T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

İNŞAAT RİSK YÖNETİMİ İÇİN GENETİK ALGORİTMA TABANLI BİR YAPAY SİNİR AĞI MODELİ

Mehmet Alp AYTEKİN

DANIŞMAN
Dr. Öğr. Üyesi Ersin NAMLI

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

Eylül, 2019

Bu çalışma, 13.09.2019 tarihinde aşağıdaki jüri tarafından Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Dr. Öğr. Üyesi Ersin NAMLI(Danışman)
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr. Öğr. Üyesi Funda Hatice SEZGİN
İstanbul Üniversitesi - Cerrahpaşa
Mühendislik Fakültesi

Dr. Öğr. Üyesi Murat Taha BİLİŞİK
İstanbul Kültür Üniversitesi
İktisadi ve İdari Bilimler Fakültesi

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Tez çalışmamın her aşamasında bilgi ve birikimlerini esirgemeyen, bayram, izin, hafta sonu, tatil ayırt etmeksizin yılın hangi zamanı ve günün hangi saati olursa olsun destek olan saygıdeğer danışman hocam Dr.Öğr.Üyesi Ersin NAMLI'ya teşekkür ederim.

Ayrıca bu tez çalışmasının kritik bölümünü oluşturan ve risk analizi aşamasında kullanılan verilerin temininde göstermiş olduğu ilgi alâka ve katkılarından ötürü Doğa HSE Group Direktörü Sayın Çağlar Dohman'a teşekkür ederim.

Tüm hayatım boyunca ve dahi yükseköğrenimim sırasında desteklerini esirgemeyen annem Hülya AYTEKİN'e şükranlarımı sunarım.

Eylül 2019 Mehmet Alp AYTEKİN

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **vii**
TABLO LİSTESİ ..... **ix**
SİMGE VE KISALTMA LİSTESİ ..... **x**
ÖZET ..... **xi**
SUMMARY ..... **xiii**
1. GİRİŞ **1**
2. GENEL KISIMLAR **3**
2.1. PROJE……3
2.2. PROJE YÖNETİMİ……...4
2.2.1 Proje Yönetim Sistemi……6
2.3. PROJE YÖNETİMİNDE ALTI SİGMA……..8
2.4. RİSK YÖNETİMİ……...9
2.4.1. Riskli Olay……13
2.4.2. Riske Maruz Değer……....15
2.4.3. Monte Carlo Simülasyonu……18
2.5. YAPAY SİNİR AĞLARI……...20
2.5.1. Yapay Zekâ Çalışmalarındaki Gelişmeler……23
2.5.2. Olasılıksal Sinir Ağları (PNN)……..…26
2.5.3. PNN Çalışma Adımları……27
2.6. GENETİK ALGORİTMA……29
2.7. LİTERATÜR ÇALIŞMASI……..36
3. MALZEME VE YÖNTEM **41**
3.1. VERİ SETİ……..41

3.2. RİSK SKORUNUN HESAPLANMASI……...44

4. BULGULAR.....48

5. TARTIŞMA VE SONUÇ 69

KAYNAKLAR.....71

EKLER.....75

ÖZGEÇMİŞ 776

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Proje Yaşam Döngüsü ve Organizasyon……3

Şekil 2.2: Proje Yönetim Sistemi…….7

Şekil 2.3: Proje Risk Yönetimi……...10

Şekil 2.4: Proje Risk Yönetimine Genel Bakış……..12

Şekil 2.5: Proje Risklerini Modelleyen Standart Risk Modeli…….14

Şekil 2.6: Proje, Program ve Portföy Yönetimleri Arasındaki Etkileşimler……..16

Şekil 2.7: Genetik Algoritmanın Basit Akışı…….30

Şekil 2.8: Rulet Tekeri Seçim Modeli……..…31

Şekil 2.9: Elitist Seçim – Top %50 Modeli……....32

Şekil 2.10: Çaprazlama Operatörlerini Genetik Rekombinasyonda Gösterilmesi……...32

Şekil 2.11: Mutasyon ve İnversiyon Genetik Operatörlerinin Gösterilmesi…….....33

Şekil 2.13: Dizelerin Genetik Algoritma Yapısı Kullanılarak Çaprazlanması……..35

Şekil 4.1: Genetik Algoritma Entegre Sonuç……..…54

Şekil 4.2: Genetik Algoritma Canlı Analiz Ekranı……...54

Şekil 4.3: Genetik Algoritma Canlı Analiz Sonuç Ekranı……55

Şekil 4.4: Örnek Faaliyet (2200 TL, Dış Sıva ve Cephe Kaplama İşleri) Seçimi……56

Şekil 4.5: Örnek Faaliyet (3000 TL, Dış Sıva ve Cephe Kaplama İşleri) Seçimi……57

Şekil 4.6: Örnek Faaliyet (1750 TL, Dış Sıva ve Cephe Kaplama İşleri) Seçimi…….58

Şekil 4.7: Örnek Faaliyet 300 TL, Dış Sıva ve Cephe Kaplama İşleri) Seçimi……59

Şekil 4.8: Genetik Algoritma Entegre Sonuç……..60

Şekil 4.9: Dış Sıva ve Cephe Kaplama Faaliyetinin 18 Kod Numaralı Riski İçin Genetik Algoritma Canlı Analiz Ekranı……61

Şekil 4.10: YSA Tabanlı GA Deneme Sonuçları Kesit Ekranı…….…..61

Şekil 4.11 Proje 3 "Çatı İşleri" Faaliyeti 13 Kodlu Risk İçin Önlem Paketi 5000 TL Olduğunda Ekran Kesiti ……..…..63

Şekil 4.12: Proje 3 "Çatı İşleri" Faaliyeti 13 Kodlu Risk Önlem Paketi 3000 TL Olduğunda Ekran Kesiti……64

Şekil 4.13: Proje 3 "Çatı İşleri" Faaliyeti 13 Kodlu Risk Önlem Paketi 8000 TL Olduğunda Ekran Kesiti……65

Şekil 4.14: Genetik Algoritma Entegre Sonuç…….66

Şekil 4.15: Çatı İşleri Faaliyetinin 13 Kod Numaralı Riski İçin Genetik Algoritma Canlı Analiz Ekranı……..67

Şekil 4.16: Proje 3 "Çatı İşleri" Faaliyeti 13 Kodlu Risk Önlem Paketi 8000 TL Olduğunda Ekran Kesiti……68

TABLO LİSTESİ

Sayfa No

Tablo 2.1 Analitik Risk Yönetimi Araçlarının Gelişimi…….17

Tablo 3.1 Veri Setinin Örnek Bir Kısmı……..…41-42

Tablo 3.2 Riskler ve Risk Kodları…….43

Tablo 3.3 Olasılık ve Etki Skoru Matrisi……..45

Tablo 3.4 Aralık Ölçeği……..45

Tablo 4.1 Faaliyet 1 Önlem Maliyeti 10000 TL…….48-49-50

Tablo 4.2 Faaliyet 1 Önlem Maliyeti 8000 TL……..51

Tablo 4.3 Faaliyet 1 Önlem Maliyeti 5000 TL……..52

Tablo 4.4 Faaliyet 1 Önlem Maliyeti 2000 TL…….….53

KISALTMA LİSTESİ

Kısaltmalar	Açıklama
GA	: Genetik Algoritma
YSA	: Yapay Sinir Ağları
PNN	: Olasılıksal Sinir Ağları
Diğ.	: Diğerleri
Vb.	: Ve bunun gibi

ÖZET

İNŞAAT RİSK YÖNETİMİ İÇİN GENETİK ALGORİTMA TABANLI BİR YAPAY SİNİR AĞI MODELİ

YÜKSEK LİSANS TEZİ

Mehmet Alp AYTEKİN

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Endüstri Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Ersin NAMLI

Rekabetin yüksek olduğu ve hızla değişen koşulların olduğu günümüz şartlarında piyasada yer alan firmaların bu değişkenliğe optimum sürede uyum sağlayabilmesi, mevcut durumunun korunması ve pazar payının arttırılmasında kritik önem arz etmektedir. Bu durumlar dikkate alındığında inşaat firmaları da dahil olmak üzere proje bazlı çalışan firmaların etkin bir proje yönetim anlayışı geliştirmesi ve geliştirilen bu anlayışın uygulamaya geçirilmesi gerekir.

Bir projeye başlamadan önce geçmişteki bilgi birikimine dayanılarak proje risklerinin belirlenmesi, doğabilecek olumsuz durumların sonuçları karşısında firmanın hazırlıklı olmasını sağlayacaktır.

İyi bir proje yönetimi, kısıtlı kaynakların yani insan gücü, zaman ve maliyet gibi unsurların koordinasyonuna ek olarak riskli olayların, risk olasılıklarının gerçek yaşamdaki koşullara en yakın şekilde tahmin ve analizlerinin yapılarak yönetilmesine ihtiyaç duyar. Proje risk analizi sürecinin etki bir biçimde takip ve kontrol edilmesi, riskli olayların doğru seçilmesi, firmaların yürütmekte veya yürütecekleri projelerde var olan durumlarını analiz etmelerine ve böylece proje sırasında meydana gelebilecek olumsuz durumlara karşı gerekli önlemleri önceden belirlemelerine katkı sağlayacaktır. Bu sayede olumsuz olayların maddi etkilerinden minimum düzeyde etkileneceklerdir.

Hayata geçirilmek istenen projelerin veya hali hazırda yürütülmekte olan projelerin tamamlanması ön görülen hedef maliyeti doğru tahmin etmek, firmaların kısıtlı kaynaklarının ve firmanın bir proje için ayırdığı bütçenin verimli kullanılması bakımından oldukça önem arz eder. Projenin, önceden planlanan iş paketleri takvimlerine uyularak tamamlanabilmesi firmaların hem rekabetçi gücünün artmasına olanak sağlayacak hem de yapılan bu risk analizleri firmanın sonraki dönemlerdeki projeler için bilgi birikimi oluşturulmasını sağlayacaktır.

Bu tez çalışmasında, inşaat konut projeleri için "inşaat risk yönetimi için genetik algoritma tabanlı bir yapay sinir ağı modeli" oluşturmak amaçlanmıştır. Oluşturulan modelde, konut inşaatlarının yapımında yapay sinir ağı ve genetik algoritmalar kullanılarak meydana gelebilecek risklerin analizi, bu risklere karşı alınabilecek önlem maliyetleri, önlem maliyetleri alınmadan önceki ve önlem maliyeti alındıktan sonraki sonuçlar ile firmaların doğabilecek olumsuz durumlara karşı ön görülü olarak hareket edebilmesi amaçlanmıştır.

Eylül 2019, 90 sayfa.

Anahtar kelimeler: Risk analizi, yapay zekâ, yapay sinir ağları, genetik algoritma

SUMMARY

AN ARTIFICIAL NEURAL NETWORK MODEL BASED ON GENETIC ALGORITHM FOR CONSTRUCTION RISK MANAGEMENT

M.Sc. THESIS

Mehmet Alp AYTEKİN

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Industrial Engineering

Supervisor : Assist. Prof. Dr. Ersin NAMLI

In today's conditions where competition is high and rapidly changing conditions, it is critical for companies in the market to adapt to this variability in an optimum time, to maintain their current situation and increase their market share. When these situations are taken into consideration, project-based firms, including construction companies, should develop an effective project management understanding and this developed understanding should be put into practice.

Determining the project risks based on past knowledge before starting a project will ensure that the company is prepared against the consequences of negative situations that may arise.

Good project management requires the management of risky events by estimating and analyzing the risk probabilities as close to real-life conditions in addition to the coordination of limited resources, namely manpower, time and cost. Effectively monitoring and controlling the project risk analysis process, selecting the risky events correctly, will help companies analyze their current situation in the projects they are conducting or will carry out and thus determine the necessary precautions in advance against the negative situations that may occur

during the project. In this way, they will be affected to a minimum by the material effects of adverse events.Summary text.

Accurate estimation of the target cost, which is expected to be completed by the projects that are intended to be implemented or the projects currently being carried out, is very important for the efficient use of the limited resources of the companies and the budget allocated by the company for a project. Completion of the project in accordance with the schedules of the planned work packages will enable the companies to increase their competitive power and these risk analyzes will ensure the accumulation of knowledge for the projects in the future periods.

In this thesis, it is aimed to create an artificial neural network model based on genetic algorithm for construction risk management for construction housing projects. In this model, it is aimed to analyze the risks that may occur by using artificial neural network and genetic algorithms in the construction of housing constructions, preventive costs to be taken against these risks, the results before and after the precautionary costs are taken and the companies to act as a foresight against the negative situations that may arise.

September 2019, 90 pages.

Keywords: Risk analysis, artificial intelligence, artificial neural networks, genetic algorithm

1.GİRİŞ

Bu çalışmada, proje yönetimi, genetik algoritma ve yapay sinir ağları kapsamlarında konut inşaat projelerinde genetik algoritma tabanlı bir yapay sinir ağı modeli oluşturulmaya çalışılacaktır. Firmaların, projelerini sürdürürken karşılaşabilecekleri riskli durumların meydana gelmesi sonucu oluşan maddi yükler, günümüz rekabetçi ortamı ve müşteri ihtiyaçlarının optimum düzeyde karşılanması zorunluluğu, firmaları yenilikçi mühendislik yöntemleri ile çözümler aramaya itmektedir. Geliştirilmeye çalışılan model, bilgisayar destekli, olduğundan modele girilen veriler, bu verilerin yapay sinir ağı tarafından öğrenilmesi ve genetik algoritma tarafından çözümlenmesi sonucu riskli olayların meydana gelme olasılıkları istenilen düzeyde kontrol altında tutulabilecek ve firmaların bu olaylara hazırlıklı olması sağlanacaktır.

Günümüzde iş kazaları ile ilgili çeşitli çalışmalar yürütülmüş ve kanunlar yürürlüğe konmuştur. Geliştirilmeye çalışılan bu model sayesinde riskli olaylar firmaların kontrolü altında tutulabileceğinden bu kazaların da meydana gelmesi önlenebilecek veya meydana gelme olasılığı düşürülebilecektir. Böylece, işçilerin iş kazası geçirmeleri sonrasında meydana gelen ölüm, yaralanma, engelli kalma gibi olayların önüne geçilme olasılığı artabilecektir. Elbette istenmeyen bu durumların yalnızca bir bilgisayar modeli uygulanarak engellenmesi pek mümkün olmayacaktır. İş kazalarının ve riskli olayların meydana gelmesinin önlenebilmesi bilgisayar destekli mühendislik uygulamalarının yanında kanunlara riayet edilmeli, gerekli eğitimler alınmalı ve firmalar bünyesinde bir güvenlik kültürü oluşturulmalıdır.

