

**T.C.**  
**İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ ANA BİLİM**  
**DALI**  
**BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ BİLİM DALI**

**AKILLI YARDIMCI: REGRESSION MODELİNE**  
**DAYALI STOCK TAHMİNLEME YAPISI**

**YÜKSEK LİSANS TEZİ**

**Ömer KÜÇÜK**

**İSTANBUL**

**Ekim 2018**

**T.C.**  
**İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ ANA BİLİM**  
**DALI**  
**BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ**  
**YÜKSEK LİSANS PROGRAMI**

**SMART ADVISOR:**  
**AN INTELLIGENT INVENTORY PREDICTION BASED ON**  
**REGRESSION**

**YÜKSEK LİSANS TEZİ**

**Ömer KÜÇÜK**

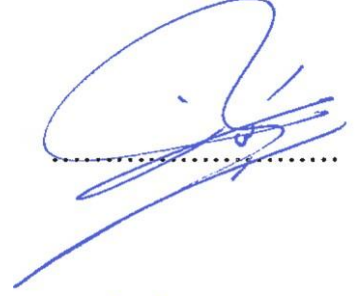
**Tez Danışmanı**  
**Dr. Öğr. Üyesi. Farzad KIANI**

**İstanbul**  
**Ekim 2018**

Fen Bilimleri Enstitüsü Müdürlüğüne,

Bu çalışma, jürimiz tarafından Bilgisayar Bilimleri ve Mühendisliği Anabilim Dalı, Bilgisayar Bilimleri ve Mühendisliği (%30 İngilizce) Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman Dr. Öğr. Üyesi Farzad KLANI



Üye Dr. öğr. Üyesi Amani YAHYAOUİ



Üye Dr. öğ. Üyesi Ferdi SÖNMEZ



Onay

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.



Prof. Dr. Ahmet Korhan BİNARK

Enstitü Müdürü

## BİLİMSEL ETİK BİLDİRİMİ

Yüksek lisans tezi olarak hazırladığım “Akıllı Yardımcı: Regression Modeline Dayalı Stock Tahminleme Yapısı” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

Ömer KÜÇÜK



## ÖNSÖZ

Araştırmamdaki her aşamada bana yardımcı olan değerli tez danışmanım Dr. Öğr. Üyesi Farzad KIANI'ya, eğitim alanında dersleriyle bize vizyon katan çok değerli hocamız Dr. Muhammad FAHIM'e, yüksek lisans eğitimim boyunca benden desteklerini esirgemeyen aileme teşekkürlerimi sunarım.

**Ömer KÜÇÜK**

**İstanbul - 2018**



## ÖZET

# AKILLI YARDIMCI: LİNEER REGRESYONA DAYALI STOK TAHMİNLEME

Ömer Küçük

Yüksek Lisans, Bilgisayar Bilimleri ve Mühendisliği

Tez Danışmanı: Dr. Öğr. Üyesi. Farzad KIANI

Kasım 2018, 47 sayfa

Bu çalışmada makine öğrenme tekniklerinden lineer regresyon modeli kullanılarak stok altyapısı üzerinde ileriye yönelik tahminlemelerde bulunulmuştur. Akıllı Yardımcı isimli geliştirilen bir program ile yapay bir veri seti üzerinde lineer regresyon modeli kullanılarak analiz yapılmış ve tahminleme değerleri üretilmiştir. Son olarak lineer regresyonun hesaplama üzerine etkisi incelenmiş ve elde edilen sonuçlar değerlendirilmiştir.

**Anahtar Kelimeler:** Makine Öğrenme, Lineer Regresyon, Tahminleme

## **ABSTRACT**

### **SMART ADVISOR: AN INTELLIGENT INVENTORY PREDICTION BASED ON REGRESSION**

Ömer Küçük

Master of Science, Computer Science and Engineering

Supervisor: Asst. Prof. Dr. Farzad KIANI

November 2018, 47 Pages

In this thesis predictions performed on inventory infrastructures by using linear regression model from machine learning algorithms. Analyzed and computed prediction results by using a self-developed program names Smart Adviser on an example dataset. Finally analyzed effect of linear regression over calculations, results which obtained were discussed.

**Keywords:** Machine Learning, Linear Regression, Prediction

## TEŞEKKÜR

Yüksek lisans öğrenimim boyunca desteklerini benden eksik etmeyen, dersleri bize sevdiren ve ders dışında da bize kıymetli vakitlerini ayıran değerli bölüm hocalarıma çok teşekkür ederim.

Tez çalışmam esnasında değerli zamanını ve yardımlarını eksik etmeyen, fikirleriyle bana yön veren ve bu çalışmanın ortaya çıkmasında büyük emeği olan sayın danışmanım Dr. Muhammad FAHİM ve Dr. Öğr. Üyesi. Farzad KIANI ye saygı sevgi ve teşekkürlerimi iletirim.

Beni bu günlere getiren ve manevi desteğini üzerimde hissettiğim aileme de teşekkürlerimi sunmayı borç bilirim.





## İÇİNDEKİLER

TEZ ONAYI.....	Hata! Yer işareti tanımlanmamış.
BİLİMSEL ETİK BİLDİRİMİ.....	ii
ÖNSÖZ .....	iii
ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER .....	Hata! Yer işareti tanımlanmamış.
ŞEKİLLER.....	ix
<b>BİRİNCİ BÖLÜM GİRİŞ .....</b>	<b>1</b>
1.1. Gözetimli Öğrenme(Supervised Learning) .....	3
1.2. Gözetimsiz Öğrenme(Unsupervised Learning).....	3
1.3. Takviyeli Öğrenme (Reinforcement Learning).....	4
1.4. Makine Öğrenmesi alanında kullanılan diğer algoritma türleri .....	4
1.4.1. Regresyon.....	5
<b>İKİNCİ BÖLÜM KAYNAK ARAŞTIRMASI.....</b>	<b>8</b>
<b>ÜÇÜNCÜ BÖLÜM VERİ ANALİZİ VE MODELLEME .....</b>	<b>14</b>
3.1. Model.....	15
3.2. SMART ADVISOR .....	19
3.3. Malzeme Tanımı.....	19
3.4. Malzeme Girişi .....	19
3.5. Malzeme Çıkışı.....	19
3.6. Stok Durum Raporu.....	20
<b>DÖRDÜNCÜ BÖLÜM SONUÇLAR .....</b>	<b>21</b>
4.1. Minimum Seviye Şeması.....	21
4.2. Stok Durum Şeması.....	22

4.3. Lineer Regresyon Şeması .....	23
<b>BEŞİNCİ BÖLÜM DEĞERLENDİRME</b> .....	29
<b>ALTINCI BÖLÜM SONUÇ VE GELECEKTEKİ ÇALIŞMALAR</b> .....	30
<b>YEDİNCİ BÖLÜM KAYNAKLAR</b> .....	31
<b>EKLER</b> .....	33



## ŞEKİLLER

Şekil 1- Hipotez fonksiyonu.....	6
Şekil 2- Veri Akış Şeması.....	16
Şekil 3- Çalışma Yapısı.....	17
Şekil 4- Tahminleme.....	18
Şekil 5- Stok Durum Raporu.....	20
Şekil 6- Minimum Seviye Şeması.....	21
Şekil 7- Stok Şeması.....	22
Şekil 8- Lineer Regresyon Grafiği.....	23
Şekil 9- Formül Hesaplama.....	24
Şekil 10- %10 luk Filtre ile Regresyon Grafiği.....	25
Şekil 11- %10 luk Filtre ile Stok Durum Raporu.....	25
Şekil 12- %50 lik Filtre ile Regresyon Grafiği.....	26
Şekil 13- %50 lik Filtre ile Stok Durum Raporu.....	26
Şekil 14- %85 lik Filtre ile Regresyon Grafiği.....	27
Şekil 15- %85 lik Filtre ile Stok Durum Raporu.....	27



# BİRİNCİ BÖLÜM

## GİRİŞ

Bu bölümde bahsedilecek konular kısaca;

- Makine Öğrenme Algoritmaları
- Gözetimli Öğrenme
- Gözetimsiz Öğrenme
- Takviyeli Öğrenme
- Regresyon
- Lineer regresyon

şeklindedir.

Günümüzde işletmelerin en büyük harcama kalemlerinden biri hammadde ve stok tutarlarıdır. Bu nedenle, doğru stok yönetimi, işletmelerin kârlılığı için çok önemlidir. Zamanında satın alınmayan ürünler, üretimde kesintiye neden olmakta ve son kullanma tarihi geçtiğinden geriye kalan ürünler de işletmeler için kayıplara neden olmaktadır. Bu nedenle, uygun stok yönetimi, işletmelerin kâr / zarar durumları için kritik önem taşır.

Stok tüketiminin doğru analiz edilmesi ileride tüketilecek stok miktarının da doğru tahmin edilmesini sağlar. Stok tüketiminin doğru tahmin edilmesi, karar verme aşamasında doğru adımların atılmasına yardımcı olur. Yani sadece gerektiği zamanda sadece yeterli miktarda satın alma imkanı sağlar. Bu aşamalar ekonomik stok yönetimi için kritik öneme sahiptir. Bu nedenle, modelleri sağlayabilen sağlam ve uyarlanabilir yaklaşımlar, stok tüketimini doğru bir şekilde yönetebilmeyi sağlar.

Stok hareketlerinin yönünü tahmin etmeyle ilgili daha önceden yazılmış kaynak bulmak oldukça zordur. Bunun en önemli nedenlerinden biride akademik literatürde bu tarz çalışmaların yapılması için yeteri kadar teşvik olmamasıdır. Bu yüzden konuyla ilgili yazılan makaleler ve yapılan çalışmalar sınırlı kalmış, sonuçlar tekrarlanabilir seviyeye ulaşamamıştır.

Makine Öğrenmesi Yapay Zekanın bir alt koludur. Temel mantığı verileri analiz ederek kendi kendine bir öğrenim faaliyeti gerçekleştirmesidir. Yapay Zekâ ise bilgisayarların bazı görevleri gerçekleştirebilmesi için akıllı denilen yöntemleri kullanabilmesidir ve kapsam olarak makine öğrenmesinde daha geniş bir alandır. Makine Öğrenme, bilgisayarların programlanmadan sadece elde edilen verilerle öğrenme yaparak Yapay Zekâyı gerçekleştirmesidir. Bu çalışmada, stok tüketiminin tahmin modeli oluşturmak için Makine Öğrenme tekniklerinden Lineer Regresyon tekniğini kullanacağız.

Makine Öğrenme algoritmaları genel olarak 3 grupta sınıflandırılır:

- Gözetimli Öğrenme.
- Gözetimsiz Öğrenme.
- Reinforcement Learning

### 1.1. Gözetimli Öğrenme(Supervised Learning)

Kontrollü öğrenmede denilen bu yöntemde verilen X değerleri kümesinden istenilen Y sonuç kümesinin elde edilebilmesi için objektif bir fonksiyon öğrenilmesidir. Gözetimli öğrenme denen yöntemde yapay bir eğitim dataseti vardır. Eğitim datasetinde her bir örnek için giriş ve çıkış değerleri bulunur. Bu giriş ve çıkış değerleri arasında da bir ilişki olduğu varsayılır. Gözetimli öğrenmede veri datasetinde doğru çıktının ne olması gerektiği konusunda bilgimiz bulunmaktadır. Gözetimli öğrenme yönetiminde, öğrenilmek istenen kavramla ilgili elde edilen gözlemler bir eğitim kümesi olarak sisteme girilir. Eğitim kümesinde her bir örnek için istenen sonuç değerleride verilir. Bu veriler kullanılarak giriş ile sonuç arasında bir bağlantı oluşturulur. Oluşturulan bağlantı kullanılarak gelecekte karşılaşılabilecek X girişlerinin karşılık geldiği Y değerleri tahminlenebilir. Gözetimli öğrenme regresyon ve sınıflandırma şeklinde ikiye ayrılır. Regresyonda giriş değerlerini bazı sürekli fonksiyonlara uygulamaya çalışılır. Sınıflandırmadaysa sınıflar ayrı şekildedir. Giriş değerlerini ayrı kategorilere haritalamaya çalışır. Her bir gözleme birer sınıf atanır.

