Verimlilik %	Kalite Dağılım Göstergesi	Fire Yaratacak Kalite Hatası Sayısı	Üretim Kaynaklı Kayıplar %	2. İşlem Kaynaklı Kayıplar %	Anıza Kayıpları %	Jumbo Oran %	Vardiya Sorumlusu	Operator 1	Operator 2	YSA Kalite Kaybı Oran Göstüsü	Fiili Kalite Kaybı %	Sapma %
1.02.2019	24/08	295.3	278.2	94,2	1,56	130,0	4,9	0,0	0,0	71,6	O. Yılmaz	Y. Kıvanç	B. Fırat	0,793	0,908	-0,115
1.02.2019	08/16	295.8	277,6	93,9	1,45	184,0	4,8	0,0	0,0	74,7	T. Turgut	M. Güray	M. Er	1,257	1,394	-0,137
1.02.2019	16/24	295,7	276,3	93,5	1,43	171,0	5,6	0,0	0,0	68,9	Z. Tuna	B. Genç	H. Aslan	1,139	0,986	0,153
2.02.2019	24/08	295,3	278,1	94,2	1,42	156,0	4,7	0,0	0,0	68,9	E. Muratoğlu	Y. Kıvanç	M. Kara	1,004	1,181	-0,176
2.02.2019	08/16	295,4	277,6	94,0	1,45	201,0	4,7	0,0	0,0	71,8	T. Turgut	M. Güray	M. Er	1,409	1,347	0,062
2.02.2019	16/24	295,3	278,9	94,5	1,47	178,0	4,3	0,0	0,0	64,2	Z. Tuna	H. Aslan	B. Genç	1,208	1,235	-0,027
3.02.2019	24/08	296,0	263,7	89,1	1,51	174,0	9,7	0,0	0,0	62,8	Z. Tuna	H. Aslan	M. Kara	1,177	1,252	-0,075
3.02.2019	08/16	296,2	276,8	93,5	1,46	147,0	5,5	0,0	0,3	71,0	E. Muratoğlu	M. Güray	M. Er	0,928	0,819	0,109
3.02.2019	16/24	296,3	279,9	94,5	1,62	180,0	4,2	0,0	0,0	86,4	E. Muratoğlu	B. Fırat	Y. Kıvanç	1,246	1,361	-0,115
4.02.2019	24/08	296,0	279,6	94,5	1,60	195,0	4,0	0,0	0,0	83,8	O. Yılmaz	M. Kara	Y. Kıvanç	1,377	1,513	-0,136
4.02.2019	08/16	296,6	279,0	94,1	1,63	197,0	4,7	0,0	0,0	83,2	E. Muratoğlu	B. Genç	M. Er	1,399	1,245	0,154
4.02.2019	16/24	295,7	272,5	92,2	1,50	134,0	6,9	0,0	0,0	76,5	T. Turgut	B. Fırat	H. Aslan	0,819	0,956	-0,137
5.02.2019	24/08	295,4	279,6	94,4	1,53	100,0	5,3	0,0	0,0	81,6	O. Yılmaz	M. Güray	M. Kara	0,520	0,382	0,137
5.02.2019	08/16	293,6	276,0	94,0	1,67	142,0	5,0	0,0	0,0	74,1	E. Muratoğlu	B. Genç	M. Er	0,920	1,021	-0,101
5.02.2019	16/24	293,5	276,7	94,3	1,93	117,0	5,0	0,0	0,0	82,2	T. Turgut	B. Fırat	H. Aslan	0,736	0,726	0,011
6.02.2019	24/08	293,5	277,6	94,6	1,70	105,0	4,8	0,0	0,0	85,4	O. Yılmaz	M. Güray	M. Kara	0,595	0,592	0,003
6.02.2019	08/16	293,5	276,4	94,2	1,67	139,0	4,8	0,0	0,0	86,2	E. Muratoğlu	M. Er	R. Özlü	0,893	1,009	-0,115

Ek 4: Kullanılan Excel VBA Kodu

Sub KNN()

Application.EnableEvents = False

Dim Distance As Double

Dim Min_Distance(1 To 1951, 1 To 5) As Double

Dim Yakin_Randiman(1 To 1951, 1 To 5) As Double

Dim Yakinlik_Onayi As Boolean

Dim Tahmin(1 To 1951) As Double

Dim cnt As Integer

cnt = 0

For ka = 1 To 99999

If Not IsEmpty(ActiveSheet.Cells(ka + 1, 3).Value2) Then

cnt = cnt + 1

Else

Exit For

End If

Next ka

For i = 1 To 1951

Yakin_Randiman(i, 1) = 0

Yakin_Randiman(i, 2) = 0

Yakin_Randiman(i, 3) = 0

Yakin_Randiman(i, 4) = 0

Yakin_Randiman(i, 5) = 0

```

Min_Distance(i,1) = 999999999999#
Min_Distance(i,2) = 999999999999#
Min_Distance(i,3) = 999999999999#
Min_Distance(i,4) = 999999999999#
Min_Distance(i,5) = 999999999999#

```

```

Distance = 0

```

```

For j = 1 To cnt

```

```

    Yakinlik_Onayi = False

```

```

    Distance = (ActiveSheet.Cells(i + 1,8).Value2
    - ActiveSheet.Cells(j + 1,3).Value2) ^ 2