Çalışmada, öncelikle proje ve proje yönetiminin kapsamından, proje yönetim sisteminden bahsedilecektir. Sonrasında risk yönetimi kapsamında risk yönetiminin ne olduğu, bu alanda hangi çalışmaların yürütüldüğü, tez çalışmasının özet ve giriş kısımlarında sıkça bahsedilen riskli olayların ne olduğu ve Monte Carlo Simülasyonu'ndan bahsedilmiştir. Daha sonra, geliştirilmeye çalışılan modelin temel yapı taşlarını oluşturan yapay sinir ağlar ve genetik algoritma başlıkları ele alınacaktır. Bu başlıklar altında ise yapay sinir ağlarının ve genetik algoritmaların icadı, çalışma şekilleri, kullanımları sırasında çalışan formüller ve algoritmalar hakkında bilgiler verilecektir.

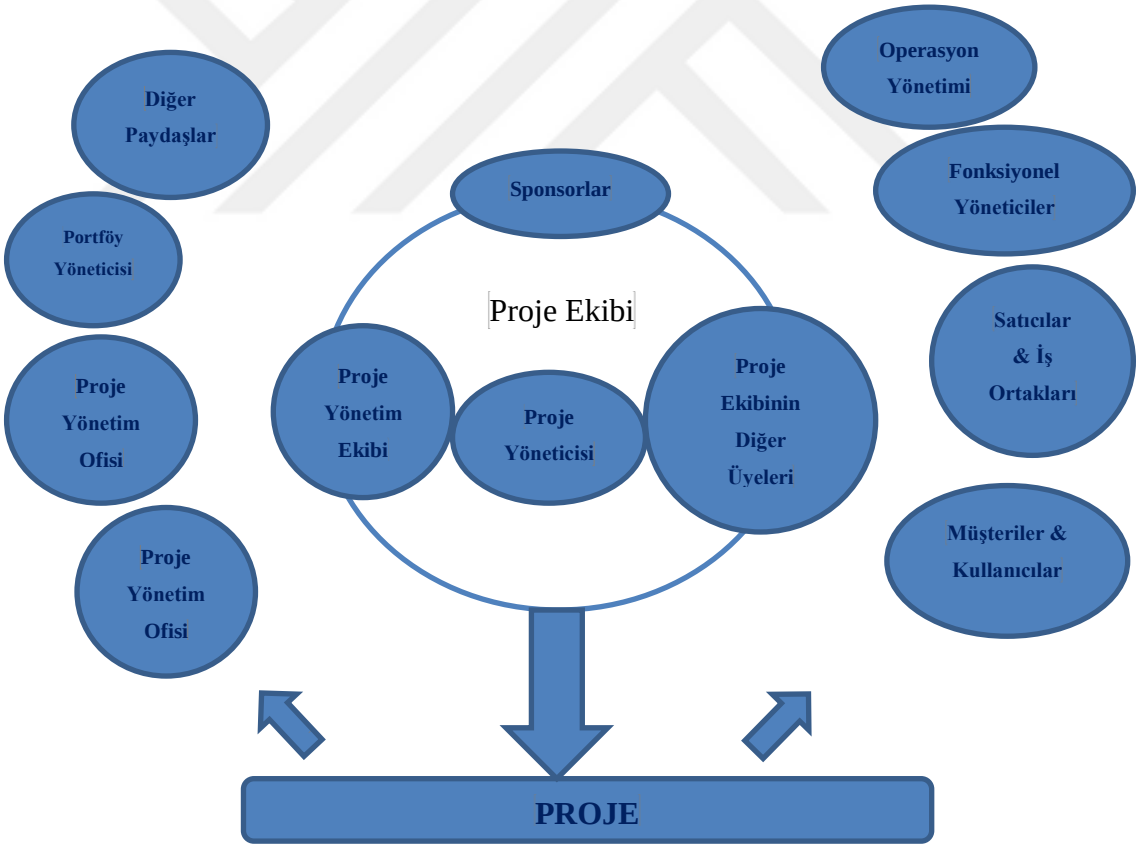
Malzeme ve yöntem bölümünde ise kullanılan metodolojiler açıklanacak, bulgular bölümünde kullanılan bu metodolojiler sonucunda istenilen sonuçların nasıl elde edildiği hakkında bilgiler verilecek, çeşitli tablo ve şekiller yardımıyla sonuçlar görselleştirilerek yapılan işlemler adım adım görselleştirilecektir. Son olarak tartışma ve sonuç bölümünde oluşturulmaya çalışılan bu modelin inşaat ve diğer sektörlere olabilecek katkılarından bahsedilecektir.

2.GENEL KISIMLAR

2.1. PROJE

Proje; benzersiz bir ürün, hizmet ya da sonuç elde etmek için yürütülen, açıkça tanımlanmış bir çalışma alanı, bir bütçesi, başlangıç ve bitiş süresi belirli olan geçici bir girişimdir.

Joseph M. Juran'a göre proje tanımı ise; çözüm için planlanmış soruna proje denir. Bir projenin başarılı sayılabilmesi için, paydaşların beklentilerini anlatması, sonuçların ne olması gerektiğinin anlaşılması, sonrasında bu sonuçları elde etmek ve bu beklentileri karşılayabilmek için çıktılarının neler olması gerektiğini belirleyerek, gereklilikleri açığa kavuşturması durumunda proje başarılıdır denebilir [4].



Şekil 2.1: Proje Yaşam Döngüsü ve Organizasyon [1]

Geçicilik, her zaman sürenin kısa olduğu anlamına gelmez. Proje ile ortaya konulan ürün, hizmet ya da sonuç için genellikle geçicilik söz konusu değildir. Çoğu proje kalıcı bir sonuca

ulaşmak amacıyla yürütülür. Örneğin, ulusal bir anıt inşa etmek için yürütülen bir proje yüzyıllarca ayakta kalacak bir sonuç ortaya çıkaracaktır. Ayrıca, projelerin kendilerinden çok daha uzun süreli olan toplumsal ekonomik ve çevresel etkileri olabilir [1].

Bir proje ile aşağıda belirtilenler ortaya konulabilir;

- Başka bir öğenin bileşeni olan ya da tek başına nihai bir öğe teşkil eden bir ürün
- Bir Hizmet gerçekleştirme potansiyeli (örneğin; üretimi ya da dağıtımı destekleyen bir fonksiyon)
- Bir sonuç ya da belge (örneğin, bir trendin var olup olmadığını ya da yeni bir sürecin topluma yarar getirip getiremeyeceğini belirlemekte kullanılabilecek bilgiler geliştirmeye yönelik bir araştırma projesi) [1]

Proje hedeflerine ulaşıldığında ya da hedeflere ulaşılamayacağı veya artık projeye ihtiyaç duyulmadığı için projeye son verildiğine proje bitiş süresine ulaşılmış olur.

2.2. PROJE YÖNETİMİ

Yönetim: Organizasyonel bir bakış açısı ile basitçe ifade etmek gerekirse yönetim; organizasyonun hedeflerinin insanlar ve diğer kaynaklar aracılığıyla elde edilmesidir.

Yönetimin Beş Fonksiyonu: Planlama, organizasyon, personel, yönetme, kontrol [2].

Planlama: Bu yönetimsel işlev, geleceği öngörmek ve örgütsel hedeflere ulaşmak için en iyi eylem planını belirlemekle ilgilidir.

Organizasyon: Organizasyon, insan ve maddi kaynakları, görev ve otoritenin resmi bir yapısının tasarımıyla harmanlayan yönetim işlevi olarak tanımlanır.

Personel: Personel işlevi, kuruluş içinde doğru kişiyi doğru işe almak, seçmek, eğitmek ve görevlendirmekle ilgilidir.

Yönlendirme: Çalışanları organizasyonel hedeflere doğru yönlendirmek ve motive etmek.

Kontrol: Yönetimin nihai işlevi, organizasyonların performansının, hedeflerini gerçekleştirip gerçekleştirmediğini belirlemek için değerlendirildiği kontrol etmektir [2].

Proje Yönetimi: Proje hedeflerini karşılamak için yapılması gereken tüm faaliyetlerin planlanmasını, programlanmasını ve kontrol edilmesini kolaylaştıran bir yönetim biçimidir [4].

Başka bir deyişle proje yönetimi bilgilerin, becerilerin, araçların, insan kaynağının ve tekniklerin projenin gereksinimlerini yerine getirmek amacıyla proje aktivitelerine uygulanmasıdır.

Proje yönetimi, mantıksal olarak gruplanmış kırk iki proje yönetim sürecinin uygun şekilde uygulanması ve entegrasyonu şeklinde gerçekleştirilir. Bu süreçler beş grupta toplanmıştır. Bu gruplar [1];

- Başlangıç
- Planlama
- Yürütme
- İzleme ve Kontrol
- Kapanış

Bir projenin yönetilmesi genellikle şunları içerir: [1]

- Gereksinimlerin belirlenmesi
- Projenin planlanması ve yürütülmesi aşamalarında paydaşların çeşitli ihtiyaçlarının, kaygılarının ve beklentilerinin ele alınması
- Projenin birbiri ile çelişen kısıtlarının dengelenmesi bu kısıtların bazıları şunlardır:
- Kapsam, kalite, zaman çizelgesi, bütçe, kaynaklar, risk

Bu faktörler arasındaki ilişkiden ötürü, herhangi bir faktörde değişiklik olması durumunda diğer faktörlerin en azından birinin etkilenmesi muhtemeldir. Örneğin, zaman çizelgesi kısaltıldığında, çoğu zaman aynı miktarda işi daha kısa bir sürede tamamlayabilmek için ek kaynaklara başvurulur ve bunun için bütçenin artırılması gerekebilir. Bütçe artışı mümkün değilse, aynı bütçeyle daha kısa sürede bir ürün elde edilebilmesi için kapsam ya da kalite düşürülebilir. Bu tür durumlarda proje paydaşlarının, hangi faktörün müşteri beklentilerinin karşılanmasında diğer faktöre göre daha önemli olduğunun kararını vermeleri gerekir. Proje paydaşlarının en önemli faktörlerin hangisi olduğu konusunda birbirlerinden farklı fikirleri olabilir ve bu durum daha da büyük bir güçlüğün doğmasına yol açar. Proje gereksinimlerini

değiştirmek farklı riskler doğurabilir. Proje ekibi, başarılı bir proje gerçekleştirebilmek için durumu değerlendirebilmek ve talepleri dengeleyebilmek zorundadır.

Değişiklik potansiyeli nedeniyle, proje yönetimi planı sürekli güncellenir ve projenin yaşam döngüsü boyunca aşamalı bir olgunlaşma sürecinden geçer. Aşamalı olgunlaşma, daha ayrıntılı ve daha özellikli bilgiler ve daha geçerli tahminler elde edildikçe planın sürekli olarak iyileştirilmesi ve ayrıntı hale getirilmesi sürecidir. Bu süreç, bir proje yönetim ekibinin, proje ilerledikçe artan bir ayrıntı düzeyine ulaşmasını mümkün kılar.

2.2.1. Proje Yönetim Sistemi

Sürdürülen bir projede iyi bir proje yönetimine sahip olunmak istenirse uygun bir proje yönetim sistemini oluşturan yedi bileşen vardır [4].

1) İnsan

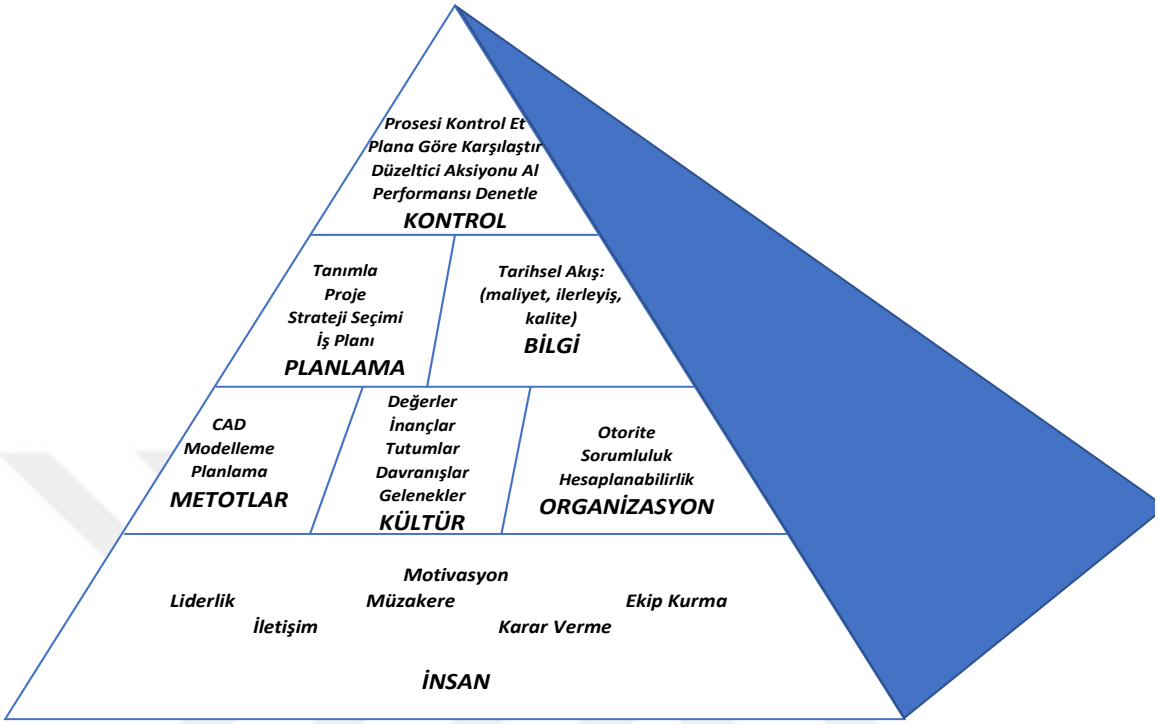
İnsan kaynağı bir projenin yürütülmesinde en temel kaynaktır. Yönetim sisteminin en alt kısmında yer alır. Bunun nedeni, insanların iyi yönetilmesi durumunda tüm yapının destekleneceği ve daha iyi sonuçlar alınmasını sağlayacağındandır.

2) Kültür

Kültür, kelime olarak bir organizasyonda var olan değerlerin, tutumların, geleneklerin ve davranışların toplamını belirtir. Projeler küresel hale geldiğinden ve proje ekiplerinin kültürel olarak çeşitliliği arttığından, proje yöneticilerinin kültürel farklılıklar ve bu farklılıklarla nasıl başa çıkacaklarını öğrenmeleri ve onlara değer vermeleri önemlidir [4].

3) Yöntemler

Piramidin yöntemler bileşeni, projeleri yönetmek için kullanılan araçları gösterir. Bu bileşen, programlama yöntemlerini, kazanılan değer analizini, iş dökümü yapılarını vb. içerir.



Şekil 2.2: Proje Yönetim Sistemi [4]

4) Organizasyon

Bu bileşen, bir projenin nasıl organize edildiğini ve şirketin organizasyon şemasının nasıl oluşturduğunu ele alır. Her kurum, çalışanlarının iş tanımı, yetki ve sorumluluk sınırlarını tanımlamalıdır.