### 1.2. Gözetimsiz Öğrenme(Unsupervised Learning)

Gözetimsiz öğrenme veri yığınları arasındaki dolaylı ilişkileri keşfeder ve diğer değişkenler üzerindeki en büyük nedensel etkiye sahip değişkenlerdeki davranış değişikliğini tanımlayan kuralları geliştirir. Gözetimli öğrenme yönteminde X giriş değerleri gözlemlendiği gibi Y çıkış değerleri de gözlemlenir. Gözetimsiz öğrenme yönteminde ise sadece X giriş değerleri üzerinde durulur. X ile bağlantılı bir Y değerleri kümesi bulunmadığı için, Y çıkış değerleri tahmin edilmeye çalışılmaz. Gözetimsiz öğrenme yöntemi, sonuçları bilinmeyen problemlerin yapısı hakkında fikir sahibi olma imkânı sağlar. Amaç elde edilen ölçümlerle ilgili bilgiler keşfetmektir. Örneğin elde edilen gözlemleri alt gruplara bölme imkânı araştırılır ya da verilerin bilgi elde edilecek şekilde gözlemlenmesine çalışılır. Problemleri çözebilmek için X değerleri arasındaki bağlantıdan yararlanır.

### 1.3. Takviyeli Öğrenme (Reinforcement Learning)

Takviyeli öğrenme, etrafını algılayarak kendi başına kararlar alabilen bir sistemin, hedefine ulaşabilmesinde doğru kararlar almayı nasıl öğrenebileceğini gösterir. Takviyeli öğrenme metotları, hakkında bilgi sahibi olmadıkları dinamik veya belirsiz ortamlarda uygulanabilirler. Bu yöntem robotik, oyun programlama, hastalık teşhisi ve fabrika otomasyonu gibi alanlarda sıklıkla kullanılır.

Takviyeli öğrenmede bir eğitmen bulunur fakat denetimli öğrenmedeki gibi sisteme çok detay vermez veya veremez. Bunun yerine öğrenen sistem bir karar verdiğinde bu kararın doğru olduğu durumlar için sistemi ödüllendirir ve yanlışlar için de cezalandırır. Takviyeli öğrenme metotları çevresiyle etkileşim içinde bulunarak tecrübesini artırır. Amaç, öğrenen sistemin denediği olası durumların hedef olup olmadığının kontrolü ve denenen doğru veya yanlış tüm durumların hatırlanmasıdır.

Karar verilen durumlar artarda gelen diziler şeklinde hatırlanırsa sonunda başarıya ulaşan duruma bağlı olarak hatırlanan ardışıl durumlar dizisindeki her karara büyük ödülün hisseler dağıtılır. Sürekli ödül alan hareketleri seçerek başarısını maksimum değere çıkarmaya çalışır.

Ödül veya cezayı belirleyen genellikle bir değer (amaç veya hedef de denilir) fonksiyonu ( $V$ ) vardır. Davranış politikası ( $\pi$ ) ile  $t$  anındaki durumda iken ( $s_t$ ) yapılabilecek hareketlerden ( $a_t$ ) optimumu seçilebilir. Takviyeli öğrenme, değer fonksiyonunun ürettiği en büyük ödüle sahip davranış politikasını tercih eder. Optimum davranış politikasının tercihi şöyle ifade edilir.

$$\Pi = \operatorname{argmax}(V(s_t, a_t))$$

### 1.4. Makine Öğrenmesi alanında kullanılan diğer algoritma türleri

- ÖRNEK TEMELLİ
- BAYESYEN
- BOYUT AZALTMA
- KARAR AĞAÇLARI
- KÜMELEME



- DERİN ÖĞRENME
- SİNİR AĞLARI
- TOPLULUK
- REGRESYON
- DÜZENLEME
- KURAL TABANLI SİSTEM

#### 1.4.1. Regresyon


Regresyon, iki (ya da daha fazla) değişken arasındaki doğrusal ilişkinin fonksiyonel şeklini, biri bağımlı diğeri bağımsız değişken olarak bir doğru denklemi olarak, göstermekle kalmaz, değişkenlerden birinin değeri bilindiğinde diğeri hakkında kestirim yapılmasını sağlar.

Kısaca verilerimizi x-y kordinatında değerlerine göre dağıttığımızı düşünelim. Bu veriler birbiri arasında bir uzaklıkları vardır. Amacımız tüm verilerden geçebilecek ya da en doğru şekilde geçen bir doğru çizmektir. Buradaki doğru çizmek olayı lineer bir yapıda regresyon gerçekleştirdiğimiz içindir. Amacımız eğitim verilerimizin düzlem üzerindeki dağılımını matematiksel bir modele benzetmek böylelikle doğru regresyon türünü bulabiliriz.

Lineer regresyon bir veya birden fazla (bağımsız) değişken ile başka bir (bağımlı) değişken arasındaki bağlantıyı modellemek için kullanılan bir yöntemdir. Bunun için öncelikle lineer regresyon fonksiyonunu tanımlayalım:

$$h_0(x) = \theta_0 + \theta_1 x$$

Bu formülde  $h(x)$  fonksiyonuna hipotez fonksiyonu denir. Genelde hipotez, önerilen ve sonrasında yapılan çalışmalarla değiştirilen teorilere denir. Makine öğrenmesi literatürüne uyarlayacak olursak hipotez, verilen giriş değerine karşılık olarak fonksiyonun döndüğü cevaptır. Bu cevap, örneklerle birlikte geliştirilir. En sonunda elde edilen hipotez, genelleştirilmiş olan ve örnekleri en iyi şekilde temsil eden hipotez olur.



Şekil 1- Hipotez fonksiyonu

X eksenindeki değerler bizim giriş değerlerimiz, Y eksenindekilerde bu değerlere karşılık gelen çıkış değerleri olsun. Burada amaç, kırmızıyla gösterilen ve giriş değerlerini en iyi şekilde temsil eden doğruyu bulmak. Bu durumda X ve Y değerleri ile (eğitim dataseti) eğitilen fonksiyon, daha öncesinden görmediği bir girişe karşılık gelebilecek değeri tahmin edebilir.

Basitlik olması açısından  $\theta_0=0$  olarak alınırsa, fonksiyon merkezden geçen bir doğru fonksiyonuna dönüşmektedir:

$$h_{\theta}(x)=\theta_1x$$

Bu fonksiyonda X değerleri bize verilmekte ve bizim yapmamız gereken  $\theta$  parametrelerinin değerlerini bulmak olacaktır. Bu durumda, böyle bir doğru fonksiyonunu nasıl elde edeceğiz, asıl soru bu. Bu sorunun cevabını bulmak için cost fonksiyonunu bilmek gerek. Basit olarak cost fonksiyonu, yukarıda belirttiğimiz hipotezin doğru sonuçlar verip vermediğini test eder. Burada en küçük kareler yöntemiyle, hipotez ile gerçek değer arasındaki mesafeyi hesaplayarak yapar.

Lineer regresyon için cost fonksiyonu şu şekilde hesaplanabilir:

$$J(\theta_1) = \frac{1}{2m} \sum_{i=0}^m (h(x(i)) - y(i))^2$$

Bu formülle ifade edilen fonksiyonda, m eğitim amaçlı kullanılan örnek giriş/çıkışların (x,y) sayısını ifade eder. Formüldeki 1/2 katsayısı daha sonra türev alınırken işimize yarayacak.

Yukarıda belirtilen formülde bütün eğitim setlerinin (m) örnekleri için cost fonksiyonunu bulduk.

Bir sonraki bölümde konuyla ilgili geçmişte yapılan araştırmalardan ve bunların değerlendirilmesinden bahsedilecektir.



## İKİNCİ BÖLÜM

### KAYNAK ARAŞTIRMASI

Bu bölümde bahsedilecek konular kısaca;

- Arthur Samuel in Yapay Zeka alanındaki oyunu
  - Alan Turing in Makine Öğrenme alanındaki Hesap Yapan Makine ve Zeka makalesi
  - Raymond S. T. Lee nin Makine Öğrenme alanındaki iJADE Stock Advisor makalesi
  - Edward Tsang in Stok Tahmini isimli makalesi
  - Michael David Rechen in makalesi
  - N. K. Zadeh, M. M. Sepehri ve H. Farvareh in ilaç tahmini alanındaki çalışması
  - Lin Xu nun çalışması
  - Alexander Renz ve Ye Chen in çalışması
  - M.Z. Babai ve Y. Dallery nin çalışması
  - T. Suesut, S. Gulphanich, P. Nilas, P. Roengruen, K. Tirasesth in çalışması
- şeklindedir.

Yapay Zeka alanındaki ilk alıřmalardan birisi Arthur Samuel in geliřtirdiđi dama oyunudur[1]. Arthur Samuel, makine ğrenmesini bilgisayarın aıka programlanmadan bir iři ğrenme yeteneđi olarak tanımlamıřtır. Arthur Samuel 1950 yılında bir dama oyunu geliřtirdi. Bu oyunu diđerlerinden farklı kılan zelliđi ise makine ğrenmesinin ilk rneklerinden biri olmasıydı. Oynanan oyunlardaki verileri analiz edip karřılařtırarak iyi ve kt pozisyonları ğrenen program sonunda Arthur Samuel'den daha iyi dama oynar hale geldi.

Makine ğrenme alanındaki ilk makalelerden bir diđeri ise 1950 yılında Alan Turing'e ait "Hesap Yapan Makine ve Zekâ" (Computing Machinery and Intelligence) [2] adlı alıřmasıdır. Bu alıřmada makineler dřünebilir mi? sorusunu sormakta ve konuyu anlatmak iin bir "benzetme oyunu (Imitation Game)" tarif etmekte. Bu oyuna gre makine, gnll bir insanla birlikte, yarıřmacının grř alanının dıřında bir yere saklanır. Yarıřmacı yalnız soru sormak suretiyle hangisinin insan hangisinin bilgisayar olduđunu saptamaya alıřır. Yarıřmacının sorular ve daha nemlisi aldıđı yanıtlar, tamamen ses gizlenerek, yani ya bir klavye sisteminde yazılarak veya bir ekranda gsterilerek verilir. Yarıřmacıya bu soru-cevap oturumunda elde edilen bilgiler dıřında her iki taraf hakkında hibir bilgi verilmez. Dizi halinde tekrarlanan testler sonucunda yarıřmacı, tutarlı bir řekilde insanı saptayamadıđı takdirde makine Turing testini gemiř sayılır. Bu oyun dzenli olarak her yıl gerekleřtirilen Loebne Prize isimli yarıřmanın temelini oluřturur.

Makine ğrenme kullanarak Stok Tahmini yapma ile ilgili alıřmalardan birisi Raymond S. T. Lee nin 2004 yılında yayınladıđı iJADE Stock Advisor isimli makalesidir[5]. Bu makalede, akıllı Web madenciliđi ve diđer akıllı e-ticaret uygulamaları iin kapsamlı bir "akıllı" ajan tabanlı stok danıřmanlıđı uygulaması geliřtirmiř: iJADE Stok Danıřmanı. Stok tahmini iin daha nceden hibrid bir RBF tekrarlayan sinir ađı geliřtirilmiřti. alıřma geleneksel RBF ađının bir uzantısı olup iki ana zellik ekliyor: İlk olarak, geri yayılım algoritmasında bir 'unutma faktr' ortaya ıkıyor. İkincisi, tekrar eden zaman farkı mekanizması iinde bir "rrme" ortaya ıkmaktadır. Her iki ekleme de, daha yeni gzlemlerin nemini etkin biimde arttırmaktadır.