```

```

    Distance = Distance + (ActiveSheet.Cells(i + 1,9).
    Value2 - ActiveSheet.Cells(j + 1,4).Value2) ^ 2

```

```

    Distance = Distance + (ActiveSheet.Cells(i + 1,10).
    Value2 - ActiveSheet.Cells(j + 1,5).Value2) ^ 2

```

```

    Distance = Math.Sqrt(Distance)

```

```

If Distance <= Min_Distance(i,1) Then

```

```

    Min_Distance(i,5) = Min_Distance(i,4)

```

```

    Yakin_Randiman(i,5) = Yakin_Randiman(i,4)

```

```

    Min_Distance(i,4) = Min_Distance(i,3)

```

```

    Yakin_Randiman(i,4) = Yakin_Randiman(i,3)

```

```

    Min_Distance(i,3) = Min_Distance(i,2)

```

```

    Yakin_Randiman(i,3) = Yakin_Randiman(i,2)

```

```

    Min_Distance(i,2) = Min_Distance(i,1)

```

```

    Yakin_Randiman(i,2) = Yakin_Randiman(i,1)

```

```

    Min_Distance(i,1) = Distance

```

```

    Yakinlik_Onayi = True

```

```
Yakin_Randiman(i, 1) = ActiveSheet.Cells(j + 1, 2).Value2  
End If
```

```
If Distance <= Min_Distance(i, 2) And Yakinlik_Onayi = False Then  
Min_Distance(i, 5) = Min_Distance(i, 4)  
Yakin_Randiman(i, 5) = Yakin_Randiman(i, 4)  
Min_Distance(i, 4) = Min_Distance(i, 3)  
Yakin_Randiman(i, 4) = Yakin_Randiman(i, 3)  
Min_Distance(i, 3) = Min_Distance(i, 2)  
Yakin_Randiman(i, 3) = Yakin_Randiman(i, 2)  
Min_Distance(i, 2) = Distance  
Yakinlik_Onayi = True  
Yakin_Randiman(i, 2) = ActiveSheet.Cells(j + 1, 2).Value2  
End If
```

```
Range(B2:P2).Select  
Selection.Font.Size = 14  
Selection.Font.Size = 12  
Selection.Font.Bold = True  
Selection.Font.Bold = False
```

```
If Distance <= Min_Distance(i, 3) And Yakinlik_Onayi = False Then  
Min_Distance(i, 5) = Min_Distance(i, 4)  
Yakin_Randiman(i, 5) = Yakin_Randiman(i, 4)  
Min_Distance(i, 4) = Min_Distance(i, 3)  
Yakin_Randiman(i, 4) = Yakin_Randiman(i, 3)  
Min_Distance(i, 3) = Distance  
Yakinlik_Onayi = True
```

```
Yakin_Randiman(i, 3) = ActiveSheet.Cells(j + 1, 2).Value2
```

```
End If
```

```
If Distance <= Min_Distance(i, 4) And Yakinlik_Onayi = False Then
```

```
Min_Distance(i, 5) = Min_Distance(i, 4)
```

```
Yakin_Randiman(i, 5) = Yakin_Randiman(i, 4)
```

```
Min_Distance(i, 4) = Distance
```

```
Yakinlik_Onayi = True
```

```
Yakin_Randiman(i, 4) = ActiveSheet.Cells(j + 1, 2).Value2
```

```
End If
```

```
If Distance <= Min_Distance(i, 5) And Yakinlik_Onayi = False Then
```

```
Min_Distance(i, 5) = Distance
```

```
Yakinlik_Onayi = True
```

```
Yakin_Randiman(i, 5) = ActiveSheet.Cells(j + 1, 2).Value2
```

```
End If
```

```
Next j
```

```
For k = 1 To 5
```

```
Tahmin(i) = Tahmin(i) + Yakin_Randiman(i, k) * (6 - k) / (15)
```

```
Next k
```

```
ActiveSheet.Cells(i + 1, 13).Value = Tahmin(i)
```

```
Next i
```

MsgBox (cnt)

Application.EnableEvents = True

ActiveWindow.ScrollRow = 4

ActiveWindow.ScrollRow = 11

ActiveWindow.ScrollRow = 22

ActiveWindow.ScrollRow = 47

ActiveWindow.ScrollRow = 107

ActiveWindow.ScrollRow = 171

ActiveWindow.ScrollRow = 338

ActiveWindow.ScrollRow = 640

ActiveWindow.ScrollRow = 1126

ActiveWindow.ScrollRow = 1290

ActiveWindow.ScrollRow = 1712

ActiveWindow.ScrollRow = 1876

ActiveWindow.ScrollRow = 1894

ActiveWindow.ScrollRow = 1901

ActiveWindow.ScrollRow = 1926

ActiveWindow.LargeScroll Down: = 0

Range("N1951").Select

ActiveWorkbook.Save

Range("F1934").Select

ActiveWindow.LargeScroll Down: = -90

Range("F6").Select

ActiveSheet.Shapes.Range(Array("Button 1")).Select

Selection.OnAction = "AA"

Range("F8:F9").Select

Range("F9").Activate

```
ActiveSheet.Shapes.Range(Array("Button 1")).Select  
End Sub
```

```
Range("Q4").Select  
ActiveWorkbook.RefreshAll  
ActiveWorkbook.Save  
End Sub
```