5) Kontrol

Bir projeyi yönetiyor olmanın nedeni genellikle organizasyon tarafından istenen sonuçların alındığından emin olmaktır. Yönetilen işlerin kontrol altında olması proje yöneticisinin beklediği bir durumdur. Kontrol, yönetilen faaliyet için nerede olmanız gerektiği ile bulunulan durumun karşılaştırılması ile gerçekleştirilir. Karşılaştırılma sonucunda hedeflenen performanstan sapmaları düzeltmek için adımlar atılır.

6) Planlama

Projenin yönetilmesinde planın olmaması kontrole sahip olunamayacağı anlamına gelecektir. Çünkü, ilk etapta nerede olunması gerektiğini bildiren faktör plandır. Ayrıca, nerede olduğunu bilmiyorsanız, kontrolünüz olamaz. Nerede olduğunuzun bilgisi sisteminizden gelir [4].

7) Bilgi

Çoğu kurum, envanter, bordro, sipariş ve diğer durumların takibi için bilgi sistemleri sağlama konusunda iyi bir iş çıkarır, ancak projeleri izleme sistemleri yoktur çünkü böyle bir sisteme ihtiyaç duyduklarını bilmemekte ya da buna yeterince önem vermemektedir. Bu durum çoğu proje yöneticisinin projelerini manuel olarak takip etmek zorunda olduğu anlamına gelir.

2.3.PROJE YÖNETİMİNDE ALTI SİGMA

Altı sigma, süreçler veya ürünlerdeki kabul edilebilir hatalarla uğraşan bir felsefedir. Buradaki fikir, bu tür hataları veya kusurları çok düşük seviyelere indirmektir.

Bir sürecin veya ürünün gereksinimlerine uygunluğunu gösteren normal bir dağılım eğrisi çizerseniz, ortalamanın her iki tarafındaki ± 3 standart sapmanın, nüfusun yüzde 99.74'ünü içereceğini görürsünüz. Yani, aldığınız önlemlerin yüzde 0.26'sı bu sınırların dışında kalacaktır. Ortalamanın sadece bir tarafını düşünürseniz, o zaman ölçülerin yüzde 0.13'ü kabul edilemez olacaktır (beklenenden daha iyi performans gösteren bir ürünün kabul edilebilir olduğunu varsayarak) [4].

Normal dağılım eğrisini ± 6 standart sapmayı kapsayacak şekilde çizerseniz, uygun olmayan önlemlerin yüzdesi bir milyonda 1'e düşer. Altı sigma sistemi, performans hedeflerinin bu seviyeye ayarlanmasını gerektirir.

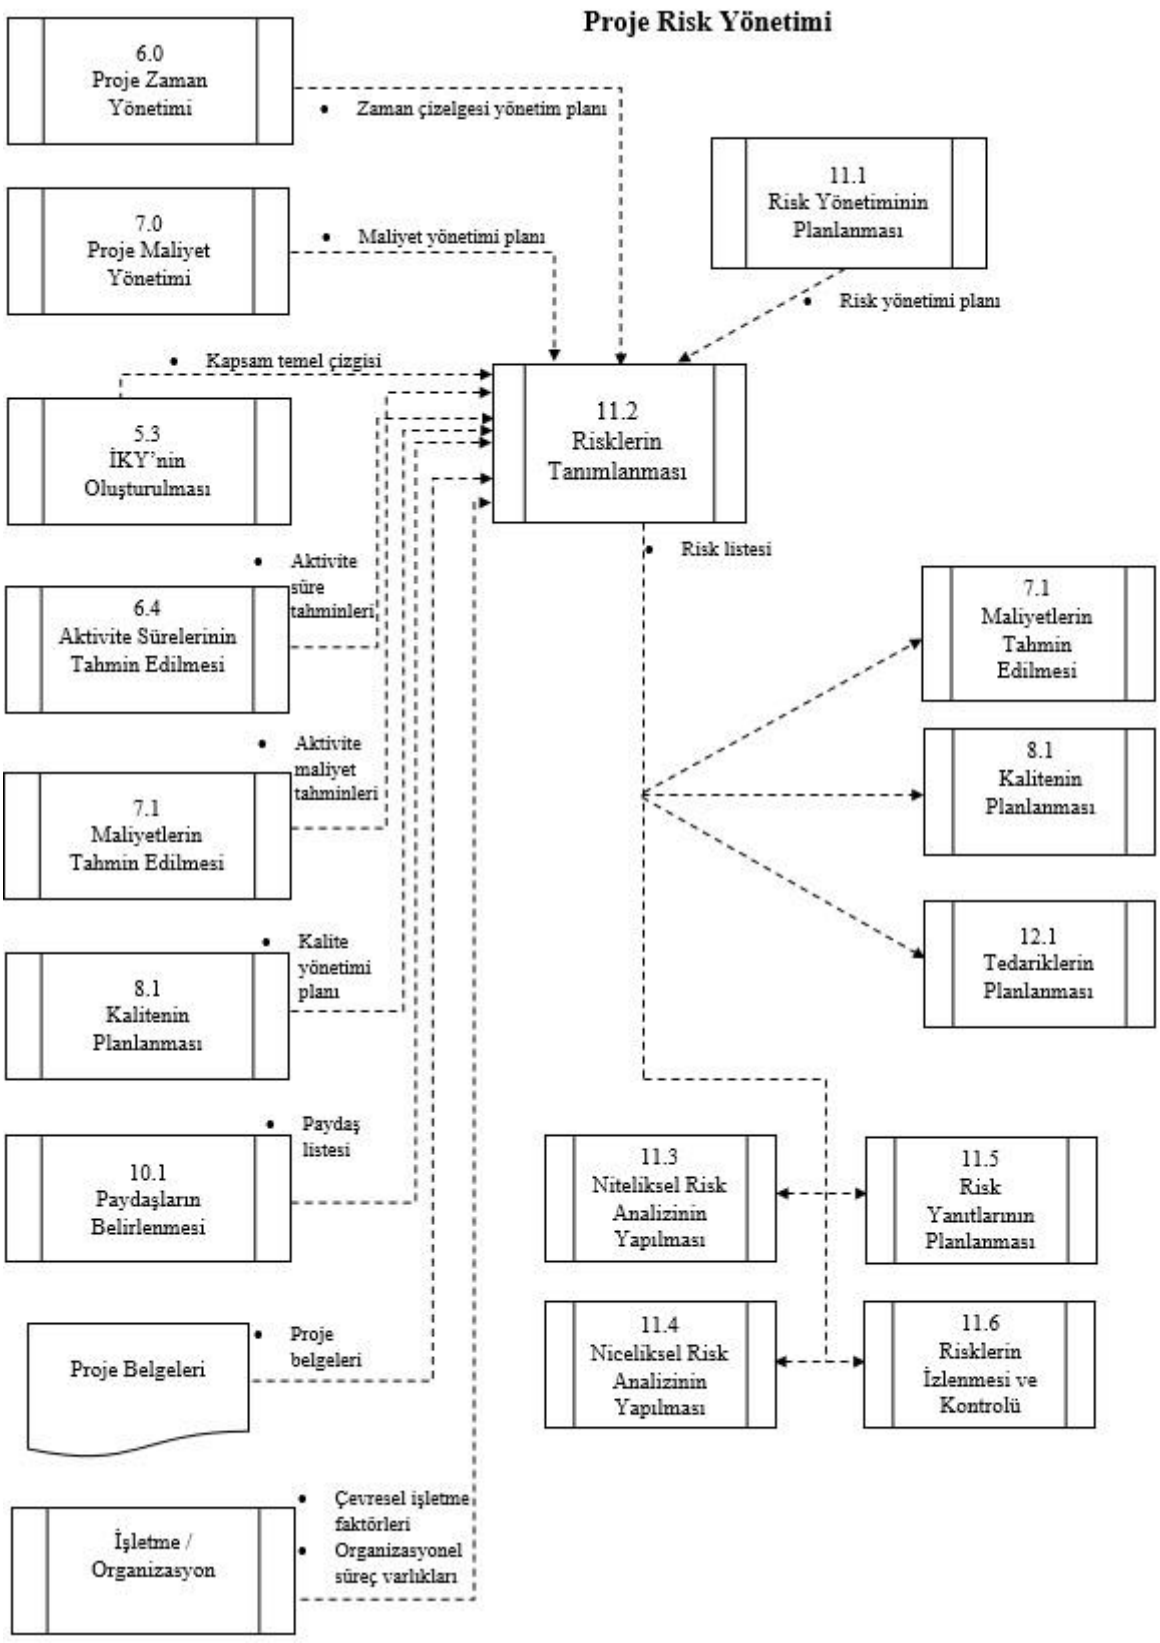
Proje yönetimi ve altı sigma farklıdır. Proje yönetimi, organizasyonların altı sigma performans hedeflerine ulaşmasına yardımcı olacak araçlar sunar.

2.4.RİSK YÖNETİMİ

Risk yönetimi tanımına ve yapılan araştırmalar sonucu elde edilen bilgilere geçmeden önce risk yönetiminin temelinin dayandığı “risk” ile ilgili bilgiler sunmak daha faydalı olacaktır.

Bir durum hakkındaki belirsizlik, genellikle riski, yani zarar, hasar veya istenmeyen herhangi bir olay olasılığını ifade edebilir. Çoğu insan düşük risk ister, bu da yüksek bir başarı, kâr veya bir çeşit kazanç anlamına gelir.

Örneğin, gelecek ay için satışlar belirli bir miktarın üzerindeyse (arzu edilen bir olay), siparişler envanteri azaltacak ve gönderim siparişlerinde gecikme olacaktır (istenmeyen bir olay). Nakliye gecikmesi emirleri kaybetmek anlamına gelirse, o zaman bu olasılık bir risk oluşturur [10].



Şekil 2.3: Proje Risk Yönetimi [1]

Hemen hemen her türlü değişiklik, iyi ya da kötü, bazı riskler doğurur. Şekil 2.3'de proje risk yönetiminde yapılması ve tanımlanması gereken durumlar belirtilmiştir. Kendi analiziniz genellikle çok sayıda potansiyel risk alanını ortaya çıkaracaktır: fazla mesai maliyetleri, envanter kıtlığı, gelecekteki satışlar, jeolojik araştırma sonuçları, personel dalgalanmaları, öngörülemeyen talep, değişen işgücü maliyetleri, hükümet onayları, potansiyel birleşmeler, bekleyen mevzuat bu risk alanlarına örnek olarak verilebilir [10].

Verilen bu bilgilerden sonra riski farklı yollardan tanımlayabiliriz. Bu tanımların bir kısmı aşağıda sunulmuştur:

İlk olarak, riski bazı olayların kesin olarak bilinmediği herhangi bir durumu temsil etmek olarak tanımlayabiliriz [8].

İkinci olarak, risk, kaybetme olasılığı olarak tanımlanabilir. Yani, eğer bir hisse senedi sahibiyiz ve fiyat düşüşü olasılığı varsa, risk altındayız. Hisse senedi risk değildir, kayıp da risk değildir. Kayıp olasılığı risktir. Hisse senedine sahip olduğumuz sürece, risk altındayız. Riski kontrol etmenin tek yolu hisse senedi almak veya satmaktır [7].

Üçüncü olarak, risk, istenmeyen bir sonucun (veya arzu edilen sonucun yokluğunun) projenizi bozma olasılığı olarak tanımlanır. Ürün inovasyonunda risk doğar ve bu nedenle bir projeyle ilgili her karar risk içerir çünkü her zaman aşağı akışa kadar sahip olamayacağımız bilgiler vardır. İşletmeler, günümüzün piyasaya sürdüğü zamanlardaki artan odaklanma nedeniyle belirli riskler üstlenirler [9].

Risk Yönetimi: Yönetmek, yönlendirmek ve kontrol etmektir. Risk yönetimi, kayıp olasılığını yönlendirmek ve kontrol etmektir. Bir risk yöneticisinin faaliyetleri, riski ölçmek ve hisse senedi alıp satarak riski arttırmak ve azaltmaktır.



Şekil 2.4: Proje Risk Yönetimine Genel Bakış [1]

Şekil 2.4'de bir proje risk yönetiminde genel olarak hangi unsurların yer aldığı gösterilmiştir.

Genel olarak, iyi bir risk yönetimi birkaç unsuru birleştirir [7]:

1. Ticaret ve risk yönetim sistemlerini bilgisayar koduna dönüştürene kadar açıklığa kavuşturmak.

2. Çeşitlendirme ve cihaz seçiminin geri test sürecine dahil edilmesi.

3. İşlem parametresi duyarlılığını ve optimal değerleri belirlemek için geri test ve stres testi.

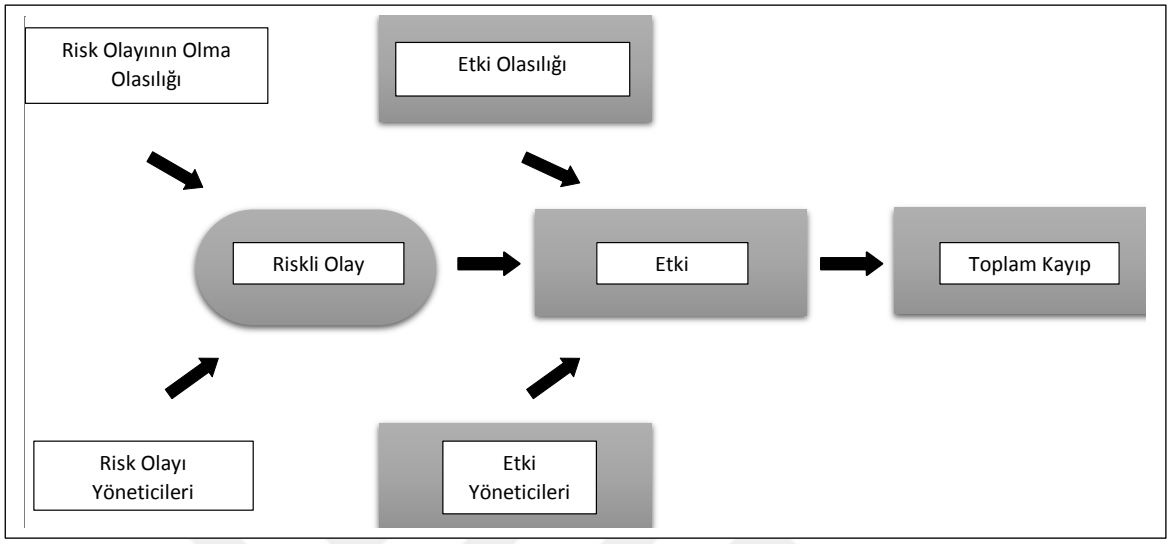
4. Tüm tarafların volatilite ve getiri beklentisi konusunda anlaşmaya varılması.