Bir diđer alıřma ise Edward Tsang ın 2009 yılında yayınladıđı Stok Tahmini[6] ile ilgili makalesidir. Tsang, giriř niteliđindeki bir literatr taramasından yola

çıkarak, basit bir Yapay Sinir Ağları tabanlı bir stok tahmin çözümü sunuyor. Temel ve teknik analiz kavramları ve verimli pazar hipotezi incelenmiş, doğrusal modeller kullanılarak geleneksel zaman serileri tahmini ve stok hareketi tahmini konusundaki Yapay Sinir Ağlarının yakın zamandaki popülaritesi tartışılmıştır.

Michael David Rechenh in 2014 yılında stok analizi ve tahmini için makine öğrenme sınıflandırma teknikleri adlı tez çalışmasında[7] ileriye yönelik öngörülebilirliği araştırıyor ve daha sonra, gelecekte stok yönünün öngörülen göstergelerinin yanı sıra, kullanılacak bir karar destek çerçevesi tasarlıyor. Çerçeve, geçmiş verilerin rassal alt gruplarını kullanarak ve benzer stokları kapsayan ve bu temel sınıflandırıcıların en iyisini optimum olarak birleştiren binlerce geleneksel taban sınıflandırıcısı (SVM, Karar Ağacı ve Sinir Ağı) oluşturarak değişikliklere uyum sağlıyor. Ayrıca, stok veri akışlarıyla, özellikle sınıfsal dengesizlik, nitelik yaratma, boyut azaltımı gibi sorunları da ele almaktadır.

N. K. Zadeh, M. M. Sepehri ve H. Farvaresh ilaç satışı için bir tahmin yaklaşımı geliştirmiştir [8]. Çalışmalarının amacı, PDC satışlarını tahmin etmek için yeni bir yöntem önermektir. Sunulan yöntem, ağ analiz araçlarının ve zaman serileri tahmin yöntemlerinin bir kombinasyonudur. Her ilaç için yeterli geçmiş satış kayıtlarının bulunmaması nedeniyle, klik takımlarını ve grup üyelerini bulmak ve satış öngörülerinde paydaşların satış verilerini kullanmak için araştırmaya dayalı ağ tabanlı bir analiz yapılır. Daha sonra, zaman serisi satış tahmin modelleri ARIMA metodolojisi, sinir ağı ve gelişmiş bir melez sinir ağı yaklaşımı gibi üç farklı yaklaşımla oluşturulur. Her ilacın ve onun kayıt cihazlarını geçmiş kayıtlara uygulayarak sunulan melez yöntem, doğrusal ve doğrusal olmayan satış modellerini doğru bir şekilde yakalamayı kolaylaştırır. Önerilen yöntemin performansı, İran'daki önde gelen PDC' ler den biri tarafından sağlanan gerçek bir veri kümesi tarafından değerlendirildi. Sonuçlar, önerilen yöntemin ilaç satışlarını doğru bir şekilde tahmin ederken, geçmiş kayıtların sayısının düşük olabileceğini gösterdi. Burada bizim çalışmamızdan farklı olarak stok çıkışından ziyade satışların tahminine yönelik bir çalışma gerçekleştirilmiş.

LIN XU 2006 da Yapay Sinir Ağları teknikleriyle sıfır stok yönetimi tabanlı bir yaklaşım geliştirdi[18]. Çalışmasında tedarik zincirinde sıfır stok kavramı uzun analiz edilmektedir. Tedarik zincirindeki envanter tahmininde bir sinir ağı tahmin

modeli oluşturulmuş ve detaylı olarak analiz edilmiştir. Sinir ağının parametresi, BP algoritmasının yerel minimum ve yavaş yakınsamasını önlemek için Gerçek Değerli Genetik Algoritma üzerinden geçer. Simülasyonda, geleneksel bir BP algoritması eğitimi sinir ağı, GA tabanlı sinir ağı ve tahmin sonuçları ile karşılaştırılmıştır. Sonuçlar ve analizden GA tabanlı sinir ağı tahmin modelinin iyi bir hız ve hassaslığa sahip olduğu ve simülasyonun tatmin edici bir tahmin sonucu verebileceği sonucuna varılmıştır.

Alexander Renz ve Ye Chen 2008 deki erken uyarı sistemine dayalı stok yönetim çalışmasında[19] yazılım üzerinde çalışan bir envanter ajanı, programlanabilir bir işlemcinin, bir envanterdeki stok ile ilgili envanter verilerini almasına, envanter verisini bir koşullu olasılıksal tahmin edici istatistiksel algoritmaya uygulamasına, tahmin edilen envanter seviyesini hesaplamasına ve kullanmasını sağlamak için çalıştırılabilen talimatları içermektedir. Envanter için ilave stok sipariş edip etmemeyi belirlemek için hesaplanan tahmini envanter seviyesini istatistiksel algoritma, verileri işlemek için bir koşullu olasılık modelini kullanır. Bizim çalışmamızda ise stok siparişi için stok seviyelerinin tahmin edilmesi ve minimum seviye uyarı kontrolü yöntemi önerilmektedir. Bu işlemler, öğrenme tabanlı yöntemi ile gerçekleştirilmektedir.

M.Z. Babai ve Y. Dallery 2006 da stok yönetimi politikaları hakkında bir literatür incelemesi [20] sunuyorlar. İki yaklaşım üzerinde duruluyor: standart stok yönetimi yaklaşımı ve ön talep bilgi temelli yaklaşımı. Özellikle önceden talep edilen bilgi tabanlı yaklaşımı üzerinde duruluyor ve taleplerin tahminler şeklinde verildiği tek aşamalı ve tek kalemlili bir stok sistemi inceleniyor. İki tahmin tabanlı stok yönetimi politikası ise dinamik bir yeniden sipariş noktası politikası olan  $(r_k, Q)$  ve dinamik bir sipariş politikası olan  $(T, S_k)$  sıralanıyor. Bu politikalar standart  $(r, Q)$  ve  $(T, S)$  politikaları ile karşılaştırılıyor. Ayrıca, bazı durumlarda, öngörme temelli stok yönetimi politikalarının ve standart stok yönetimi politikalarının eşdeğer olduğunu da gösteriyorlar. Ayrıca, emniyet miktarı olarak adlandırılan yeni bir emniyet parametresi, klasik emniyet stoğu parametresiyle karşılaştırılıyor ve bu güvenlik miktarını hesaplamak için pratik bir yaklaşım öneriliyor. Bizim çalışmamızda öğrenme metoduyla çok kalemlili hesaplama sistemi gerçekleştirilmiştir. Ayrıca, buradaki emniyet parametresi ile benzer görev gören stok minimum seviyeleri parametresi kullanılıyor.

T. Suesut ve arkadaşları 2004 yılındaki çalışmasında[21], sürekli gözden geçirme ve tahmin sistemini kullanarak depo otomasyonundaki stok seviyesini kontrol etmek için bir teknik geliştirmişler. Depoda depolanan ürün talebi, müşterilerden gelen siparişlere bağlıdır. Her ürün için talep Poisson sürecini takip eder ve teslimat süresi bilinir. Talep tahmini, sipariş eğilimini tahmin edebilir ve otomatik depo kontrol sistemine bağlı stoğun yeniden sipariş noktasını (YSN) yeniden tanımlayabilir. Otomatik depo, bilgisayar entegrasyonu imalat sisteminde (BEİS) önemli bir rol oynar. BEİS'in fonksiyonları arasında, üretim planlaması, malzeme ihtiyaç planlaması, iş emri üretimi, proses kontrolü, kalite kontrol, sevkiyat planlaması, depo ve stok yönetimi ve malzeme maliyet muhasebesi yer almaktadır. Geliştirdikleri yöntem otomatik depo kontrolü ve stok yönetimi talebi tahmin sisteminin uygulanmasına odaklanmaktadır.

Robert Fildes, Charles Beard 1992 yılındaki makalelerinde[22], üretim ve stok kontrol tahmin probleminin, bilginin kullanımındaki diğer tahmin uygulamalarından nasıl farklı olduğunu ve stok tipi verilerinin özelliklerini dikkate almaya devam ettiğini göstermişler. Tüm veri serilerine tek bir tahmin metodu uygun değildir ve makale, tahmin metodolojisindeki son gelişmelerin doğruluğunun nasıl artırabileceğini tartışır. Veri dizisinin zaman dizisi öyküsünün ötesinde veri tabanını genişletme yaklaşımlarını ele alır. “İdeal” bir tahmin sistemi tartışması ile sonuçlanır ve üretim ve stok kontrolünde kullanılan birçok popüler programın bu idealden ne kadar uzakta olduğu tartışılır.

Jui-Chan Huang ve arkadaşları 2017 deki çalışmalarında[23] şirketlere stok kontrolünü iyileştirme konusunda yardımcı olmayı amaçlamaktadır. Bu çalışmalarında farklı bir yol olarak stok tüketimine göre değil üretime göre stok girişlerinin yönetimini sağlamayı denemişler. İlk olarak, portföyde sunulan ürünler gruplara ayrılıyor, R programlama dili yardımıyla farklı ürünlerin gelecekteki satışlarını teşvik etme ve tahminlemeler gerçekleştiriliyor. Tüm ürün kalemlerinin konsolidasyonu ve faaliyete dayalı sınıflandırmalara göre gruplandırılması, kategorizasyon sonuçlarına göre gelecekteki satışların simülasyonu ve tahminleri ile farklı formülasyonların oluşturulmasına yönelik sınıflandırmaların ve tahminlerin sonuçlarına göre stok seviyelerinin yönetilmesi için simülasyonlara ve tahminlere dayanan kontrol teknikleri uygulanmaktadır. Sonuçlar stok kontrolünü geliştirmek için ve stok yönetimi için kullanılabilir.



Marisol Valencia-Cárdenas, Francisco Javier Díaz-Serna & Juan Carlos Correa-Morales 2015 teki makalelerinde[24] çoklu ürünlere yönelik talebin model tahminlerinin bir karşılaştırmasını sunarak, aşağıdakiler arasında en iyi olanı seçmektedir: otoregresif entegre hareketli ortalama (ARIMA), üssel düzleştirme (ES), bir Bayesian regresyon modeli (BRM) ve bir Bayesian dinamik doğrusal model (BDLM). Bu amaçla, zaman serilerinin normal olarak dağıtıldığı durumlar ilk olarak simüle edilir. İkinci olarak, bir benzin servis istasyonunun üç ürünü için satış tahminleri, dört model kullanılarak tahmin edilmekte ve BRM'nin en iyi model olduğu ortaya çıkmaktadır. Daha sonra çoklu ürün stok modeli optimize edilmiş. Sipariş, stok, maliyetler ve karlarla ilgili politikaları tanımlamak için, çözümü geliştirmek için bir Tabu arama öğelerini birleştiren Bayeşçi arama elemanları kullanılır. Bu stok modeli optimizasyon süreci daha sonra Kolombiya'daki bir benzin servis istasyonuna uygulanır. Bu son iki çalışmada bizim çalışmamızdan farklı olarak stok çıkışları yerine satış değerlerine yönelik bir tahminleme gerçekleştiriliyor.

Bu bölümde bahsedilen çalışmalar Yapay Zeka ve Yapay Sinir Ağları alanında geçmişte gerçekleştirilen tahminlemeye yönelik araştırmalar olup stok tahmini alanında yeterli miktarda çalışma bulunmamaktadır. Stok tahmini konusundaki araştırma eksikliğinden dolayı bu alanda regresyona dayalı tahminleme yöntemiyle çalıştırma geliştirilmiştir.

Bir sonraki bölümde yapılan çalışma ve önerilerden bahsedilecek.

## ÜÇÜNCÜ BÖLÜM

### VERİ ANALİZİ VE MODELLEME

Bu bölümde kısaca;

- Önerilen Model
- SMART ADVISOR
- Malzeme Tanımı
- Malzeme Girişi
- Malzeme Çıkışı
- Stok Durum Raporu

konu başlıklarından bahsedilecek.