5. Yatırımcılar ve yöneticiler arasındaki destekleyici ilişkilerin sürdürülmesi.

6. Her şeyden önce, sisteme bağlı kalır.

2.4.1.Riskli Olay

Riskli bir olayı, önceden kesin olarak bilinmeyen herhangi bir olay olarak tanımlarız [8]. Bu, riskin temel özellikleri hakkında bazı ipuçları verir. Birincisi, olayların (örneğin, gerçekleşmiş ve gözlemlenmiş olan olayların) emin olduğunu belirler. İkincisi, zamanın temel bir risk özelliği olduğunu öne sürmektedir. Gerçekten de öğrenmeye izin vermek, bugün bilinmeyen bazı olaylar yarın bilinebilir. (Örneğin belirli bir yerdeki yağışlar). Bu, riskin zamansal boyutunu vurgulamaktadır.



Şekil 2.5: Proje Risklerini Modelleyen Standart Risk Modeli [9]

Üç ana faktör, riskli olayların varlığına ve yaygınlığına katkıda bulunur. Birincisi, olayların kesin olarak bazı nedensel faktörlerini kontrol edememe mi z ve / veya ölçmememiz nedeniyle risk vardır. Buna iyi bir örnek bir bozuk paranın havaya atılıp çevirmenin sonucudur. Bir madeni parayı çevirme sürecinde anlaşılmayacak bir şeyin olup olmadığını bir mühendise veya bir fizikçiye sorun. Verecekleri cevap bu olayda anlaşılmayacak bir şeyin olmayacağıdır. Çünkü madeni paranın izlediği yolu yöneten fizik yasaları iyi bir şekilde anlaşılmıştır. Peki, sonuç neden önceden bilinememektedir? Cevap, madeni paranın asla iki kez tam olarak aynı şekilde havaya atılamamasıdır. Sonuç olarak madeni para yörüngesi yeterince uzun olduğu sürece, paranın nasıl ineceğini tahmin etmek zordur. Buradaki belirsizliği ortaya koyan şey, madeni para yörüngesinin başlangıç koşullarının tam olarak kontrol edilememesidir. Bu kontrol edilememe durumu bozuk paranın havaya atılması olayını riskli bir olay haline getirmektedir.

İkinci olarak, bilginin işlenmesi konusunda sınırlı bir yeteneğimizin olmasından dolayı riskin oluşmasıdır. Buna iyi bir örnek; bir satranç oyunu oynamanın sonucudur. Bir satranç oyunu iyi tanımlanmış kurallar içerir ve başlangıç koşulları verilir. Bu nedenle oyun hakkında bir belirsizlik yoktur. Ve sadece üç olası sonuç var: Belirli bir oyuncu kazanabilir, kaybedebilir veya berabere kalabilir. Peki neden bir satranç oyunu sonucu belirsiz? Çünkü kazanmayı garanti edebilecek bilinen bir oyun stratejisi yoktur.

İnsan ortamımız hakkında mevcut olan tüm bilgilerin işlenemeyeceğini fark ettikten sonra, riskli olayların çok yaygın olduğu ortaya çıkmaktadır.

Üçüncüsü, insan beyni çok miktarda bilgi alıp işleyebilse bile, bu, bu bilgilerin kullanılacağı anlamına gelmez. Gerçekten, bilgi elde etmek ve işlemek genellikle maliyetlidir. Bilgi maliyeti birçok şekil alabilir. Parasal olmayan bir maliyet (örneğin, harcanan zamanın öğrenme maliyeti) gibi bir parasal maliyet (örneğin, bir gazetenin satın alınması veya danışmanlık hizmetleri için ödeme) içerebilir. İnsan öğreniminin zaman alıcı olduğu ve bu sürenin kıt kaynak olduğu göz önünde bulundurulduğunda, her bireyin neyi öğrenmesi gerektiğine karar vermek uygun olur. Sınırlı rasyonalite göz önüne alındığında, hiç kimsenin her şey hakkında çok şey bilmesi beklenemez.

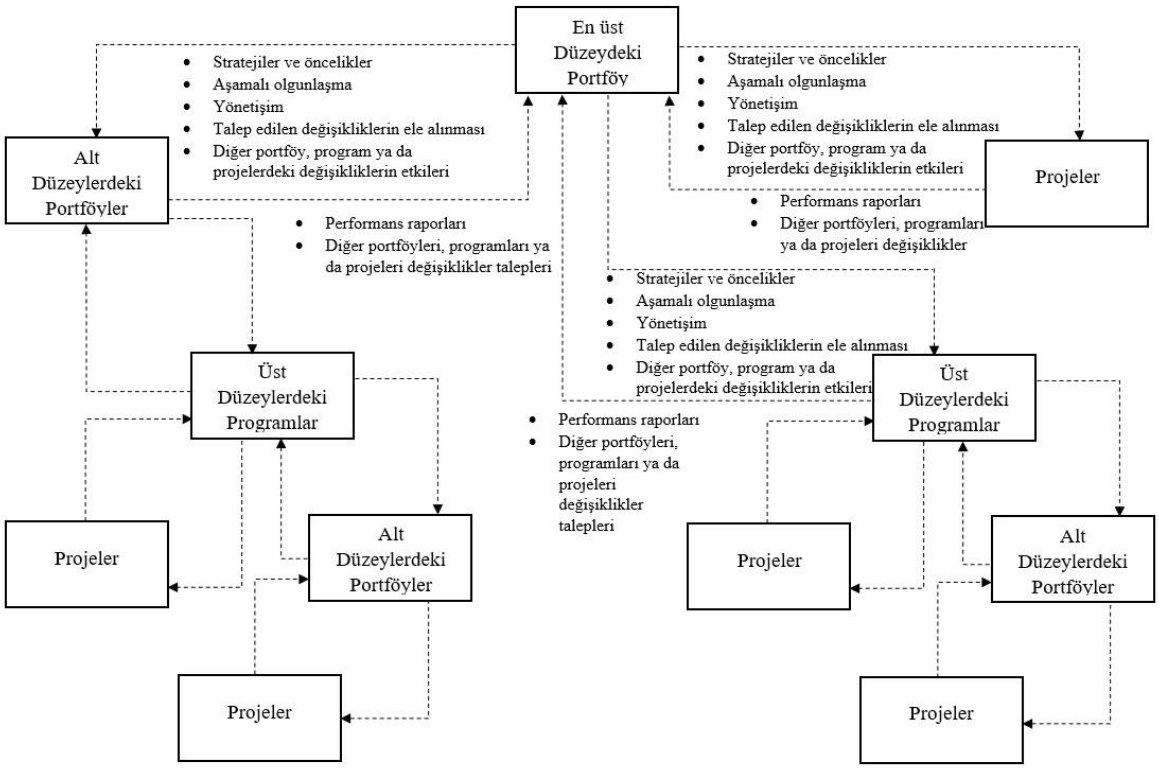
Sebepleri ne olursa olsun, tüm riskli olayların kendine özgü bir özelliği vardır: Bu olaylar kesin olarak bilinmemektedir. Bu, her zaman meydana gelebilecek birden fazla olasılık olduğu anlamına gelir. Bu ortak özellik, riskli olaylara bazı yapıları yerleştirmeye çalışan birleşik bir teori tarafından ele geçirilmiştir. Bu olasılık teorisidir. Bilimsel topluluk, olasılık teorisini, riskli olayları tanımlayıp temsil edebilen resmi bir yapı olarak ileri sürmüştür. Risk prevalansı dikkate alındığında, olasılık teorisi yaygın bir şekilde benimsenmiş ve kullanılmıştır.

2.4.2.Riske Maruz Değer (Value At Risk)

Riske Maruz Değer (VaR), belirli bir zaman aralığında belirli bir zaman aralığında normal piyasa koşullarında beklenen en kötü kayıpları ölçer.

Riske maruz değer kavramı ve kullanımı son zamanlarda artış göstermiştir. Risk altındaki değer ilk olarak 1980'lerin sonlarında büyük ticari kuruluşlar tarafından ticari portföylerinin risklerini ölçmek için kullanılmıştır. Bu zaman diliminden beri riskte değer kullanımı patladı. Halihazırda riske maruz değer, piyasa riskini ölçmek ve yönetmek için çoğu ana türev satıcı tarafından kullanılmaktadır. 1994 yılında yapılan Global Thirty'nin 2001 yılı global türev projesinde yapılan araştırmaya göre, bayilerin% 43'ü risk altında bir çeşit değer kullandıklarını, % 37'si ise 1995 yılının sonuna doğru riske maruz kalmayı planladıklarını belirtmişlerdir [11].

Bunu ifade etmenin başka bir yolu, Riske maruz değerin belirli bir süre zarfında belirli bir portföyde meydana gelebilecek olası zararların en düşük miktarını oluşturmasıdır [13].



Şekil 2.6: Proje, Program ve Portföy Yönetimleri Arasındaki Etkileşimler [13]

Şekil 2.6'da proje, program ve portföy yönetimlerinin arasındaki etkileşimler ifade edilmiştir.Riske maruz değer, olası portföy zararlarının tek, özet ve istatistiksel bir ölçümüdür. Özellikle, risk altındaki değer, "normal" piyasa hareketlerinden kaynaklanan kayıpların bir ölçütüdür. Riske maruz değerden daha büyük kayıplar, sadece belirtilen küçük bir olasılıkla zarar görür. Hesaplamada kullanılan sadeleştirme varsayımlarına bağlı olarak, riske maruz değer, bir portföydeki tüm riskleri yönetim kurulunda kullanılmak üzere uygun bir sayıya toplar, düzenleyicilere rapor verir veya bir yıllık raporda ifşa eder. Portföy üzerindeki olası zararların büyüklüğünü açıklamanın bir yoludur [11].

Piyasa riski öncelikle riske maruz değer ile ölçülür. Riske maruz değer, açıklanması basit bir dezavantaj riski istatistiki ölçüsüdür. Riske maruz değer portföy çeşitliliğini ve baskısını dikkate alarak portföy riskini ölçer.

Teoride, risk yöneticileri belirlenen koşullar çerçevesinde tüm kâr ve zarar dağılımını rapor etmelidir. Gerçek yaşamda (uygulamada) ise bu %99 güven düzeyinde en kötü kayıp şeklinde bir sayı ile özetlenmektedir. Bununla birlikte riske maruz değer, risk yöneticilerinin kullandığı önlemlerden sadece birisidir. Çok daha yüksek güven düzeyleriyle ilişkilendirilen aşırı piyasa koşullarında potansiyel kayıplar daha iyi tanımlanmalıdır.

Riske maruz değer devrimi, 1993 yılında, türevlerle uğraşmak için "en iyi uygulamalar" ın bir parçası olarak Otuz (G-30) Grubu tarafından onaylandığı zaman başladı. Bununla birlikte, riske maruz değerin arkasındaki yöntem yeni değildir. Finansal araçların fiyatlandırılmasına ve duyarlılığına odaklanan finans teorisinin bir birleşmesinden ve risk faktörlerinin davranışlarını inceleyen istatistiklerden kaynaklanmaktadır.

Tablo 2.1'de analitik risk yönetimi araçlarının gelişimi gösterilmiştir. VAR, önceki araçları olmadan gerçekleşemezdi. VAR, kurumun piyasa riskine tutarlı firma çapında risk ölçümleri uygulayarak risk yönetiminde devrim yaratmıştır. Bu yöntemler artık kredi riskine, operasyonel riske ve entegre veya firma çapında risk yönetimine ait kutsal kazıma genişletilmiştir [14].

Tablo 2.1: Analitik Risk Yönetimi Araçlarının Gelişimi [14]

1938	Tahvil Süresi
1952	Markowitz Ortalama Varyans Sistemi
1963	Sharpe'nin Sermaye Varlığı Fiyatlandırma Modeli
1966	Çoklu Faktör Modelleri
1973	Black-Scholes Opsiyon Fiyatlama Modeli
1988	Banka İçin Risk Ağırlıklı Varlıklar
1993	Riske Maruz Değer
1994	Risk Metrikleri
1997	Kredi Metrikleri

1998	Kredi ve Piyasa Riskinin Entegrasyonu
1998	Risk Bütçelemesi

2.4.3. Monte Carlo Simülasyonu

Simülasyonlar, finansal ekonominin temelidir [14]. Risk yöneticilerinin analitik olarak modellemek için çok karmaşık olan portföylerin dağılımını oluşturmasına olanak sağlar. Simülasyon kelimesini kullanarak, gerçek hayat sistemini taklit etmeyi amaçlayan herhangi bir analitik yönteme başvurduğumuzu belirtiriz; özellikle de diğer analizler matematiksel olarak karmaşık olduğunda veya çoğaltılması çok zor olduğunda. Monte Carlo simülasyonu, bir modeli simüle etmek için belirsiz değişkenler için ardışık olarak değerler üreten bir simülasyon şeklidir.

Simülasyon yardımı olmadan, bir elektronik tablo modeli yalnızca genel olarak en olası veya ortalama senaryosu olan tek bir sonucu ortaya koyacaktır. Elektronik tablo risk analizi, modellenen sistemin çıktıları üzerinde değişen girdilerin etkisini otomatik olarak analiz etmek için hem bir model hem de simülasyon kullanır. E-tabloların kendileri simülasyonları çalıştıramayacağından, bu işlevselliği sağlamak için bir e-tablo eklentisine ihtiyacınız olacaktır [10].

Simülasyon metotları oldukça esnektir ve bilgisayar kullanımında teknolojik gelişmeler ile uygulanması daha kolay hale gelmektedir. Bununla birlikte, dezavantajları hafife alınmamalıdır. Simülasyon sonuçları, modelin varsayımlarına büyük ölçüde bağlıdır: dağılımın şekli, parametreler ve fiyatlandırma işlevleri. Risk yöneticileri, bu varsayımlardaki hataların sonuçlarda yaratabileceği etkinin farkında olmalıdırlar.

Bir simülasyon çok daha kısa sürede çok daha titiz bir analizle sonuçları verir. Simülasyon , sadece belirli bir sonucun kesinliğini belirlemenize yardımcı olmakla kalmaz aynı zamanda olası sonuçların aralığını da anlamanıza yardımcı olabilir.

Sonuçlarınızı analiz ettikten sonra, temel model varsayımlarınızı sorgulamaya ve hassaslaştırmaya başlayabilir ve daha doğru risk tahminleri yapabilirsiniz. Basitçe, kendi içsel risklerinizi daha iyi anlayarak, başarıya ulaşma olasılığınızı arttırabilirsiniz.

Monte Carlo simülasyonu adını kumarhaneleri ile meşhur olan Monte Carlo, Monaco şehrinden almıştır. Rulet çarkı, zar ve slot makineleri gibi şans oyunları, rastgele davranış sergiler.

Şans oyunlarındaki rastgele davranış, Monte Carlo simülasyonunun bir modeli simüle etmek için rasgele değişken değerleri nasıl seçtiğine benzemektedir. Bir zarı attığınızda, 1, 2, 3, 4, 5 veya 6'nın çıkacağını biliyorsunuz, ama hangi rulo için hangisinin olduğunu bilmiyorsunuz. Bu, bilinen bir değerler aralığına sahip olan ancak belirli bir zaman veya olay için belirsiz bir değere sahip değişkenlerle aynıdır (ör., Faiz oranları, personel ihtiyaçları, hisse senedi fiyatları, envanter, dakika başına telefon görüşmeleri) [10].