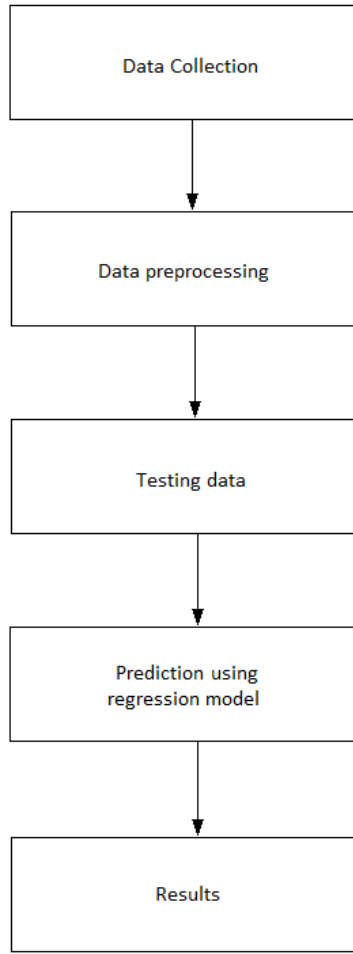
Önceki bölümde makine öğrenme algoritmaları ve lineer regresyon algoritmasından bahsedildi. Bu bölümde, sistemimize bunları nasıl uyarladığımıza bakalım. Bunun için ilk olarak kendi modelimizi oluşturuyoruz.

### **3.1. Model**

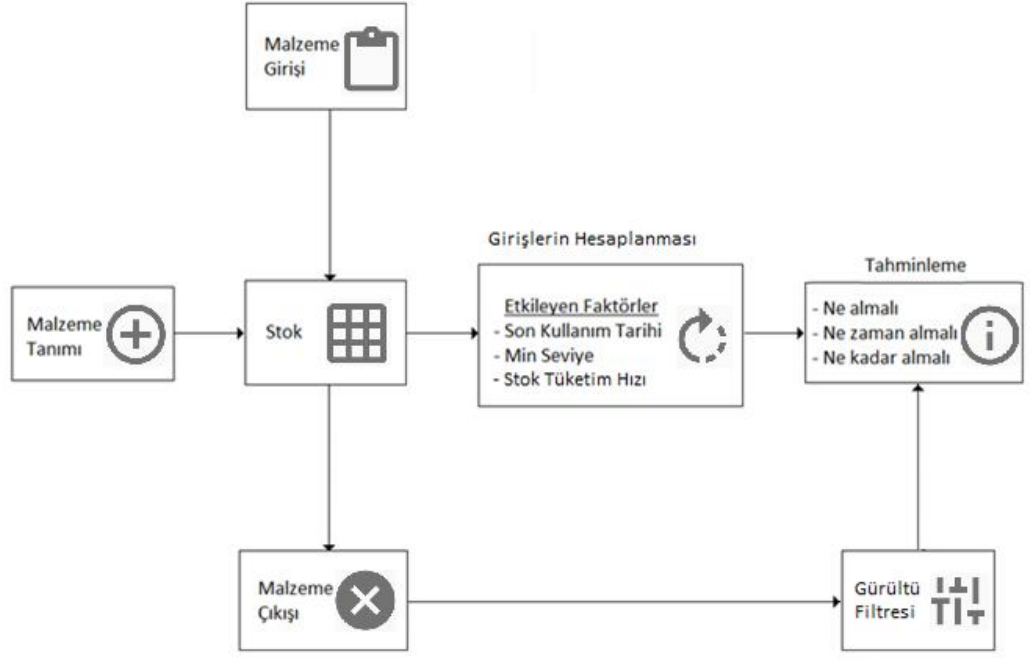
Hesaplama akış şeması şekil 2'deki aşağıdaki diyagramdır.

Hesaplamalar için bir test veri seti oluşturduk. İlk önce hesaplamalarda kullanılmak üzere belli miktarda malzeme ve ilaç tanımlanmıştır. Ardından, farklı tarihlerde bu ilaç ve malzemelerden farklı miktarlarda satın almalar yapıldı. Ve farklı tarihlerde, bazı malzemelerden tüketim yapıldı. Son olarak Smart Advisor uygulamasının sonuçları izlenmiş ve analiz edilmiş ve tahmini oranları tartışılmıştır.

Çalışmamızda stok altyapısı üzerinde, sistemin davranışını analiz ederek ileriye yönelik tahminlemelerde bulunacağız. Genel olarak aşağıdaki şema ile ifade edebiliriz.



**Şekil 2- Veri Akış Seması**



Şekil 3- Çalışma Yapısı

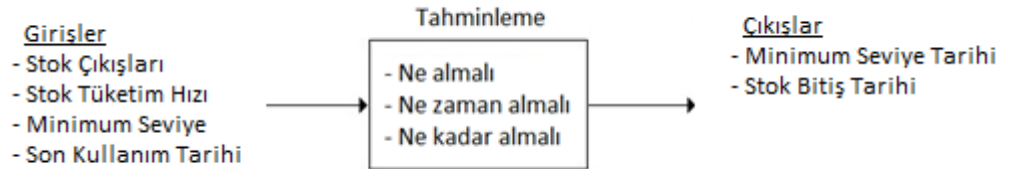
- **Malzeme Tanımı:** Sistemde tutulan malzemelerin daha önceden tanımlanması gerekir. Malzeme tanımında en önemli noktalardan birisi tahminleme algoritmasını da etkileyecek faktörlerden olan minimum seviye tanımıdır.

Minimum seviye nedir?

Bir malzemenin sipariş edildiği andan itibaren malzemenin teslim alındığı ana kadar geçen süre temin süresidir. Temin süresi kadar süre zarfında malzemeden ne kadar harcanıyorsa bu miktar o malzeme için minimum seviyedir. Yani malzemenin minimum seviyesi olarak belirlenen miktar, malzeme sipariş edildiği andan itibaren teslim alınışına kadarki sürede ihtiyacı karşılayabilmelidir. Buradaki asıl amaç ise malzeme minimum seviyeye gelmeden sipariş yapılması ki stoktaki malzeme hiçbir zaman sıfırlanmasın. Minimum seviye bilgisi malzemeye göre değişir, bu yüzden malzeme bazında tutulur.

- **Malzeme Girişi:** Sisteme girişler genelde fatura ile olur. Sisteme girişte önemli noktalardan biriside alınan malzemenin son kullanma tarihi bilgisinin de girilmesidir. Çünkü malzeme kullanımında ilk önce son kullanma tarihi en yakın olanlar kullanılır.
- **Malzeme Çıkışı:** Sistemdeki malzemelerin kullanılmasıdır.
- **Tahminlemeyi Etkileyen Faktörler:** Stok Tüketim Hızı malzemelerin birim zamanda kullanılma hızıdır. Malzemenin ilk kullanıldığı tarihle son kullanıldığı tarih arasındaki süre, o aralıkta kullanılan(çıkış yapılan) toplam malzeme miktarına oranlanarak hesaplanır. Bu çalışmada biz günlük seviyede hesaplayacağız. Bununla birlikte Minimum Seviye ve Son Kullanım Tarihi tahminlemeyi etkileyen diğer faktörlerdir.
- **Tahminleme:** En düşük maliyetle, en etkin stok yönetimi için hangi malzemeden ne zaman ne kadar alınması gerektiğini tahmin ediyoruz.

Tahminleme kısmının giriş ve çıkışları aşağıdaki gibidir.



Şekil 4- Tahminleme

Sistemdeki stok çıkışları tahminleme yapısı için giriş(X) değerleridir. Tahminleme yapısı malzeme çıkışlarını inceler, anlık stoklarını takip eder, stok tüketim hızlarını hesaplar, minimum seviye değerlerine göre de ne zaman minimum değere geleceğini hesaplar.

- **Gürültü:** Sistemdeki malzemelerin çıkışlarına bakarak günlük tüketim hızları hesaplanır. Bu bilgi o malzemenin birim zamandaki ortalama tüketim hızıdır. Bu hızın aşırı üstündeki ve aşırı altındaki çıkışlar tahminleme yapısı için

gürültü kayıtlarıdır. Bu gürültü kayıtlarını tahminleme yapısının dışında tutmak için filtreleme yapısı vardır. Stok tüketim hızının ne kadar altı ya da üstündeki kayıtlar filtrelenecek bunun seviyesini çıkışlara bakarak belirliyoruz.

### **3.2.Smart Advisor**

Bu çalışmada anlattığımız aşamaları Java ile kendi geliştirdiğimiz Ek-1 de görülen Smart Advisor adlı uygulamamızla gerçekleştirdik. Stok takip uygulaması olarak çalışan bu yapıda klasik sisteme giriş ve çıkış işlemlerinin yanında mevcut stok verilerine dayanarak ileriye yönelik tahminler ürettik. Bu hesaplamalarda kullanılmak üzere test amaçlı bir veri seti oluşturduk. Sistemde kullanılmak üzere örnek miktarda malzeme tanımı yapıldı. Daha sonra bu malzemelerden farklı tarihlerde belli miktarlarda alımlar yapıldı ve farklı tarihlerde bu alınan malzemelerden belli miktarlarda kullanımlar yapıldı.

Şimdi Smart Advisor uygulamasına biraz göz atalım.

### **3.3.Malzeme Tanımı:**

Ek-2 de malzemelerin tanımlandığı ve minimum seviyelerinin belirlendiği ekran görülmektedir. Ayrıca malzemelerin türlerine göre sınıflandırılması yine bu ekranda gerçekleştirilir.

### **3.4.Malzeme Girişi:**

Ek-3 te malzeme girişlerinin yapıldığı ekrandır. Firmalardan alınan malzemelerin fatura girişleri yapılır. Faturanın detayında hangi malzemedan kaç adet alındığı ve tutar bilgileri de girilir. Alınan malzemelerin son kullanma tarihleri bu ekrandan girilir.

### **3.5.Malzeme Çıkışı:**

Ek-4 te malzemelerin kullanımının yapıldığı ekrandır. Bir başka deyişle sistemden malzeme çıkışının yapıldığı ekrandır. Kime hangi malzemedan ne kadar kullanılmış bilgileri girilir.

### 3.6.Stok Durum Raporu

STOCK STATUS												
CODE	NAME	TYPE	MIN LEVEL	COUNT	CONSUMPTION	STATUS	DAYS TO	DAYS TO	MIN LEVEL	DATE	STOCK	END DATE
					SPEED		MIN LEVEL	STOCK END				
21	PANTOPRAZOL	DRUG	53	19	0.55	Under Min Level	-63	35	04/04/2017	10/07/2017		
15	EPOETIN BETA	DRUG	55	33	0.48	Under Min Level	-47	70	20/04/2017	14/08/2017		
19	NAPROKSEN	DRUG	51	34	0.69	Under Min Level	-25	50	12/05/2017	25/07/2017		
8	DRENS	MEDICAL MATERIAL	31	25	0.68	Under Min Level	-9	37	27/05/2017	12/07/2017		
9	GLOVES	MEDICAL MATERIAL	35	33	0.88	Under Min Level	-3	49	02/06/2017	24/07/2017		
3	KAGIT HAVLU	MATERIAL	20	20	0.45	Available	0	44	05/06/2017	20/07/2017		
22	PROPOFOL	DRUG	38	39	0.50	Available	2	79	07/06/2017	23/08/2017		
2	KATATER	MEDICAL MATERIAL	15	18	0.46	Available	7	39	12/06/2017	15/07/2017		
27	X PHE KID SE MAMA	DRUG	47	58	1.38	Available	8	42	13/06/2017	17/07/2017		
23	SODYUM FOSFAT	DRUG	39	46	0.83	Available	9	56	14/06/2017	31/07/2017		
16	LENALDOMIT	DRUG	66	76	0.80	Available	13	96	18/06/2017	09/08/2017		
5	KAN SETİ	MEDICAL MATERIAL	24	31	0.48	Available	15	65	20/06/2017	09/08/2017		
18	MENOTROPIN	DRUG	41	52	0.65	Available	17	81	22/06/2017	25/08/2017		
6	DIYALİZ MALZEMESİ	MEDICAL MATERIAL	27	36	0.48	Available	19	75	24/06/2017	20/08/2017		
4	SONDA	MEDICAL MATERIAL	14	23	0.47	Available	19	50	25/06/2017	25/07/2017		
1	ASPIRİN	DRUG	10	19	0.45	Available	20	43	26/06/2017	18/07/2017		
20	OKTRECOTID	DRUG	42	64	1.00	Available	22	64	27/06/2017	09/08/2017		
28	ZIPRASİDON	DRUG	48	77	1.29	Available	23	60	28/06/2017	04/08/2017		
24	TEMÖZOLOMİD	DRUG	40	57	0.72	Available	24	80	29/06/2017	24/08/2017		
29	ÇARŞAF	MATERIAL	46	99	2.08	Available	25	48	01/07/2017	23/07/2017		
14	DEKSTROZ (GLUKOZ)+SODYUM KLORÜR	DRUG	44	66	0.83	Available	27	80	02/07/2017	25/08/2017		
12	BLDEZOND	DRUG	28	50	0.82	Available	27	61	02/07/2017	06/08/2017		
30	PERDE	MATERIAL	11	69	1.69	Available	34	41	10/07/2017	16/07/2017		
13	CADI FİNGİ DISTİLATI	DRUG	33	56	0.67	Available	35	84	10/07/2017	29/08/2017		
26	VALSARTAN	DRUG	32	63	0.82	Available	38	77	13/07/2017	22/08/2017		
25	URKINAZ	DRUG	34	75	1.06	Available	38	70	14/07/2017	14/08/2017		
11	ASETAZOLAMİD	DRUG	19	49	0.60	Available	51	83	26/07/2017	27/08/2017		
17	MANNİTOL	DRUG	13	66	1.04	Available	51	64	27/07/2017	08/08/2017		
10	ALBÜMİN	DRUG	27	50	0.45	Available	52	113	27/07/2017	26/09/2017		
7	IV KANUL	MEDICAL MATERIAL	16	41	0.49	Available	51	84	27/07/2017	29/08/2017		

Şekil 5- Stok Durum Raporu

Sistemin stok durumunu gösteren ekrandır. Burada malzemenin kodu, adı ve türünün yanında minimum seviye bilgisi stoktaki adetlerini bu ekrandan görüyoruz. Sistemin malzemeler için hesapladığı ve tahminlemede kullanılacak olan stok tüketim hızını da yine bu ekranda görebiliyoruz. Eğer malzeme minimum seviyenin altına inmişse durumunu “Minimum Seviye Altında”, stokta tükenmişse de “Stokta Yok” şeklinde durumu alanında görebiliyoruz. Ve en sağda da tahminleme yapısının ürettiği bilgileri görüyoruz. Malzemenin minimum seviyeye inmesine kaç gün kaldığı ve stokta tükenmesine kaç gün kaldığı, minimum seviyeye hangi tarihte ineceği ve stokunun hangi tarihte tükeneceği bilgileri yer almaktadır. Dikkat edilirse minimum seviye altına düşenlerin minimum seviyeye inmesine kaç gün kaldığı bilgisi negatif görünür.

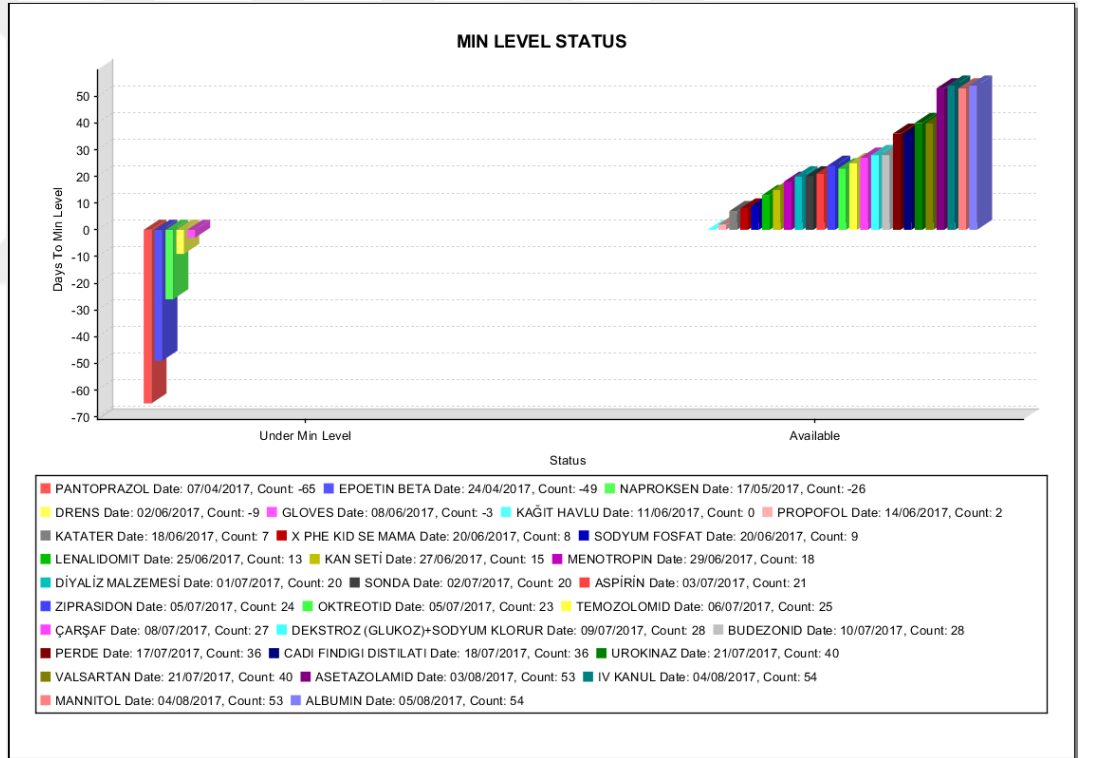


# DÖRDÜNCÜ BÖLÜM

## SONUÇLAR

Bu bölümde önerilen sistemin sonuçları ve analizleri ele alınmış sunulmaktadır. Bu bölüm dört alt başlıktan oluşmaktadır. Bunlar farklı şemalar halinde kullanıcıya değerli bilgiler sunarak bir kılavuz gibi yol gösterecektir. Bu şema geliştirilen yazılımımızdan elde edilir ve yöneticiye tedarik etmesi gereken ürünlerin, stokundaki ürünlerinin sayısı gibi önemli bilgiler sunmaktadır. Bunlardan ilki minimum seviye şemasıdır.

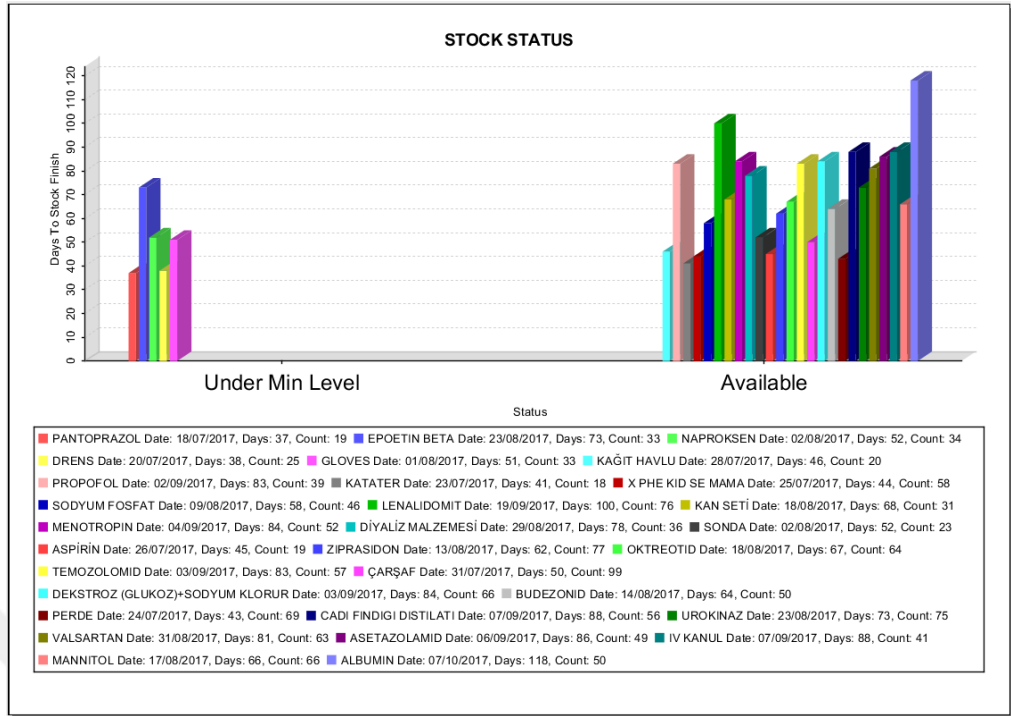
### 4.1. Minimum Seviye Şeması



Şekil 6- Minimum Seviye Şeması

Ekran malzemelerin minimum seviyelerini gösterir. Sistemdeki malzemelerin minimum seviyeye inmesine ne kadar gün kaldığı ve hangi tarihte minimum seviyeye ineceği bilgisi yer alır. Minimum seviyenin altına düşenler şekildeki gibi negatif ekseninde yer alır. Bu ekran satın alma zamanı gelen malzemeler hakkında bilgi verir.


## 4.2.Stok Durum Şeması



Şekil 7- Stok Şeması

Sistemdeki malzemelerin stok durum şemasını gösterir. Sistemdeki malzemelerin stokta ne kadar kaldığı bilgisi, hangi malzemenin stokunun tükenmesine kaç gün kaldığı ve hangi tarihte stokunun tükeneceği bilgilerini gösterir. Minimum seviye altına düşenler ayrı gösterilir.

### 4.3.Linear Regresyon Şeması



Şekil 8- Linear Regresyon Grafiği

Sistemin karakteristiğinin görüntülediği ekrandır. Bu şema oldukça önem arz eden ve birçok bilgiyi doğru bir şekilde kullanıcıya sunan bir şemadır. Filtre yapma özelliğiyle gürültülü verileri kayda almayarak doğru bir biçimde öğrenir hem de kullanıcıya doğru ve işe yarar bilgiler sunabilir. Bu bölümde farklı oranlarla bunu test edip sonuçları paylaşılmaktadır. Sistemdeki her bir çıkış, günlük tüketim hızı ve buna karşılık kaç adet çıkış yapıldığı bilgisiyle birlikte grafikte görünür. Bu iki değer oranı malzemenin o çıkışının ortalama çıkış değerinin ne kadar üzerinde ya da altında olduğu bilgisini verir. Malzemelerin bu oranlarının ortalaması bize sistemin genel karakteristiğini verir. Bu karakteristiğin fonksiyonu yukarıda değindiğimiz;

$$h\theta(x)=\theta_0+\theta_1x$$

formülüyle ifade edilir. Bu formülün katsayılarının hesaplanması arka planda uygulama tarafından gerçekleştirilir.