Monte Carlo Simülasyonu yöntemi, piyasa değişikliklerinin müşterek dağılımı hakkında bazı bilgilere sahip olduğumuz varsayımına dayanmaktadır. Daha sonra bu dağılımı kullanarak çok sayıda senaryoyu rasgele çizebilir ve her senaryo için portföyü fiyatlandırabiliriz. Zengin bir senaryo seti, portföyün nihai değerinin dağıtımı için iyi bir yaklaşım sağlayacaktır.

Bu dağılımın en düşük q-büyüklüğü, riske maruz değere bir yaklaşım olarak kullanılabilir. Üstelik bu yöntem dinamik bir gelişme sağlar. Biri küçük bir simülasyon seti çalıştırabilir, bir ön sonuç alabilir ve daha sonra gerekirse ek simülasyonlar çalıştırarak bunu geliştirebilir. Monte Carlo simülasyon yöntemi çok yavaştır, ancak muhtemelen en güçlü yöntemdir. Özel bilgileri tarihsel gözlemlerle birleştirmek için yeterince esnektir. Varyans azaltma teknikleri denilen birçok hesaplama metodu vardır [13].

Monte Carlo risk analizi modellemesi, bir problem üzerinde risk ve belirsizliğin etkisini matematiksel olarak tanımlamak için bir dizi teknik içermektedir. Modeldeki her belirsiz parametre bir olasılık dağılımı ile temsil edilir. Bu dağılımların şekli ve boyutu, parametrelerin alabileceği değerler ve bunların göreceli olasılıklarını tanımlar. İlgili model tarafından hesaplanan miktarlar çıktı olarak seçilir. Monte Carlo risk analiz yazılımı daha sonra, olasılık dağılımlarından yüzlerce, hatta binlerce olası senaryoyu hesaplamak için rasgele olarak değerler üretir. Bu çıktılar için hesaplanan değerler her senaryo için saklanır (yineleme). Simülasyonun sonunda, bu değerler, modelin çıktılarının belirsizliğinin değerlendirmesini üretmek için toplanır ve analiz edilir.

Monte Carlo modelinin sonuçları, bu çıktıların olasılık dağılımları, ilişkili tanımlayıcı istatistikler ve girdi ve çıktı belirsizlikleri arasındaki ilişkinin ölçüleridir [6].

Monte Carlo simülasyonlarının yapılması zordu. Bununla birlikte, PC'lerin, yazılımların ve bilgisayar okuryazarlığının hızlı ilerlemesiyle, teknik yaygın bir şekilde erişilebilir hale gelmiştir. E-tablolar çok yaygın bir modelleme aracı haline geldi ve @RISK (Palisade Corporation, Newfield, New York) ve Crystal Ball (Decisioneering Inc., Denver, Colorado) gibi ürünler, elektronik tablo programlarının yeteneklerini Monte Carlo modellemesi içerecek şekilde genişletti. Ayrıca, projelendirme araçlarına projenin Monte Carlo yeteneklerini eklemek için proje program süreleri ve maliyetlerine belirsizliğin belirlenmesine olanak veren yazılım programları da mevcuttur [6].

İnsanların yazılımlara olan inançlarının talihsiz bir yan etkisi, risk analiz yazılımı satın almanın güvenilir risk analizlerini anında gerçekleştirebileceklerine inandıklarıdır. Bir risk analizi modeli, geleneksel tek nokta tahmin (determinist) modellerinden çok daha karmaşıktır. Bu bölüm, Monte Carlo risk analizinin temel gereksinimlerini ele alır ve okuyucunun risk analizi modellemesinin doğruluğunu sağlamak için bazı giriş teknikleri sunar.

Monte Carlo risk analizi, risk ve belirsizliğin değerlendirilmesi için tek teknik olarak düşünülmemelidir. Riskleri analiz etmek için bir dizi başka sayısal araç vardır ve diğer, niteliksiz yönlerin de genellikle dikkate alınması gerekir. Karar verici, Monte Carlo risk analizini karar sürecine çeşitli tamamlayıcı girdilerden biri olarak kullanmalıdır.

2.5. YAPAY SİNİR AĞLARI

Yapay sinir ağları, endüstriyel uygulamalarda karmaşık sanayi süreçlerini modelleme ve tahmin etme gibi görevlerde kullanılmaktadır. Çoğunlukla, yapay sinir ağları, süreçlerin girdileri ve çıktıları arasında rasgele doğrusal olmayan ve son derece karmaşık ilişkiler yakalama yetenekleri için kullanılmıştır. Ek olarak, büyük kurumsal veri tabanlarının veri madenciliğinde yapay sinir ağları giderek daha cazip hale gelmektedir çünkü daha önce alan bilgisi gerektirmezler ve sayısal olarak verimli sonuçlar ortaya koyarlar [18].

Saniyede 100 milyon işlem yapabilen bilgisayarlar yine de görsel şekillerin ifade ettiklerini anlayamamakta ya da çeşitli nesneler arasında ayrım yapamamaktadır. Sıralı hesaplama sistemleri, matematiksel veya bilimsel problemleri çözmede başarılıdır. Bunlara örnek olarak; veri tabanlarını oluşturma, işleme ve sürdürme; elektronik iletişimde; metinler, grafikler ve otomatik düzenleme işlemlerinde; ve hatta elektrikli ev cihazları için kontrol fonksiyonlarını

daha verimli ve kullanıcı dostu yapmak verilebilir. Ancak, dünyayı yorumlamada neredeyse ‘’okuma – yazma’’ bilmeyen bir insan gibidirler.

Bu problem, Von Neumann’ın sıralı sistem felsefesine (Neumann, 1956) dayanan bilgi işlem sistemi için tipik bir durumdur. Bu da, araştırmacıları, insan beyninin yaptığı gibi, günlük problemleri çözen yapay sinir ağları veya bağlantı sistemlerinin geliştirilmesine odaklanmaya itmiştir. Bu biyolojik organ (beyin), herhangi bir dijital işlem sistemi için oldukça önemli olan çeşitli özelliklere sahiptir: Sağlam ve hataya toleranslıdır, nöronlar işleyişi etkilemeden her gün ölürler. Socratic öğrenme yoluyla (yani örneklerle) yeni ortamlara uyum sağladığından ve zorunlu olarak programlama gerektirmediğinden, esnektir. Dağınık bilgiyi (yani tutarsızlık veya gürültü durumlarını) yönetebilir. Son derece paralel ve dolayısıyla etkilidir. Küçük, kompakt ve az enerji tüketir. İnsan beyni, gerçekten, kesin olmayan bir şekilde duyuları kesin olmayan bilgileri yorumlayabilen bir “bilgisayar” dır. Gürültülü bir odada bir fısıltıyı ayırt edebilir, karanlık bir sokakta bir yüzü tanıyabilir ve çizgiler arasında okuyabilir ve en şaşırtıcı şekilde, bu yetenekleri herhangi bir açık talimat olmadan mümkün kılan içsel temsili oluşturmayı öğrenir.

Yapay sinir ağları veya bağlantı sistemleri, biyolojik sinir ağlarını, görevlerin programlanmasını gerektirmediği, ancak genellemek ve deneyimleyerek öğrenmek istedikleri için taklit ederler. Mevcut yapay sinir ağları, biyolojik nöronları taklit eden çok sayıdaki basit işlem elemanlarından ve aralarındaki belli sayıda bağlantıdan oluşur. Talimatlar uygulamazlar, sunulan girdilere paralel olarak cevap verirler ve bir işlem elemanı veya bir bağlantının çalışması durduğunda veya bilgilerin belirli bir gürültü seviyesine sahip olduğunda doğru şekilde çalışabilirler. Bu nedenle, girişlere yanıt olarak sistemin sunduğu çıktıyı ayarlamak için işleme elemanları bağlantılarıyla ilişkili değerleri değiştiren bir eğitim süreci yoluyla öğrenebilen bir hata ve gürültü toleranslı sistemdir. Sonuç bir bellek konumunda saklanmaz; bir dengeye ulaşılan ağın durumu. Yapay bir sinir ağının bilgi ve gücü, kendi yönergelerinde değil, topolojisinde (işleme elemanlarının konumu ve aralarındaki bağlantılar), işleme elemanları arasındaki bağlantıların (ağırlıkların) değerlerinde ve öğelerini ve öğrenme mekanizmalarını tanımlar.

Yapay sinir ağı ile yapılan çeşitli deneyler, gerçekliği yansıtmayan yöntemlerin kullanılması nedeniyle, bağlantı sistemlerinin ve biyolojik nöron ağlarının işleyişi arasındaki çatışmaların varlığını göstermiştir. Örneğin, basit bir bağlantı sistemi olan çok katmanlı bir algılayıcı

durumunda, işleme elemanları arasındaki sinaptik bağlantılar, eksitatör veya inhibitör olabilen ağırlığa sahipken, doğal sinir sisteminde nöronlar bu işlevleri temsil ediyor gibi görünmektedir. bağlantılar; Son araştırmalar (Perea ve Araque, 2002) glial sistemin hücrelerinin, daha somut olarak astrositlerin de önemli bir rol oynadığını göstermektedir. (Astrosit: Beyin ve omurilikte en fazla bulunan glia hücredir. Beyindeki iyon dengesinin korunmasında rol oynarlar. Ayrıca sinir sistemi hasar gördüğünde tamir etmek için astrositler görev alır.) (Glia Hücreleri: Sinir sisteminde nöronların yanında sayıları nöronlardan 10 ile 50 kat daha fazla olan destek hücrelerine verilen addır.)

Diğer bir sınırlama, “geri yayılım” olarak bilinen öğrenme algoritması ile ilgilidir. Bu, bağlantı değerinin değişiminin, yapay sinir ağlarındaki hata sinyalinin geriye doğru iletilmesini gerektirdiğini ima eder. Geleneksel olarak, bu davranışın, Cajal'ın (1904) “dinamik polarizasyon” teorisine göre hücresel somaya ulaşana kadar akson boyunca bilgiyi verimli bir şekilde iletemediği doğal bir nöronda imkânsız olduğu varsayılmıştır; Bununla birlikte, yeni araştırmalar, nöronların belirli koşullar altında ya dendritlerdeki mevcut mekanizmalar vasıtasıyla ya da astrosit gibi glial hücrelerin çeşitli müdahaleleri yoluyla, enformasyona karşı nöronlara bilgi gönderebildiğini keşfetmiştir.

Geri yayılım modelleri ile doğal model arasındaki bu farklılıklar kendi içlerinde çok önemli değildir. Yapay modellerin tasarımı, doğal modelin mükemmel bir kopyasını elde etmeyi amaçlamıyordu, ancak nihai işlevi mümkün olduğu kadar yaklaşan bir dizi davranış vardı. Yine de, her ikisi arasındaki yakın benzerlik, çıktıyı iyileştirmek ve yapay sinir ağlarının karmaşıklığını arttırmak için vazgeçilmezdir ve daha “akıllı” davranışlarla sonuçlanabilir. Bu bağlamda, bu çalışmanın nörobilimde en son keşifleri ne ölçüde analiz ettiği (Araque ve ark., 2001; Perea & Araque, 2002) bu ağlara katkıda bulunmaktadır: Serebral aktiviteden ilerleyen bölgelerdeki keşifler; bilginin öğrenilmesi ve işlenmesinde yer almıştır (Porto, 2004).

Son olarak, var olan yapay sinir ağ modellerinin yeni yapıların gelişimine yönelik yeniliğinin, öğrenme parametrelerine yeni parametreleri entegre etmeleri gerekliliği ile değerlerini ayarlayabilmeleri için şartlandığını hatırlamalıyız. Yapay sinir ağının işleme elemanlarını yeni işlevler ile sağlayan yeni parametreler, hesaplamaların çıktısını arttıran ve temel olarak algoritmanın hesaplama tarafı üzerinde çalışan en sık kullanılan algoritmaların optimizasyonlarından daha zordur.

2.5.1. Yapay Zekâ Çalışmalarındaki Gelişmeler

Günümüze kadar geliştirilen hesaplama modellerinin analizi, yapay sinir ağlarının (YSA) bilgi işlem paradigmaları olarak belirli sınırlara sahip olduğunu göstermektedir. Bu sınırlamaların, mevcut modellerin nöronların belirli davranışlarını yansıtmadığı veya yapay nöron olmayan elementlerin katılımını göz önünde bulundurmadığı gerçeğine inanıyoruz.

YSA, insan beynini taklit ettiği için, araştırmacılar, nöronların sinir sisteminde sahip oldukları önemi temsil etmeye çalışmışlardır. Bununla birlikte, son yıllarda, nöro bilim alanında araştırmalar kayda değer bir şekilde ilerlemiş ve giderek artan karmaşık sinir devreleri ve aynı zamanda glial sistem, yakından gözlemlenmektedir. Glial sistemin önemi araştırmacılara, sinir sistemindeki bilgilerin işlenmesine katılımlarının daha önce varsayıldığından çok daha alakalı olduğunu düşünmelerine neden olmaktadır. Bu durumda, nöron olmayan diğer unsurların yapay modellerine entegre edilmesi yararlı olabilir. Şu ana kadar yapay modellerde dikkate alınmamış olan bu yardımcı unsurlar, impuls (uyarı) iletiminin hızlanması, en iyi aktarım yollarının oluşturulması, belirli bir unsuru oluşturan unsurların seçimi gibi özel görevlerden sorumlu olacaklardır. Devre, bilginin "sezgisel" işlenmesi (belirli bilgilerin işlenmesine müdahale etmemek için diğer devrelerin uyarılması), vb.

McCulloch ve Pitts (1943) ve Wiener (1985) ve Von Neumann (1958) gibi diğer yazarlar, sibernetik üzerine yaptıkları çalışmalarda ve otomatlar üzerindeki teorileriyle, biyolojik süreçlerin mühendislik yöntemleri ile entegrasyon problemini çözen ilk kişilerdi.[16]

McCulloch ve Pitts, şimdi isimlerini taşıyan yapay nöron modelini önermiştir: iki durumlu ikili bir cihaz ve hepsi aynı eylem ve küresel eylem inhibitörleri ile uyarıcı bağlantılar veya sinapslar alan sabit bir eşik. Beyin nöronlarının yapısını ve işleyişini basitleştirdiler, onları m girişleri, tek bir çıkışı ve sadece iki olası durumu olan cihazları göz önünde bulunduruyorlardı: aktif veya inaktif. Bu ilk aşamada, hepsi de aynı zaman ölçeklerine sahip yapay nöronlardan oluşan bir ağ, diğer nöronların çıktılarının başkalarının girdilerine bağlı olduğu McCulloch ve Pitts nöronlarının bir toplamıydı.

McCulloch ve Pitts'in önerileri 1943'ten beri modifikasyonlar olmaksızın sürdürülüyor. Fakat yapay sinir ağlarında yapılan tüm matematiksel formüller, kesin modeller gibi davranmadan biyolojik sistemlerin, biyolojik sinir ağlarının araştırılması için bir başlangıç noktası olarak kullanılmasını sağladı. Son zamanlarda biyologların güçlü bir şekilde ilham aldığı bazı modellerin sunumundan kaynaklanmaktadır (Hopfield, 1989).

1950'lerin başlarında, Herbert Simon, Allen Newell ve Cliff Shaw, insan düşünce süreçlerini taklit etmek için yazılı programlarda deneyler yaptılar. Deneyler, zaten kanıtlanmış aksiyomların kurallarından oluşan Mantık Teorisi adlı bir programla sonuçlandı. Yeni bir mantıksal ifade verildiğinde, sezgisel algoritma kullanarak yeni ifadenin bir kanıtını bulmak için tüm olası işlemleri araştırırdı. Bu yapay zekâ gelişiminin önemli bir adımıydı. Mantık Teorisi, elli iki problemden otuz sekizini Whitehead ve Russel'in geliştirdiği kanıtlarla çabucak çözebiliyordu. Aynı zamanda Shanon, satranç oynayan bilgisayarların olasılığına dair bir makale ile çıktı.

Simon ve arkadaşları ile Shanon'un çalışmaları, akıllı bilgisayar programları kavramını gösterseler de, 1956 yılı Yapay Zekâ konusunun başlangıç yılı olarak kabul edilir. Çünkü John McCarthy, Marvin Minsky, Nathaniel Rochester ve New Hampshire'daki Dartmouth Koleji'nde Claude Shanon tarafından düzenlenen ilk yapay zekâ konferansı, 1956'da yapıldı. Bu konferans, makine istihbaratı alanındaki ilk organize çaba oldu. Bu konferansta LISP programlama dilinin geliştiricisi John McCarthy'nin Yapay Zekâ terimini önerdi. Dartmouth konferansı, sembollerin işlenmesi için bilgisayar kullanımının, yeni dillerin gerekliliğinin ve teoriye benzeyen donanımlara odaklanmak yerine teorem için bilgisayarların rolünün incelenmesinin önünü açtı.

Bu gelişmelere paralel olarak, Michigan Üniversitesi'ndeki John Holland, 1960'ların başlarında, Darwin'in güçlü bir arama mekanizması oluşturmak için en güçlü ve doğal genetik hayatta kalma teorisini bir araya getiren adaptif sistemleri geliştirmek için deneyler yaptı. Bu sistemler kapalı öğrenme yetenekleriyle, genetik algoritmalar olarak adlandırılan yeni bir problem çözme paradigması sınıfına yol açmıştır. Araştırma, optimizasyon, sentez ve öğrenme içeren uygulamaların prototip sistemleri, birçok mühendislik alanında çok ümit verici bulunan bu teknik kullanılarak geliştirilmiştir.

Pek çok kişi tarafından bilgisayar kullanılarak insan beyninde öğrenmeyi simüle etmek için kapsamlı araştırma ve geliştirme çalışmaları yürütülmüştür. Bu tür çalışmalar, Yapay Sinir Ağının, mühendislik alanındaki farklı alanlarda çok çeşitli problemleri çözmek için bir paradigma olarak ortaya çıkmasına yol açmıştır. Farklı problem sınıflarını çözmek için yapay sinir ağlarının farklı konfigürasyonları önerilmiştir. Ağ ilk olarak mevcut bir giriş ve çıkış grubu ile eğitilir. Eğitimden sonra, ağ aynı sınıfın farklı problemlerini çözebilir ve çıktı üretebilir. Çözümün hata seviyesi, ağı eğitmek için kullanılan sorun kümelerinin niteliğine ve sayısına bağlı olacaktır. Eğitim için kullanılan veri kümelerinin sayısı ve genişliği ne kadar fazla olursa, üretilen çözümlerde hata seviyesi o kadar az olacaktır. Aslında, bu teknik, mühendislik araştırma topluluğu arasında, uygulamadaki basitlik ve ürettiği sonuçlarda güvenilirlik nedeniyle, genetik algoritmalar gibi diğer tekniklere kıyasla çok popüler hale gelmiştir.

Yapay zekâ ve ilgili konular alanında gerçekleşen tüm bu gelişmeler sekiz özel dalda sınıflandırılabilir [15]:

1. Problem Çözme ve Planlama: Bu, hedef hiyerarşisinin sistematik olarak düzeltilmesi, gözden geçirme mekanizmalarını planlamak ve önemli hedeflerin odaklanmış bir araştırması ile ilgilidir.

2. Uzman Sistemler: Bu bilgi işleme ve karmaşık karar verme sorunları ile ilgilidir.

3. Doğal Dil İşleme: Otomatik metin oluşturma, metin işleme, makine çevirisi, konuşma sentezi ve analizi, metin dilbilgisi ve stil analizi gibi alanlar bu kategoriye girer.

4. Robotik: Bu, nesneleri manipüle etmek veya kavramak ve eylemleri yönlendirmek için sensörlerden bilgi kullanmak için robotların kontrol edilmesi ile ilgilidir.

5. Bilgisayar Görüsü: Bu konu akıllı görselleştirme, sahne analizi, görüntü anlayışı, işleme ve hareket türetme ile ilgilidir.

6. Öğrenme: Bu konu, farklı makine öğrenim şekillerinde araştırma ve geliştirme ile ilgilidir.

7. Genetik Algoritmalar: Bunlar, içsel öğrenme yeteneğine sahip uyarlamalı algoritmalardır. Arama, makine öğrenimi ve optimizasyonda kullanılırlar.

8. Sinir Ağları: Bu konu, kalıp tanıma görevlerini, tümdengelimli akıl yürütmeyi ve sayısal hesaplamaları birleştirerek insan beynindeki öğrenmenin simülasyonunu ele almaktadır.

Yapay sinir ağları, bir problem sınıfı için örneklerden kendi çözümlerini geliştirir. Ayrıca merkezi sinir sisteminin düşük seviyeli operasyonlarını simüle eden bağlantı sistemleri olarak da adlandırılır. İstenen bilgi işleme özellikleri beyinde öğrenme, genelleme ve hata toleransı gibi tezahür eder ve bunlar yakalanır ve yapay sinir ağlarında taklit edilir.

Bir yapay sinir ağı, bir ağ oluşturmak için birbirine bağlı olan nöronların bir koleksiyonu olarak görselleştirilebilir. Ağdaki nöronlar, ağın yapısı içinde paralel ve toplu olarak işlem yapar. Nöral ağlar, nöronların bağlantı şekilleri, operasyon modları ve ağların nasıl eğitildiği gibi farklı tiplere ayrılabilir. Bu özelliklerin uygun kombinasyonları, çözülmekte olan probleme bağlı olarak oluşturulacaktır [15].

2.5.2. Olasılıksal Sinir Ağları (PNN)

Geri yayılmanın temel farklılıklarına sahip yararlı bir sinir ağ mimarisine, Olasılıksal Sinir Ağı (veya PNN) denir [20]. Bu mimari, yapısal olarak ileriye doğru ilerlemesine rağmen, geri yayılmaya benzer, ancak öğrenmenin gerçekleştiği yolda çok farklıdır. Hem geri yayılım hem de PNN denetimli öğrenme algoritmalarıdır, ancak PNN, gizli katmanında ağırlıklar içermez. Bunun yerine, her bir gizli düğüm bir örnek vektörü temsil eder, örnek de bu gizli düğümün ağırlıkları olarak hareket eder.

Gerçek örnek vektörü, giriş katmanına uygulanan ağırlıklar olarak işlev görür. Son olarak, bir çıktı katmanı, giriş verilerinin sınıflandırılabildiği olası sınıfların her birini temsil eder. Burada, gizli katmanın çıkış katmanına tamamen bağlı olmadığını unutmayın. Belirli bir sınıfın örnek düğümleri yalnızca bu sınıfın çıkış düğümü ve diğer hiçbiri için bağlantı kuramaz. Örnek PNN'de, ağımızın her biri için iki eğitim örneği bulunan dört sınıfı vardır.

PNN'nin bir diğer önemli unsuru, çıkış tabakası ve giriş tabakasının uyduğu sınıfın belirlenmesidir. Bu, ‘’kazanan hepsini alır’’ metodu ile yapılır. En büyük aktivasyona sahip çıkış sınıfı düğümü kazanan sınıfı temsil eder. Sınıf düğümleri yalnızca sınıfları için örnek gizli düğümlere bağlanırken, giriş özelliği vektörü tüm örneklere bağlanır ve bu nedenle bunların aktivasyonlarını etkiler. Dolayısıyla, giriş özelliği vektörünün sınıfını belirleyen örnek vektör aktivasyonlarının toplamıdır [20].

Olasılıksal bir sinir ağı (PNN) 3 katman düğümüne sahiptir. Aşağıdaki şekil, K=2 sınıfında bir PNN mimarisini göstermektedir. Ancak farklı sınıflarda olan PNN'ler için farklı K sayısı olabilir. Solda görülen giriş katmanı "N" düğümlerini içerir; "N" giriş özellik vektörlerinin her birisi için bir tane girdi içerir. Bunlar, her bir öznitelik düğümünün gizli (veya orta) katmandaki tüm düğümlere dallanabilen, her bir gizli düğümün, tam x giriş özelliğinin vektörünü almasını sağlayan taraf dışı düğümlerdir. Gizli düğümler gruplar halinde toplanır.

K sınıfı için gruptaki her bir gizli düğüm, k'nıncı sınıftaki ilişkili özellik vektörü üzerinde merkezlenmiş bir Gauss fonksiyonuna karşılık gelir. Yani her örnek özellik vektörü için bir Gauss vardır. Bir sınıf grubundaki tüm Gauss'lular, işlevsel değerlerini bu sınıf için aynı çıkış katmanı düğümüne besler, bundan dolayı K çıkış düğümleri vardır.

2.5.3.PNN Çalışma Adımları

K sınıfı için çıkış düğümünde (burada k=1 veya 2), K sınıfı için tüm Gauss değerleri toplanır ve toplanır, böylece toplam işlev altındaki olasılık hacmi bir bütündür ve böylece toplam olasılık yoğunluğu işlevi oluşturur. Burada açıklık için özel gösterimi geçici olarak kullanıyoruz. ''P'' örnek niteliğindeki özellik vektörleri olsun. { $x^{(p)}$: p=1,…,P} ''Sınıf 1'' olarak belirtilsin ve ''Q'' örnek özellik vektörleri olsun. Bu da { $y^{(r)}$: r=1,…,R} şeklinde ''Sınıf 2'' olarak belirtilsin.

Gizli katmanda, Sınıf 1 için P düğümleri (r) ve Sınıf 2 için de ''R'' düğümleri vardır. Her bir Gaussian için ilgili Sınıf 1 ve Sınıf 2 için sırasıyla ve özellik vektörleri üzerinde bulunan denklemler herhangi bir giriş vektörü için x'dir. ''N'' ise vektörlerin boyutudur [17].

$$g_1(x)=[1/\sqrt{(2\pi\sigma^2)^N}]\exp\{-|| x - x^{(p)} ||^2/(2\sigma^2)\} \quad (1)$$

$$g_2(x)=[1/\sqrt{(2\pi\sigma^2)^N}]\exp\{-|| y - y^{(q)} ||^2/(2\sigma^2)\} \quad (2)$$

σ değerleri aynı gruptaki özellik vektörleri arasındaki ortalama mesafenin yarısı kadar olabilir veya her örnekte örneklerden en yakın diğer örnek vektörüne olan mesafenin yarısı kadar olabilir. k'nıncı çıkış düğümü, karma Gaussians veya Parzen pencereleri olarak adlandırılan k'nıncı gruptaki gizli düğümlerden alınan değerleri toplar. Bu toplamlar aşağıdaki formüllerd(square root of the sum of squared differences)e gösterildiği üzere tanımlanmıştır:

$f_1(x)=[1/\sqrt{(2\pi\sigma^2)^N}](1/P)\sum_{(p=1,P)}\exp\{-||\ x-x^{(p)}\ ||^2/(2\sigma^2)\}$ (3)

$f_2(y)=[1/\sqrt{(2\pi\sigma^2)^N}](1/Q)\sum_{(p=1,Q)}\exp\{-||\ y-y^{(p)}\ ||^2/(2\sigma^2)\}$ (4)

x herhangi bir giriş özelliği vektörüdür, sırasıyla ve , Sınıf 1 ve Sınıf 2'deki Gaussians için yayılan parametreler (standart sapmalar). N giriş vektörlerinin boyutudur. P, Sınıf 1'deki merkez vektörlerin sayısıdır ve R, Sınıf 2'deki merkezlerin sayısıdır ve Sınıf 1 ve Sınıf 2'deki merkezlerdir.

$||\ x-x^{(p)}\ ||$, x ve $x^{(p)}$ arasındaki Öklid mesafesidir. (Kare farklarının karekökü)

Herhangi bir giriş vektörü olan x, $f_1(x)$ ve $f_2(y)$ fonksiyonlarında işleme sokulur ve $f_1(x)$ ve $f_2(y)$'nin maksimum değeri sınıfa karar verir. K>2 yani 2'den fazla sınıfın olduğu durumlarda süreç 2 sınıfın olduğu durumun sürecine benzerdir.

Hiçbir iterasyon ve ağırlık hesaplaması yoktur. Toplamda çok sayıda Gaussians için, hata birikimi önemli olabilir. Böylece, her sınıftaki özellik vektörleri, bir diğerine çok yakın olan ve F'yi daha büyük yapanların incelmesiyle azaltılabilir.

Yüksek Seviye Algoritması

Aşağıda örnek özellik vektörleri verilmiştir. Her biri için ait olduğu sınıfı biliyoruz. Aşağıdakiler PPN'yi ayarlanmasında kullanılır [17].

Adım 1: Örnek vektörleri ve sınıf numaralarını dosyasından okuyun.

Adım 2: Bunları her kümenin bir vektör sınıfını içerdiği K kümelerine ayırın.

Adım 3: Her k için;

- Her örnek k vektörü için merkezlenmiş bir Gauss fonksiyonu tanımlayın
- Toplam Gauss çıkış fonksiyonunu tanımlayın

PNN tanımlandıktan sonra, vektörleri PNN'ye geri besleme yapabilir ve bunları aşağıdaki gibi sınıflandırabiliriz:

Adım 1: Giriş vektörünü okuyun ve her bir sınıftaki her Gaussian fonksiyonuna besleyin.

Adım 2: Her gizli düğüm grubu için gizli düğümlerdeki tüm Gaussian işlevsel değerlerini hesaplayın.

Adım 3: Her bir gizli düğüm grubu için, tüm Gaussian fonksiyonel değerlerini o grup için tek çıkış düğümüyle besleyin.

Adım 4: Her bir sınıf çıkış düğümünde, tüm girişleri toplayın ve sabit olarak çarpın

Adım 5: Çıkış düğümlerinde toplanan tüm işlevsel değerlerin maksimum değerini bulun.