Malzeme çıkışlarının günlük tüketim hızı ile çıkış adetlerinden oluşan veri setine göre Şekil-9 deki gibi sistemin karakteristiğini gösteren fonksiyonun katsayıları hesaplanıyor. Burada  $\theta_0$  intercept ve  $\theta_1$  slope bilgisine denk gelir. Bu durumda aşağıdaki formülü ifade edebiliriz. Formülün hesaplama yöntemi ise şekil 9’de sunulmaktadır.

$$Y = \text{slope} * X + \text{intercept}$$

```
package com;

import java.util.HashMap;

import org.apache.commons.math3.stat.regression.SimpleRegression;

public class TryRegression {

    public static HashMap<String, Double> calculate(double[][] d) {

        HashMap<String, Double> ret = new HashMap<String, Double>();
        // creating regression object, passing true to have intercept term
        SimpleRegression simpleRegression = new SimpleRegression(true);

        // passing data to the model
        // model will be fitted automatically by the class
        simpleRegression.addData(d);

        // querying for model parameters
        System.out.println("slope = " + simpleRegression.getSlope());
        System.out.println("intercept = " + simpleRegression.getIntercept());

        ret.put("slope", simpleRegression.getSlope());
        ret.put("intercept", simpleRegression.getIntercept());

        return ret;

    }

}
```

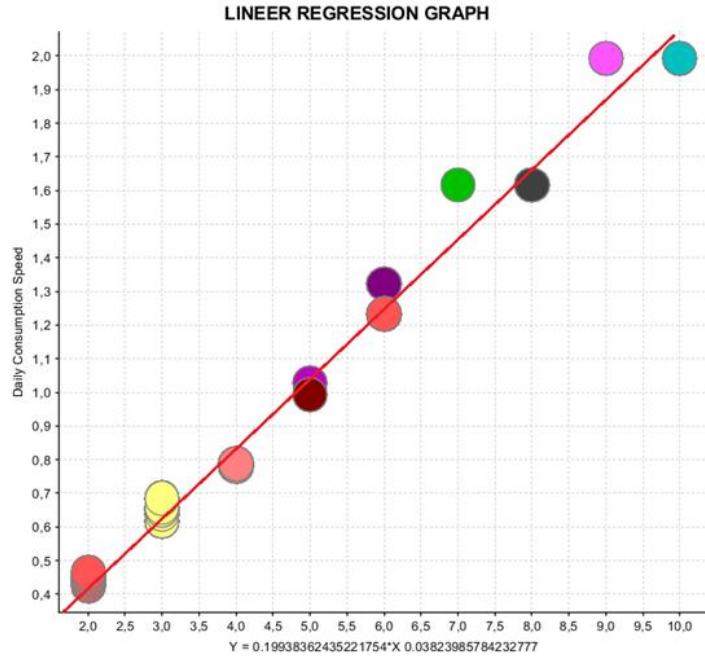
**Şekil 9- Formül Hesaplama**

Hesaplanan katsayılarla birlikte elde edilen fonksiyon Lineer Regresyon Grafiğinin hemen altın da gösterilir. Bu fonksiyonun grafiği olan lineer çizgi ise kırmızı renkte gösteriliyor. Bu kırmızı çizgi yukarıda bahsettiğimiz malzemelerin oranlarının ortalaması olan sistemin genel karakteristiğidir. Yani sistemdeki malzeme çıkışlarının değerlerinin o malzemenin günlük tüketim hızına olan oranlarının ortalaması bu lineer regresyon çizgisinin eğimini verir.

Bu durumda günlük tüketim hızına eşit değerdeki çıkışlar bu çizginin tam üzerinde görünür. Günlük tüketim hızının altında ya da üstündeki çıkışlarsa bu çizginin üstünde ya da altında görünür.

Bu çizginin aşırı altında ya da üstündeki kayıtlar sistem için gürültü kayıtlarıdır. Bu gürültü kayıtlarını elemek için uygulamada bir filtre yapısı vardır.

Bu filtre lineer regresyon çizgisinin belli oran altında ve belli oran üstündeki kayıtları hesaplama dâhil edecek, bunların dışındaki kayıtları hesaplama dışı bırakacak şekilde çalışır. Bu oranı yüzde olarak belirtiyoruz. Örneğin %10 luk bir oran için Lineer Regresyon grafiği Şekil-10 da ki gibi olacaktır.



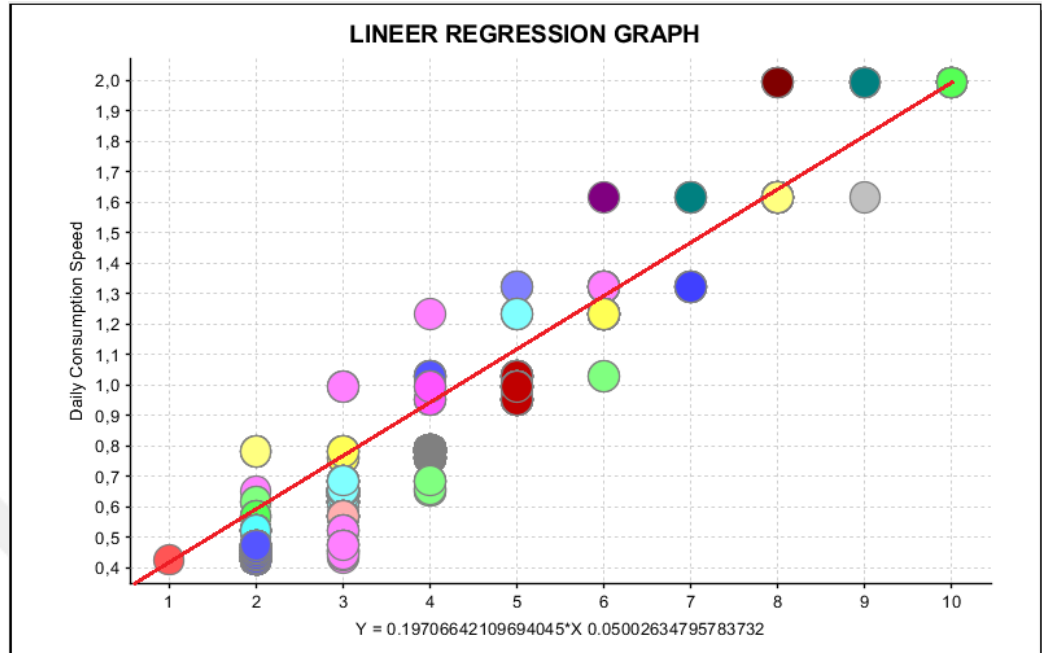
**Şekil 10- %10 luk Filtre ile Regresyon Grafiği**

Lineer regresyon grafiğinin yanında birde stok tahmin değerlerini kontrol edelim.

STOCK STATUS										
CODE NAME	TYPE	MIN LEVEL	COUNT	CONSUMPTION	STATUS	DAYS TO MIN LEVEL	DAYS TO STOCK END	MIN LEVEL DATE	STOCK END DATE	
21	PANTOPRAZOL	DRUG	53	19	0.37	Under Min Level	-92	51	12/03/2017	02/08/2017
15	EPOETIN BETA	DRUG	55	33	0.00	Under Min Level	-22	33	21/05/2017	15/07/2017
19	NAPROKSEN	DRUG	51	34	0.00	Under Min Level	-17	34	26/05/2017	16/07/2017
8	DRENS	MEDICAL MATERIAL	31	25	0.00	Under Min Level	-6	25	06/06/2017	07/07/2017
9	GLOVES	MEDICAL MATERIAL	35	33	0.00	Under Min Level	-2	33	10/06/2017	15/07/2017
3	KAĞIT HAVLU	MATERIAL	20	20	0.00	Available	0	20	12/06/2017	02/07/2017
22	PROPOFOL	DRUG	38	39	0.00	Available	1	39	13/06/2017	21/07/2017
2	KATER	MEDICAL MATERIAL	15	18	0.00	Available	3	18	15/06/2017	30/06/2017
23	SODYUM FOSFAT	DRUG	39	46	0.00	Available	7	46	19/06/2017	28/07/2017
5	KAN SETİ	MEDICAL MATERIAL	24	31	0.00	Available	7	31	19/06/2017	13/07/2017
1	ASPIRİN	DRUG	10	19	0.00	Available	9	19	21/06/2017	01/07/2017
4	SONDA	MEDICAL MATERIAL	14	23	0.00	Available	9	23	21/06/2017	05/07/2017
6	DIYALİZ MALZEMESİ	MEDICAL MATERIAL	27	36	0.00	Available	9	36	21/06/2017	18/07/2017
18	MENOTROPIN	DRUG	41	52	0.00	Available	11	52	23/06/2017	03/08/2017
24	TEMCOZOLMD	DRUG	40	57	0.00	Available	17	57	29/06/2017	08/08/2017
14	DEKSTROZ (GLUKOZ)-SODYUM KLORÜR	DRUG	44	66	0.00	Available	22	66	04/07/2017	17/08/2017
20	OKTREOTİD	DRUG	42	64	0.00	Available	22	64	04/07/2017	15/08/2017
10	ALBUMİN	DRUG	27	50	0.00	Available	23	50	05/07/2017	01/08/2017
13	CADI FİNGİĞİ DİSTİLATI	DRUG	33	56	0.00	Available	23	56	05/07/2017	07/08/2017
7	IV KANUL	MEDICAL MATERIAL	16	41	0.00	Available	25	41	07/07/2017	23/07/2017
27	X PHE KID SE MAMA	DRUG	47	58	0.13	Available	91	479	11/09/2017	04/10/2018
16	LENALİDOMİT	DRUG	66	76	0.10	Available	103	785	23/09/2017	06/08/2019
29	ÇARŞAF	MATERIAL	46	99	0.33	Available	164	307	23/11/2017	15/04/2018
28	ZİPRASİDON	DRUG	48	77	0.17	Available	180	477	09/12/2017	02/10/2018
25	UROKİNAZ	DRUG	34	75	0.20	Available	214	391	12/01/2018	08/07/2018
12	BİDEZONİD	DRUG	28	50	0.10	Available	227	517	25/01/2018	10/11/2018
26	VALSARTAN	DRUG	32	63	0.10	Available	320	651	28/04/2018	25/03/2019
17	MANNİTOL	DRUG	13	66	0.13	Available	411	512	28/07/2018	05/11/2018
11	ASETAZOLAMİD	DRUG	19	49	0.07	Available	465	760	20/09/2018	11/07/2019
30	PERDE	MATERIAL	11	69	0.05	Available	1305	1553	07/01/2021	11/09/2021

**Şekil 11- %10 luk Filtre ile Stok Durum Raporu**

Bu durumda sadece çizgiye en yakın kayıtlar hesaplamaya dahil olacağından tahmin etmedeki doğruluk payımız düşecektir. O zaman filtre oranını biraz daha arttıralım: %50




Şekil 12- %50 lik Filtre ile Regresyon Grafiği

**STOCK STATUS**

CODE NAME	TYPE	MIN LEVEL	COUNT	CONSUMPTION SPEED	STATUS	DAYS TO MIN LEVEL	DAYS TO STOCK END	MIN LEVEL DATE	STOCK END DATE
21 PANTOPRAZOL	DRUG	53	19	0.37	Under Min Level	-92	51	12/03/2017	02/08/2017
15 EPOETİN BETA	DRUG	55	33	0.37	Under Min Level	-59	89	13/04/2017	09/09/2017
19 NAPROKSEN	DRUG	51	34	0.68	Under Min Level	-25	50	18/05/2017	01/08/2017
8 DRENS	MEDICAL MATERIAL	31	25	0.61	Under Min Level	-10	41	02/06/2017	23/07/2017
9 GLOVES	MEDICAL MATERIAL	35	33	0.61	Under Min Level	-3	54	09/06/2017	05/08/2017
3 KAĞIT HAVLU	MATERIAL	20	20	0.42	Available	0	49	12/06/2017	31/07/2017
22 PROPOFOL	DRUG	38	39	0.48	Available	2	81	14/06/2017	01/09/2017
2 KATATER	MEDICAL MATERIAL	15	18	0.40	Available	8	46	20/06/2017	28/07/2017
23 SODYUM FOSFAT	DRUG	39	46	0.91	Available	8	51	20/06/2017	02/08/2017
27 X PHE KID SE MAMA	DRUG	47	58	1.33	Available	8	44	20/06/2017	26/07/2017
16 LENALIDOMIT	DRUG	66	76	0.88	Available	11	87	23/06/2017	07/09/2017
5 KAN SETİ	MEDICAL MATERIAL	24	31	0.46	Available	16	69	27/06/2017	19/08/2017
18 MENOTROPİN	DRUG	41	52	0.62	Available	18	84	30/06/2017	04/09/2017
20 OKTRETOTİD	DRUG	42	64	1.10	Available	20	58	02/07/2017	09/08/2017
4 SONDA	MEDICAL MATERIAL	14	23	0.46	Available	20	51	02/07/2017	02/08/2017
6 DİYALİZ MALZEMESİ	MEDICAL MATERIAL	27	36	0.46	Available	20	80	02/07/2017	31/08/2017
1 ASİRİN	DRUG	10	19	0.41	Available	22	47	04/07/2017	29/07/2017
28 ZIPRASİDON	DRUG	48	77	1.24	Available	24	62	05/07/2017	13/08/2017
24 TEMOZOLOMİD	DRUG	40	57	0.72	Available	24	79	05/07/2017	30/08/2017
14 DEKSTROZ (GLUKOZ)+SODYUM KLORÜR	DRUG	44	66	0.91	Available	24	73	06/07/2017	24/08/2017
29 ÇARŞAF	MATERIAL	46	99	2.00	Available	27	50	08/07/2017	01/08/2017
12 BUDEZONİD	DRUG	28	50	0.79	Available	28	64	10/07/2017	15/08/2017
13 CADİ FİNDİĞİ DİSTİLATI	DRUG	33	56	0.64	Available	36	88	18/07/2017	08/09/2017
30 PERDE	MATERIAL	11	69	1.61	Available	36	43	18/07/2017	25/07/2017
26 VALSARTAN	DRUG	32	63	0.79	Available	40	81	22/07/2017	01/09/2017
25 UROKİNAZ	DRUG	34	75	0.95	Available	43	79	25/07/2017	30/08/2017
11 ASETAZOLAMİD	DRUG	19	49	0.65	Available	47	76	28/07/2017	27/08/2017
17 MANNİTOL	DRUG	13	66	1.00	Available	53	66	04/08/2017	17/08/2017
10 ALBUMİN	DRUG	27	50	0.43	Available	54	118	05/08/2017	08/10/2017
7 İV KANUL	MEDICAL MATERIAL	16	41	0.41	Available	62	101	12/08/2017	21/09/2017

Şekil 13- %50 lik Filtre ile Stok Durum Raporu

Şimdi daha fazla çıkışı hesaba katarak hesaplama yapıyoruz. Filtre oranını değiştirerek grafiğin nasıl değiştiğini gözlemledikten sonra esas noktaya gelelim. Burada aslında amaç sadece gürültü kayıtlarını hesaplama dışı bırakmak, diğer bütün kayıtları hesaplama dahil etmektir. Buna göre filtre oranı olarak %85 uyguladığımızda aşağıdaki grafik ve değerler ortaya çıkar.



Şekil 14- %85 lik Filtre ile Regresyon Grafiği

<b>STOCK STATUS</b>										
CODE NAME	TYPE	MIN LEVEL	COUNT	CONSUMPTION SPEED	STATUS	DAYS TO MIN LEVEL	DAYS TO STOCK END	MIN LEVEL DATE	STOCK END DATE	
21	PANTOPRAZOL	DRUG	53	19	0.46	Under Min Level	-75	42	29/03/2017	24/07/2017
15	EPOETİN BETA	DRUG	55	33	0.46	Under Min Level	-49	73	24/04/2017	24/08/2017
19	NAPROKSEN	DRUG	51	34	0.66	Under Min Level	-26	52	17/05/2017	03/08/2017
8	DRENS	MEDICAL MATERIAL	31	25	0.66	Under Min Level	-9	38	03/06/2017	20/07/2017
9	GLOVES	MEDICAL MATERIAL	35	33	0.61	Under Min Level	-3	54	09/06/2017	05/08/2017
3	KAĞIT HAVLU	MATERIAL	20	20	0.42	Available	0	49	12/06/2017	31/07/2017
22	PROPOFOL	DRUG	38	39	0.48	Available	2	83	14/06/2017	02/09/2017
2	KATER	MEDICAL MATERIAL	15	18	0.42	Available	7	44	19/06/2017	26/07/2017
27	X PHE KID SE MAMA	DRUG	47	58	1.33	Available	8	44	20/06/2017	26/07/2017
23	SODYUM FOSFAT	DRUG	39	46	0.79	Available	9	58	21/06/2017	09/08/2017
16	LENALDOMIT	DRUG	66	76	0.77	Available	13	100	25/06/2017	20/09/2017
5	KAN SETİ	MEDICAL MATERIAL	24	31	0.42	Available	17	75	29/06/2017	26/08/2017
18	MENOTROPİN	DRUG	41	52	0.62	Available	18	84	30/06/2017	04/09/2017
4	SONDA	MEDICAL MATERIAL	14	23	0.45	Available	20	52	02/07/2017	03/08/2017
6	DIYALİZ MALZEMESİ	MEDICAL MATERIAL	27	36	0.41	Available	22	89	04/07/2017	09/09/2017
1	ASİRİN	DRUG	10	19	0.41	Available	22	47	04/07/2017	29/07/2017
20	OKTRETİD	DRUG	42	64	0.96	Available	23	67	05/07/2017	18/08/2017
28	ZİPRASİDİN	DRUG	48	77	1.24	Available	24	62	05/07/2017	13/08/2017
24	TEMOZOLOMİD	DRUG	40	57	0.69	Available	25	83	07/07/2017	03/09/2017
29	ÇARŞAF	MATERIAL	46	99	2.00	Available	27	50	08/07/2017	01/08/2017
14	DEKSTROZ (GLUKOZ)+SODYUM KLORÜR	DRUG	44	66	0.79	Available	28	84	10/07/2017	04/09/2017
12	BUDEZONİD	DRUG	28	50	0.79	Available	28	64	10/07/2017	15/08/2017
13	CADİ FİNDİĞİ DİSTİLİTİ	DRUG	33	56	0.64	Available	36	88	18/07/2017	08/09/2017
30	PERDE	MATERIAL	11	69	1.62	Available	36	43	18/07/2017	25/07/2017
25	UROKİNAZ	DRUG	34	75	1.03	Available	40	73	22/07/2017	24/08/2017
26	VALSARTAN	DRUG	32	63	0.79	Available	40	81	22/07/2017	01/09/2017
11	ASETAZOLAMİD	DRUG	19	49	0.57	Available	53	86	04/08/2017	06/09/2017
17	MANNİTOL	DRUG	13	66	1.00	Available	53	66	04/08/2017	17/08/2017
10	ALBÜMİN	DRUG	27	50	0.43	Available	54	118	05/08/2017	08/10/2017
7	IV KANUL	MEDICAL MATERIAL	16	41	0.41	Available	62	101	12/08/2017	21/09/2017

Şekil 15- %85 lik Filtre ile Stok Durum Raporu

Filtrenin oranının her deęişiminde Lineer Regresyon fonksiyonunun katsayılarının da deęiştiiğine ve Stok Durum raporundaki deęerlerinde deęiştiiğine dikkat edin. Bunun nedeni bu deęerler sadece hesaplamaya dahil edilen çıkış deęerleri üzerinden hesaplanıyor.

Şimdi bu gözlemlerin deęerlendirilmesine göz atalım.





## BEŞİNCİ BÖLÜM

### DEĞERLENDİRME

Bu çalışmada klasik bir stok altyapısında, sistemdeki stok çıkışlarını analiz ederek ileride de ne kadar stok çıkışı olabileceğini tahmin etmeye çalıştık. Bunun için mevcut stok çıkışlarının(X) analizini ve olması gereken çıkış miktarlarının(Y) hesaplamasını yaparak sistemin karakteristiğini ve lineer regresyon denklemini(X ve Y arasındaki ilişki) çıkarmaya çalıştık. Bu karakteristik fonksiyonun girdisine mevcut stok değerlerini verince de sistemde ileride ne kadar çıkış gerçekleşebileceğini tahmin etmeye çalıştık. Sistemin istisnai davranışlarını(gürültü) filtreleyerek daha kararlı bir tahminleme elde etmeye çalıştık. Mevcut çıkış değerlerinin değişimine karşılık sistemin ürettiği tahmin değerlerinin nasıl değiştiğini gözlemledik ve optimum filtre değerini bularak en doğru tahmin değerlerini elde etmeye çalıştık.

Literatürde stok çıkışından, ürün geliştirmesine, ürün satışına kadar farklı aşamalara yönelik tahminlemelerle ilgili çalışmalar bulunmaktadır. Burada hangi yöntemin seçilmesi gerektiği ürünün cinsine bağlı olarak değişiklik gösterir. Örneğin doğrudan satış yapılan ürünlerin stoku tutuluyorsa ürün satışına yönelik tahminlere daha çok ihtiyaç duyulabilir. Bizim çalışmamızda alınan malzeme doğrudan satılmadığı, üretilen ürün/hizmette kullanıldığı için biz stok çıkışlarının tahminlemesini gerçekleştirdik.

## ALTINCI BÖLÜM

### SONUÇ VE GELECEKTEKİ ÇALIŞMALAR

Çalışmamızda daha düşük maliyetle, minimum stok seviyeleriyle, daha verimli stok takibi yapabilmek için sistemin stok çıkışlarını analiz edip, stok tüketim hızını hesaplayıp ileriye yönelik stok çıkışlarının tahminlerini yaptık. Bunun için geliştirdiğimiz Smart Advisor adlı uygulamamız stok çıkışlarını okuyarak sistemin hangi malzemeyi hangi sürede tükettiğini öğreniyor ve hangi malzemenin ne zaman tükeneceğini hesaplayarak tavsiyelerde bulunuyor. Bu çalışma mevcut stokları kullanarak yeni bir ürün/hizmet üreten sistemlerde verimli sonuçlar sağlayabilir. Örneğin sağlık sektöründe hastanelerde kullanılabilir.

Bu çalışma bir sonraki aşama olan maliyet takibi ya da bütçe uygulamaları için gerekli veriyi üretebilir ve bu alanlarda yapılacak çalışmalara kaynak sağlayabilir.