PNN algoritması, sınıf – düğüm aktivasyonlarının hesaplanması basit bir işlemdir. Her sınıf düğümü için, örnek vektörünün ve girdi vektörünün çıktılarının (ürünlerinin) toplamı olan örnek vektör aktivasyonları toplanır. Aşağıdaki denklemde gösterilen gizli düğüm aktivasyonu, sadece iki vektörün çıktısıdır (ürünüdür).

E: Örnek vektörü F: Giriş Vektörü

h_i=$E_i F$

Çıkış aktivasyonları aşağıdaki denklemde tanımlanmıştır:

$$C_j = \frac{\sum_{i=1}^{N} e^{\frac{h_i}{\gamma 2}}}{N}$$

Burada N, bu sınıf için örnek vektörlerin toplam sayısıdır. h_i, gizli düğüm etkinleşmesidir ve bir yumuşatma faktörüdür. Yumuşatma faktörü, deneme yoluyla seçilir. Yumuşatma faktörü çok büyükse, ayrıntılar kaybolabilir, ancak yumuşatma faktörü çok küçükse, sınıflandırıcı iyi genellemeyebilir [20].

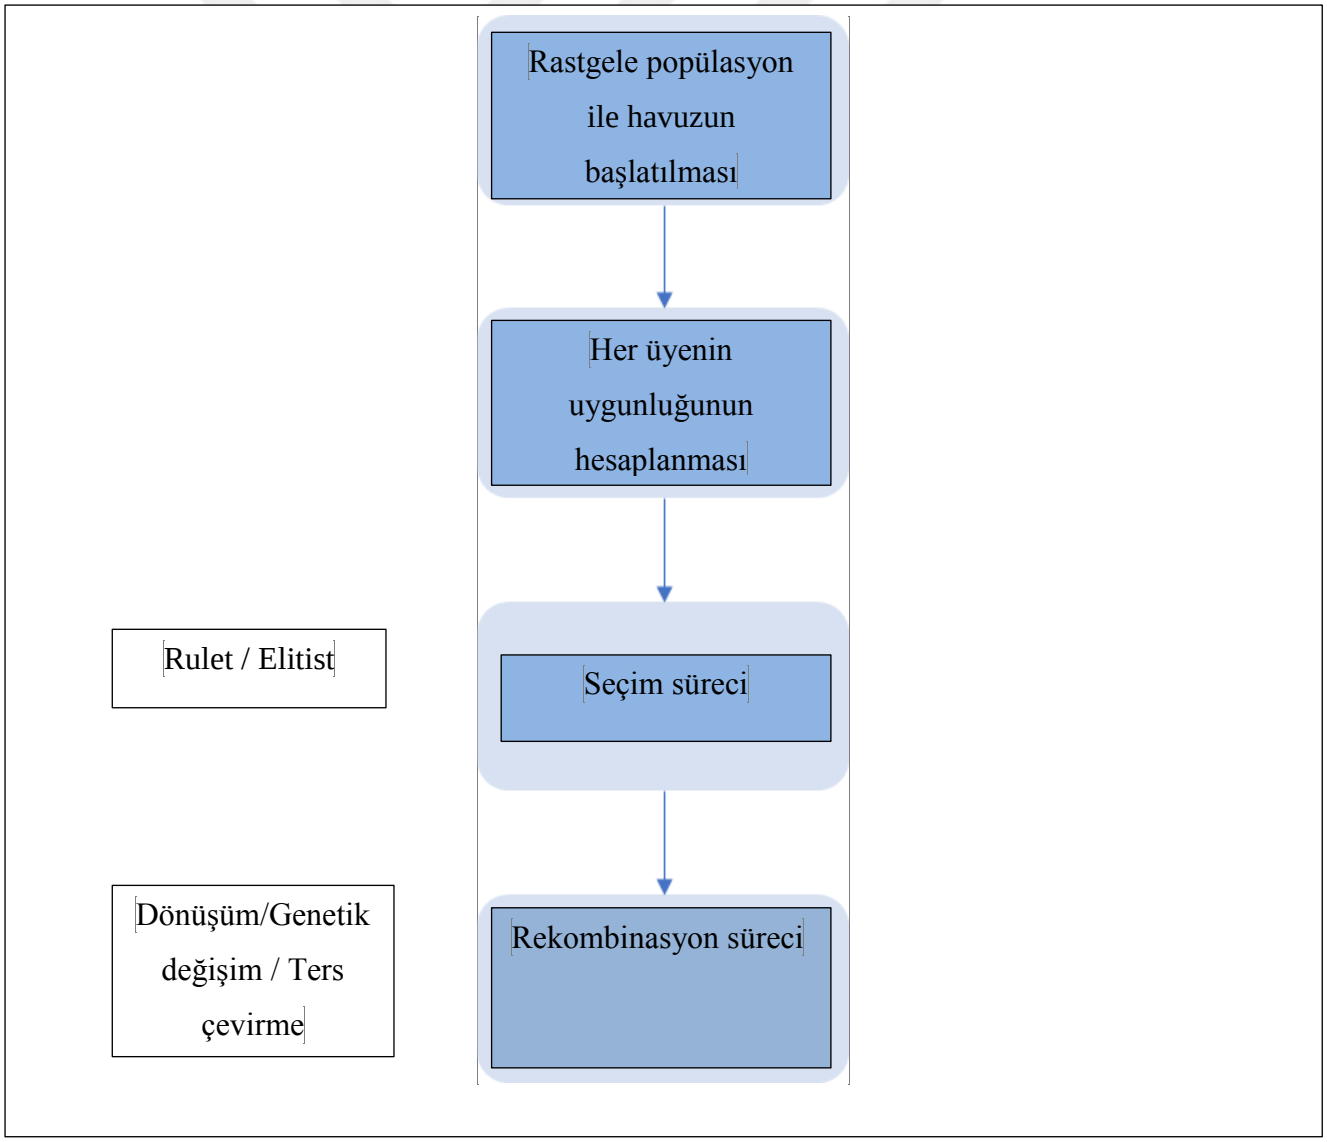
2.6. GENETİK ALGORİTMA

Genetik algoritma, gerçekte tek bir algoritma değil, bir dizi farklı sorun alanlarındaki çeşitli sorunları çözmek için kullanılabilecek bir dizi algoritma ve tekniktir. Örneğin, birçoğu genetik algoritmaları sayısal optimizasyon için bir teknik olarak düşünür, ancak genetik algoritmalar çok daha fazlası için kullanılabilir.

Genetik algoritmanın geniş kapsamlı problemleri çözme yeteneği, çözümün popülasyonda temsil edildiği yöntemden türetilmiştir. Genetik algoritma pek çok probleme uygulanabilir ve öncelikle geliştiricinin bir çözümü verimli bir şekilde temsil etme yeteneği ile sınırlıdır.

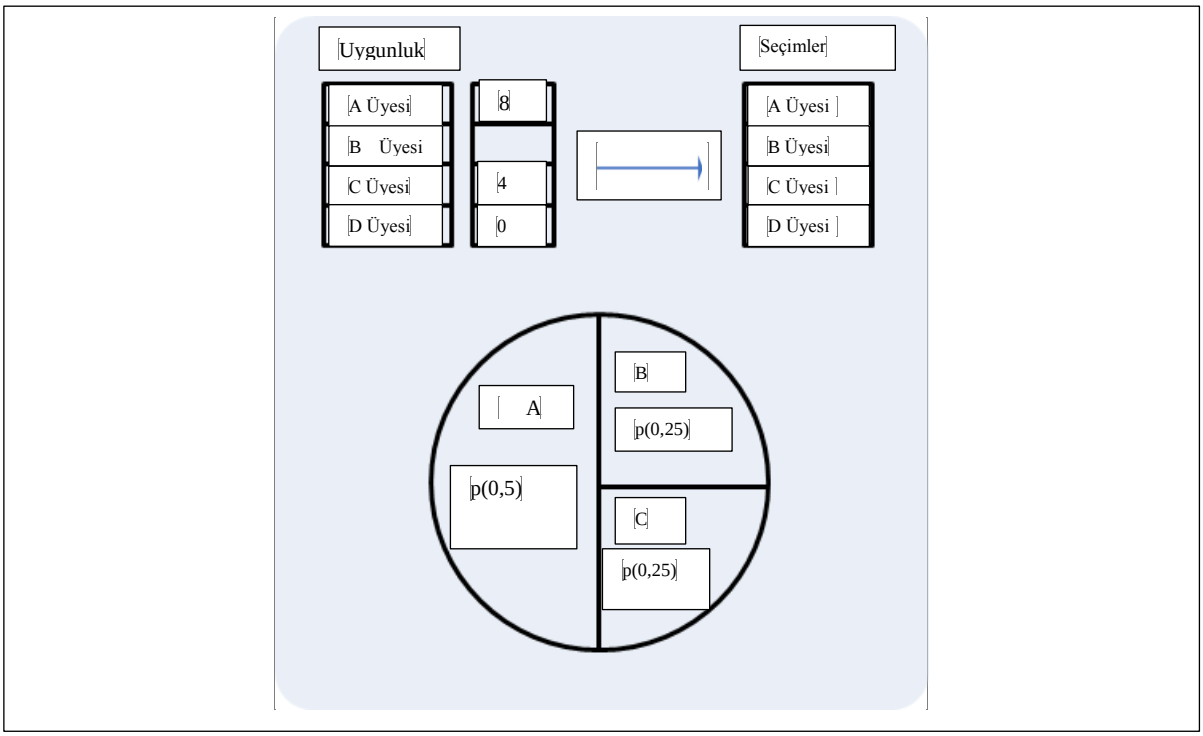
Genetik algoritma, bir dizi farklı sorunlara çözüm geliştirmek için kullanılabilecek bir algoritma tarifleri koleksiyonudur. Biz buna bir reçete diyoruz, çünkü kullanılabilecek genetik algoritmanın çok sayıda varyasyonu var. Bu varyasyonlar tipik olarak çözülecek problem türüne göre seçilir.

Genetik algoritma, popülasyona dayalı bir teknik olarak adlandırılır, çünkü tek bir potansiyel çözüm üzerinde çalışmak yerine, potansiyel bir çözüm popülasyonu kullanır. Nüfus arttıkça, nüfusun üyelerinin çeşitliliği de artar ve nüfus tarafından araştırılan alan o kadar büyük olur.



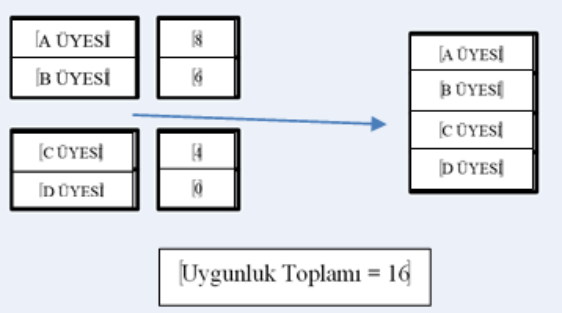
Şekil 2.7: Genetik Algoritmanın Basit Akışı [20]

Daha sonra, popülasyonun üyeleri, bazı algoritmalara göre seçilir. En basit iki yaklaşım, rulet çarkı seçimi ve elitist seçimidir (bkz. Şekil 2.8. ve Şekil 2.9.). Rulet tekerleği seçimi, popülasyonun üyelerini uygunluğu ile orantılı olarak seçen bir olasılık algoritmasıdır (üye ne kadar yüksekse, o kadar büyük olasılıkla seçilir). Elitist seçiminde, nüfusun daha yüksek uygunluk düzeyi olan üyeleri seçilir ve daha az uygun üyelerin elenmesi sağlanır.



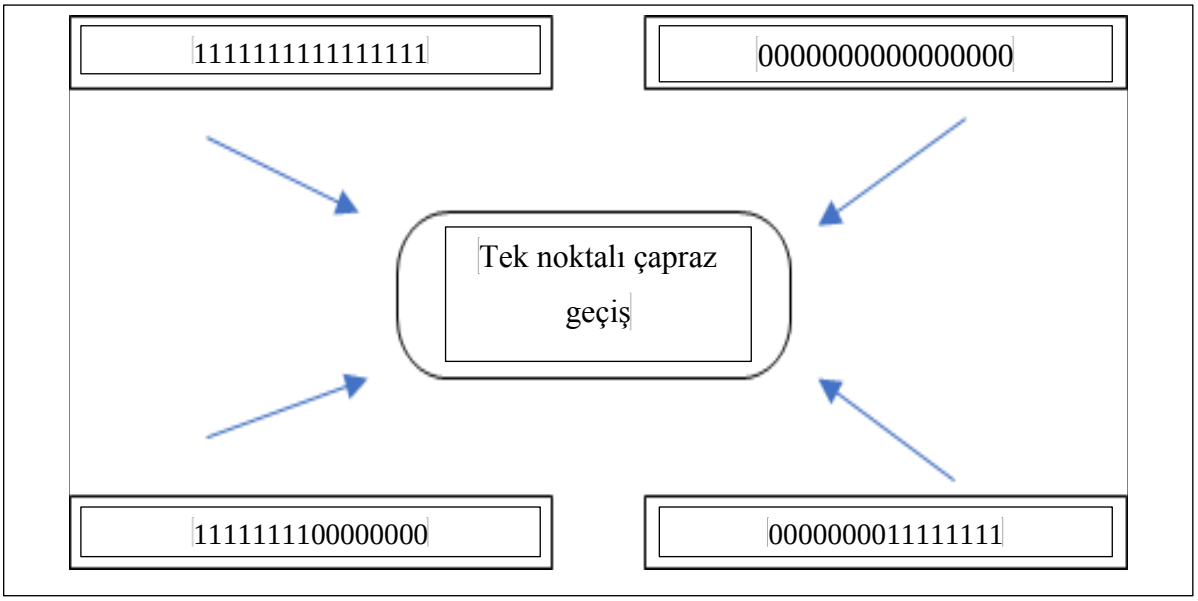
Şekil 2.8: Rulet Tekeri Seçim Modeli [20]

Rulet tekerleği seçimini kullanarak (Şekil 2.9'daki verileri kullanarak), olası bir seçim sonucu Üye A'nın ikisi seçilecektir ve C ve D'den birer tane seçilmesidir. Bir sonraki popülasyona daha fazla kromozom yayma ayrıcalığına sahiptir. Bu modeldeki elitist seçimi (Şekil 2.10'da gösterilmiştir), nüfusun üyelerinin %50'sini (en uygun) alır ve bunları bir sonraki jenerasyona dağıtır [20].