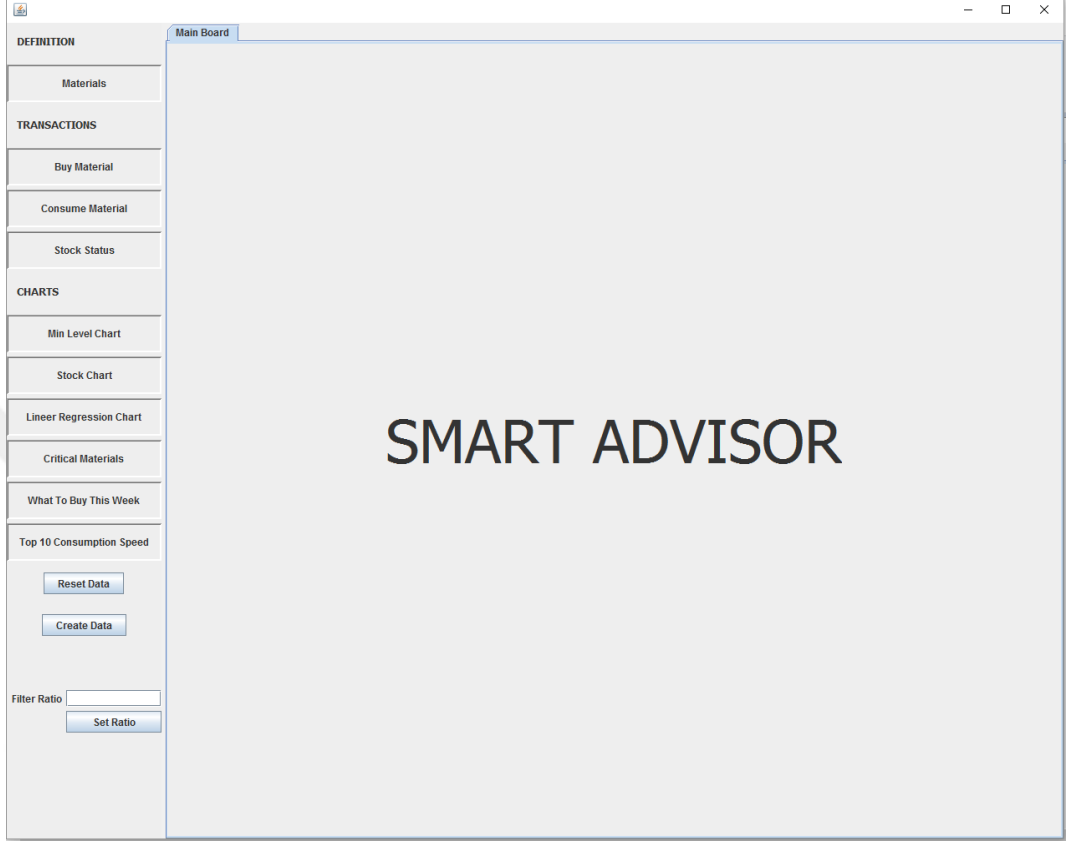
## KAYNAKLAR

- [1] Samuel A. L. "Some Studies in Machine Learning Using the Game of Checkers" 1959
- [2] A. M. Turing "Computing Machinery and Intelligence" 1950.
- [3] Zhang, G., Eddy Patuwo, M. Y. Hu "Forecasting with artificial neural networks: The state of the art" 1998.
- [4] Adya, M., F. Collopy "How Effective are Neural Networks at Forecasting and Prediction? Journal of Forecasting" 1998.
- [5] Lee, R.S.T., iJADE "Stock Advisor: An Intelligent Agent Based Stock Prediction System" 2004.
- [6] Tsang,P.M., P. Kwok, "Design and implementation of NN5 for Hong Kong stock price forecasting", "Engineering Applications of Artificial Intelligence" 2007.
- [7] Michael David Rechenthin "Machine-Learning Classification Techniques For The Analysis And Prediction Of High-Frequency Stock Direction" 2014
- [8] Neda Khalil Zadeh, Mohammad Mehdi Sepehri, Hamid Farvaresh, "Intelligent Sales Prediction for Pharmaceutical Distribution Companies: A Data Mining Based Approach" 2014.
- [9] Steven B Achelis. "Technical Analysis from A to Z" 2001.
- [10] Magnus Olden "Predicting Stocks with Machine Learning" 2016
- [11] Vatsal H. Shah "Machine Learning Techniques for Stock Prediction" 2007
- [12] Victor Louwerse, Léon Rothkrantz "Intraday Stock Forecasting" 2014
- [13] FREDRIK CEDERVALL "Machine Learning For Technical Stock Analysis" 2012
- [14] Bige Küçükefe "Machine Learning Studies In Economics" 2017
- [15] Faruk Bulut "A New Clinical Decision Support System With Instance Based Ensemble Classifiers" 2017
- [16] Ebru Ardıl "Software Maintenance Severity Prediction With Soft Computing Approach" 2009
- [17] Aslı Bahadır "Mixture Regression Models" 2010

- [18] Lin Xu, Shufang Sun, Yongliang Yan, Janhui Wang, And Shusheng Gu “Prediction of Zero Inventory in Supply Chain With GA Based Neural Network” 2010
- [19] Alexander Renz, Ye Chen “Inventory early warning agent in a supply chain management system” 2008
- [20] M.Z. Babai and Y. Dallery “Inventory Management : Forecast Based Approach vs. Standard Approach” 2006
- [21] T. Suesut, S. Gulphanich, P. Nilas, P. Roengruen, K. Tirasesth “Demand forecasting approach inventory control for warehouse automation” 2004
- [22] Robert Fildes, Charles Beard "Forecasting Systems for Production and Inventory Control" 1992
- [23] Jui-Chan Huang, Tzu-Jung Wu, Yen-Chun Chiu, Chunwei Lu “Improvement of Inventory Control and Forecast According to Activity-Based Classifications: T Company as an Example” 2017
- [24] Marisol Valencia-Cárdenas, Francisco Javier Díaz-Serna & Juan Carlos Correa-Morales “Multi-product inventory modeling with demand forecasting and Bayesian optimization” 2015
- [25] Mehmet Hacıbeyoğlu “Çoklu Etmen Mimarisi ve Takviyeli Öğrenme” 2006

## EKLER

Smart Advisor program giriş ekranı.



Ek-1 Smart Advisor

## Malzeme tanımlarının yapıldığı ekran

Code	Name	Type	Min Level	Status
1	ASPIRİN	DRUG	10	✓
2	KATATER	MEDICAL MATERIAL	15	✓
3	KAĞIT HAVLU	MATERIAL	20	✓
4	SONDA	MEDICAL MATERIAL	14	✓
5	KAN SETİ	MEDICAL MATERIAL	24	✓
6	DIYALİZ MALZEMESİ	MEDICAL MATERIAL	27	✓
7	İV KANUL	MEDICAL MATERIAL	16	✓
8	DRENS	MEDICAL MATERIAL	31	✓
9	GLOVES	MEDICAL MATERIAL	35	✓
10	ALBUMİN	DRUG	27	✓
11	ASETAZOLAMİD	DRUG	19	✓
12	BUDEZONİD	DRUG	28	✓
13	CADI FINDIĞI DISTİLATI	DRUG	33	✓
14	DEKSTROZ (GLUKOZ)+SODYUM KLORUR	DRUG	44	✓
15	EPOETİN BETA	DRUG	55	✓
16	LENALİDOMİT	DRUG	66	✓
17	MANNİTOL	DRUG	13	✓
18	MENOTROPİN	DRUG	41	✓
19	NAPROKSEN	DRUG	51	✓
20	OKTRETİD	DRUG	42	✓
21	PANTOPRAZOL	DRUG	53	✓
22	PROPOFOL	DRUG	38	✓
23	SODYUM FOSFAT	DRUG	39	✓
24	TEMOZOLOMİD	DRUG	40	✓
25	UROKİNAZ	DRUG	34	✓
26	VALSARTAN	DRUG	32	✓
27	X PHE KİD SE MAMA	DRUG	47	✓
28	ZİPRASİDİN	DRUG	48	✓
29	ÇARŞAF	MATERIAL	46	✓
30	PERDE	MATERIAL	11	✓

## Ek-2 Malzeme Tanımı

## Malzeme girişlerinin yapıldığı ekran

Invoice			Invoice Details				
Id	Date	Firm	Material	Count	Quantity Type	Amount	End Date
1	08.Oca.2017	Tıp Medikal	PERDE	40	Adet	40	09.Mar.2017
5	05.Sub.2017	Selçuk Depo	UROKİNAZ	29	Adet	29	09.Mar.2017
10	01.Mar.2017	Etkin İlaç	KAĞIT HAVLU	10	Adet	25	09.Mar.2017
15	25.Mar.2017	MedMedin	KAN SETİ	12	Adet	24	09.Mar.2017
20	04.Nis.2017	Nöro İlaç	PANTOPRAZOL	11	Adet	11	09.Mar.2017
25	30.Nis.2017	Farma İlaç	X PHE KİD SE MAMA	32	Adet	32	09.Mar.2017
30	11.May.2017	Dost Medikal	LENALİDOMİT	24	Adet	24	09.Mar.2017
35	20.May.2017	Dolu İlaç	İV KANUL	14	Adet	28	09.Mar.2017
			ZİPRASİDİN	33	Adet	33	09.Mar.2017
			SODYUM FOSFAT	20	Adet	20	09.Mar.2017
			MANNİTOL	27	Adet	27	09.Mar.2017
			MENOTROPİN	18	Adet	18	09.Mar.2017
			ASPIRİN	10	Adet	10	09.Mar.2017
			SONDA	11	Adet	33	09.Mar.2017
			DIYALİZ MALZEMESİ	13	Adet	39	09.Mar.2017
			BUDEZONİD	21	Adet	21	09.Mar.2017
			GLOVES	16	Adet	16	09.Mar.2017
			DEKSTROZ (GLUKOZ)+SODYUM KLORUR	23	Adet	23	09.Mar.2017
			KATATER	10	Adet	20	09.Mar.2017
			ASETAZOLAMİD	17	Adet	17	09.Mar.2017
			OKTRETİD	26	Adet	26	09.Mar.2017
			PROPOFOL	13	Adet	13	09.Mar.2017
			DRENS	15	Adet	60	09.Mar.2017
			CADI FINDIĞI DISTİLATI	19	Adet	19	09.Mar.2017
			VALSARTAN	23	Adet	23	09.Mar.2017
			ÇARŞAF	50	Adet	50	09.Mar.2017
			ALBUMİN	14	Adet	14	09.Mar.2017
			TEMOZOLOMİD	19	Adet	19	09.Mar.2017
			NAPROKSEN	16	Adet	16	09.Mar.2017
			EPOETİN BETA	12	Adet	12	09.Mar.2017

## Ek-3 Malzeme Girişi

## Malzeme çıkışlarının yapıldığı ekran

Consumption			Consumption Details			
Id	Date	Firm	Material	Count	Quantity Type	Amount
2	16.Oca.2017	Ali Sandıklı	ASPIRİN	2	Adet	5
3	19.Oca.2017	Osman Sınay	KATATER	1	Adet	2
4	27.Oca.2017	Resul Derici	KAĞIT HAVLU	2	Adet	5
6	07.Şub.2017	Ayşe Fatma	SONDA	3	Adet	9
7	11.Şub.2017	Salih Demir	KAN SETİ	4	Adet	8
8	17.Şub.2017	Nuriye Genç	DIYALİZ MALZEMESİ	3	Adet	9
9	23.Şub.2017	Melike Tezcan	IV KANUL	6	Adet	12
11	03.Mar.2017	Talip Öztürk	DRENS	4	Adet	16
12	07.Mar.2017	Kemal Faruk	GLOVES	3	Adet	3
13	11.Mar.2017	Selin Özel	ALBUMİN	2	Adet	2
14	18.Mar.2017	Zeynep Mert	ASETAZOLAMİD	1	Adet	1
16	26.Mar.2017	Özcan Serin	BUDEZONİD	2	Adet	2
17	29.Mar.2017	Kadriye Yeşil	CADI FINDIGI DISTİLATI	3	Adet	3
18	01.Nis.2017	Leman San	DEKSTROZ (GLUKOZ)+SODYUM KLORÜR	1	Adet	1
19	03.Nis.2017	Vedat Milor	EPOETİN BETA	2	Adet	2
21	06.Nis.2017	Osman Sınay	LENALİDOMİT	1	Adet	1
22	09.Nis.2017	Ali Sandıklı	MANNİTOL	3	Adet	3
23	14.Nis.2017	Resul Derici	MENOTROPİN	2	Adet	2
24	20.Nis.2017	Ayşe Fatma	NAPROKSEN	4	Adet	4
26	01.May.2017	Salih Demir	OKTRETİD	1	Adet	1
27	03.May.2017	Nuriye Genç	PANTOPRAZOL	2	Adet	2
28	05.May.2017	Melike Tezcan	PROPOFOL	3	Adet	3
29	08.May.2017	Talip Öztürk	SODYUM FOSFAT	1	Adet	1
31	13.May.2017	Kemal Faruk	TEMOZOLOMİD	4	Adet	5
32	14.May.2017	Selin Özel	UROKİNAZ	4	Adet	4
33	16.May.2017	Zeynep Mert	VALSARTAN	2	Adet	2
34	18.May.2017	Özcan Serin	X PHE KİD SE MAMA	6	Adet	6
36	21.May.2017	Kadriye Yeşil	ZİPRASİDON	6	Adet	6
37	24.May.2017	Leman San	ÇARŞAF	9	Adet	10
38	26.May.2017	Vedat Milor	PERDE	8	Adet	5
39	27.May.2017	Osman Sınay				
40	30.May.2017	Ali Sandıklı				

### Ek-4 Malzeme Çıkışı