Şekil 2.9: Elitist Seçim – Top %50 Modeli [20]

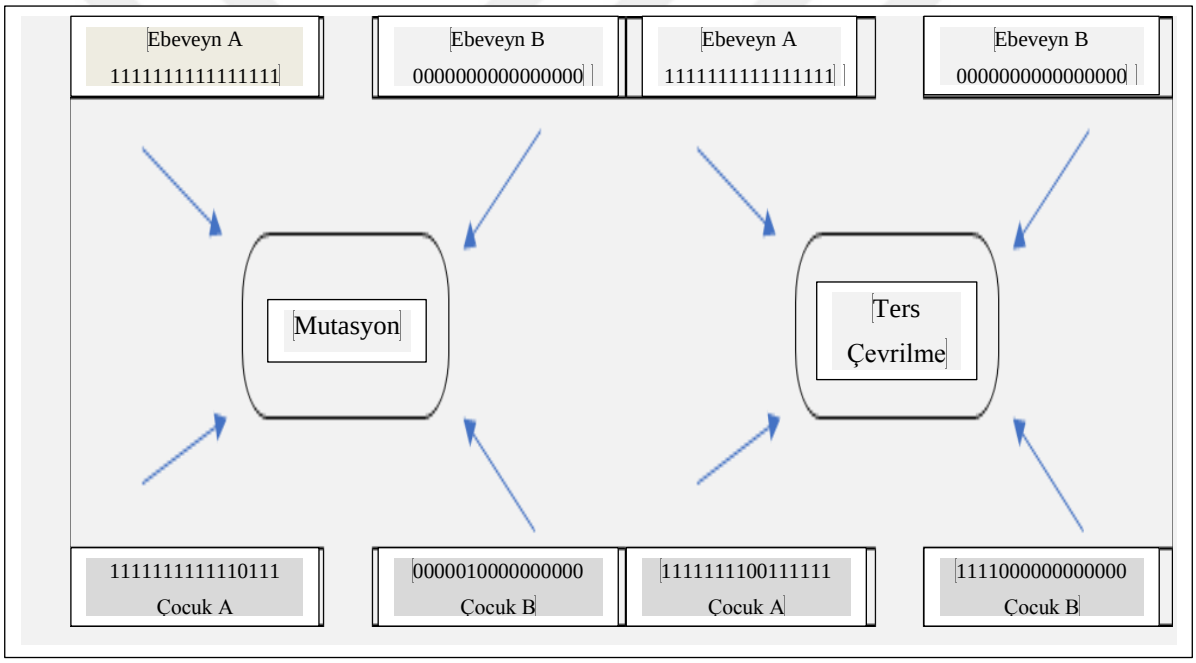
Şimdi genetik algoritma akışımıza dönersek, seçim sürecinden, genetik materyallerini bir sonraki popülasyona yayma hakkına sahip birçok üyeye sahibiz. Bir sonraki adım, bu üyelerin malzemelerini gelecek neslin üyelerini oluşturmak için yeniden birleştirmektir.



Şekil 2.10: Çaprazlama Operatörlerini Genetik Rekombinasyonda Gösterilmesi [20]

Yaygın olarak, ebeveynler (seçim sürecinden) yayılmalarına izin verilen bireyler kümesinden iki defa seçilir. İki ebeveyn göz önüne alındığında, yeni nesilde iki çocuk yaratılır ve

rekombinasyon sürecinin (genetik operatörün meydana gelebileceği belirli bir olasılıkla) nezaketsiz sayılır. Şekil 2.11 ve Şekil 2.12 genetik operatörlerin dördünü göstermektedir.



Şekil 2.11: Mutasyon ve İnversiyon Genetik Operatörlerinin Gösterilmesi [20]

Bir başka açıdan bakacak olursak, sinirsel ağlar gibi, genetik algoritmalar da bir biyolojik metafor üzerine kuruludur: Öğrenmeyi, değişen aday problem çözümlerinin bir popülasyonu arasında bir rekabet olarak görürler. Bir "uygunluk" işlevi, her çözümün yeni nesil çözümlere katkıda bulunup bulunmayacağına karar vermesini değerlendirir. Daha sonra, genetik reprodüksiyonda gen transferine benzer operasyonlar yoluyla, algoritma yeni bir aday çözüm popülasyonu yaratır.

P(t) aday çözümlerin bir popülasyonunu temsil ediyor olsun. x_i^t, t anındaki çözüm olsun [20].

P(t) = $\{x_1^t, x_2^t, ..., x_n^t\}$

Verilen bilgiler ışığında, genetik algoritmanın genel bir formunu sunalım:

begin

set time t:= 0;

initialize the population P(t);

while the termination condition is not met do

begin

evaluate fitness of each member of the population P(t);

select members from population P(t) based on fitness;

produce the offspring of these pairs using genetic operators;

replace, based on fitness, candidates of P(t), with these offspring;

set time t := t +1

end

end

Bu algoritma genetik öğrenmenin temel çerçevesini ifade eder; Algoritmanın belirli uygulamaları bu çerçeveyi farklı şekillerde başlatır. Daha sofistike yaklaşımlar, bir popülasyonu uygunluk yoluyla çağırabilir ve daha sonra eliminasyon olasılığının uygunluğunun tersi bir işlevi olduğu her üye ile ortadan kaldırılması için bir olasılık ölçüsünü ilişkilendirebilir. Daha sonra yedek algoritma, bu ölçüyü ortadan kaldırmak için adayları seçmede bir faktör olarak kullanır [20].

Her ne kadar eleme olasılığı topluluğun en güçlü üyeleri için çok düşük olsa da, en iyi bireylerin bile ortadan kaldırılması ihtimali vardır. Bu programın avantajı, genel zindeliği zayıf olan ancak daha güçlü bir çözüme katkıda bulunabilecek bazı bileşenleri içeren bazı

bireyleri kurtarabilmesidir. Bu yedek algoritmanın Monte Carlo, uygunluk orantılı seçim ve rulet çarkı dahil birçok ismi vardır.

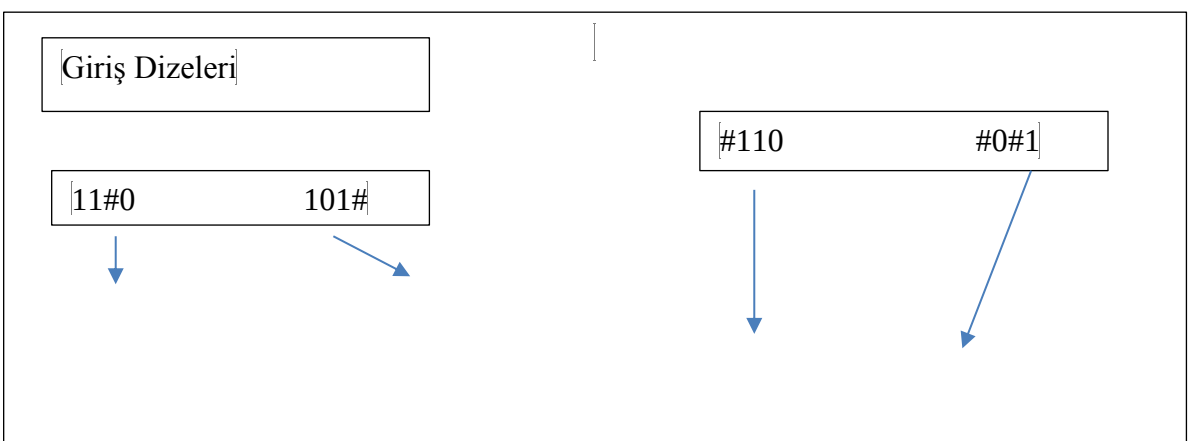
Genetik algoritma P (0) 'ı bir aday desen popülasyonuna başlatır. Tipik olarak, ilk popülasyonlar rastgele seçilir. Aday çözümlerin değerlendirilmesi bir uygunluk fonksiyonunu gerektirir. f(x_i^t) , adayın uygunluğunu t zamanında döndürür. Bir adayın uygunluğunun ortak bir ölçüsü, bir dizi örnek üzerinde test eder ve doğru sınıflandırmaların yüzdesini döndürür. Aşağıdaki gibi bir uygunluk fonksiyonu kullanarak, her aday çözüme değer atar:

f(x_i^t)/m(P, t)

Bu fonksiyonda m(P,t), popülasyonun tüm elemanları içerisinde ortalama uygunluğu ifade eder. Uygunluk ölçütünün zaman periyotları arasında değişmesi de yaygın bir durumdur. Dolayısıyla uygunluk fonksiyonu genel problem çözümünün veya f(x_i^t) 'nin bir fonksiyonu olabilir.

Her aday değerlendirildikten sonra, algoritma rekombinasyon için çiftleri seçer. Rekombinasyon, temel bileşenleri birleştiren yeni çözümler üretmek için genetik operatörleri kullanır. Doğadaki evrimde olduğu gibi, adayın zindeliği, yeniden üretme olasılığı daha yüksek olarak değerlendirilen adaylarla yeniden üretme boyutunu belirler. Daha önce de belirtildiği gibi, seçim genellikle olasılıksaldır, zayıf üyelere daha küçük bir üreme olasılığı verilir, ancak tamamen ortadan kaldırılmaz. Bazı daha az uygun adayların hayatta kalması önemlidir, çünkü bir çözümün bazı temel bileşenlerini, örneğin biraz desenin bir kısmını içerebilirler ve bu bileşeni çıkartabilirler.

Ebeveynlerinin özelliklerine sahip yavrular üreten bir dizi genetik operatör vardır; bunların en yaygın olanı geçiştir. Çaprazlama işlemi iki aday çözüm alır ve iki yeni aday üretmek için bileşenleri değiştirerek onları böler.





Şekil 2.12: Dizelerin Genetik Algoritma Yapısı Kullanılarak Çaprazlanması [20]

Örneğin, hedef sınıfın 1 ile başlayan ve sonlanan tüm dizelerin kümesi olduğunu varsayalım. Şekil 2.13'deki her iki dizge de bu görevde nispeten iyi bir performans gösterecektir. Bununla birlikte, ilk çocuk her iki ebeveynden de daha iyi olurdu: yanlış pozitiflere sahip olmayacaktı ve aslında çözelti sınıfında olan daha az ipi tanımakta başarısız olacaktı. Ayrıca, kardeşinin ebeveynden daha kötü olduğunu ve muhtemelen önümüzdeki birkaç nesilde ortadan kaldırılacağını da unutulmamalıdır.

Mutasyon, başka önemli bir genetik operatördür. Mutasyon tek bir aday alır ve onun bazı yönlerini rastgele değiştirir. Örneğin, mutasyon rasgele desende bir bit seçebilir ve bunu değiştirebilir, 1'i 0 veya # olarak değiştirebilir. Mutasyon, başlangıçtaki popülasyonun bir çözeltinin temel bir bileşenini dışlayabilmesi açısından önemlidir. Örneğimizde, ilk popülasyonun hiçbir üyesi, birinci pozisyonda bir 1'e sahip değilse, o zaman çaprazlama yapar, çünkü çocuğun ilk dört bitini oluşturan ebeveynin ilk dört bitini korur, bu da bir yavru üretemez. Bu bitlerin değerlerini değiştirmek için mutasyon gereklidir.

Genetik algoritma, bazı eşik değerlerini aşan bir veya daha fazla aday çözeltisine sahip olmak gibi bazı sonlandırma gerekliliklerinin karşılanmasına kadar devam eder.

2.7. LİTERATÜR ÇALIŞMASI

Hegde ve Rokseth (2020), mühendislik risk değerlendirmesine yardımcı olmak için makine öğrenme yöntemlerini kullanan yayınların yapılandırılmış bir incelemesini sunmuşlardır. Bu inceleme sonucunda, risk değerlendirmesinde makine öğrenmesinin kullanımına odaklanan ilgili literatürün yapılandırılmış bir incelemesini yaparak bilgi açığını kapattığını belirtmişlerdir [21].

Changwei ve diğ. (2019), esas olarak demiryolu inşaatı projesi boyunca Asya ve Avrupa ülkelerini analiz etmekte, demiryolu inşaatı projesi risk değerlendirme sistemi kurmuşlar ve çeşitli risk faktörlerini sentezlemişlerdir. İkinci olarak, iki kıta arasındaki farklı politik,

ekonomik ve kültürel unsurlar nedeniyle farklı eğitim algoritmaları kullanarak iki bağımsız sinir ağı modeli kurmuşlardır [22].

Ivarsson ve Stachowicz (2019) uyarılma olaylarını tahmin etme ve sınıflandırma süreçlerinin sertifikalı teknoloji uzmanlarının manuel olarak yaptıklarını, bir destek vektörü makinesi ile birlikte yaparak, yapay sinir ağlarına kıyasla nasıl bir performans gösterdiğini araştırmışlardır. Uzmanlar tarafından yapılan işlemler ile destek vektörü makinesi kullanarak yapılan iki modelin sonuçları arasındaki farkın oldukça az olduğunu tespit etmişlerdir [23].

Martinez ve Rodriguez (2017), yapay zekâ metodunu, proje başarısı tahmini veya kritik başarı faktörü belirleme aracı olarak kullanan makalelerin literatür taramasını yapmışlardır [24] Chiroma ve diğ. (2017), sinir ağlarının optimizasyonu üzerine yapılan araştırmaların genetik algoritma araştırması yoluyla son teknoloji incelemesini sunan bir çalışma yürütmüşlerdir [25].

Sheikh ve Mehrani (2016), proje yöneticilerine yüksek teknoloji projelerini değerlendirmek için güvenilir bir çerçeve sağlamak için, genetik algoritma ve yapay sinir ağlarını birleştirerek yüksek teknolojili projelerin risk değerlerini tahmin etmelerini öngören bir model ortaya çıkarmışlardır [26].

Serpella ve diğ. (2014) yazmış oldukları makalede, inşaat projelerinde risk yönetimi problemlerini bilgiye dayalı bir yaklaşım kullanarak ele almakta ve risk yönetim fonksiyonunun modellenmesini, değerlendirilmesini ve en iyi uygulamalar modelinin kullanılabilirliğini içeren üç katlı bir düzenlemeye dayanan bir metodoloji ortaya koymuşlardır. Ortaya konulan bu yaklaşımın uygulanması durumunda, müşterilerin ve yüklenicilerin en iyi uygulamalara dayalı olarak bir projenin risk yönetim fonksiyonunu geliştirmelerine ve ayrıca bu fonksiyonunun performansını iyileştirmelerine katkıda bulunacakları sonucuna ulaşmalarını beklediklerini belirtmişlerdir [27].

Yu ve Xu (2014) kısa vadeli gaz yükü tahmini için geliştirilmiş geri yayılım sinir ağını temel alan uygun bir kombinasyon yaklaşımı önermişlerdir ve bu yapay sinir ağı genetik algoritma ile optimize edilmiştir [28]. Unal ve diğ. (2014) makinelerde hata tahmini için yapay sinir ağı tabanlı hata tahmin algoritması geliştirmişlerdir. Geliştirdikleri bu algoritmayı deneysel testler ile doğrulamışlardır [29].

Feng ve diğ. (2014) bilgi sistemlerinde risk faktörleri arasındaki nedensel ilişkileri tanımlamak ve güvenlik açığı yayılımının karmaşıklığını ve belirsizliğini analiz etmek için bir güvenlik risk analiz modeli önermişlerdir [30].

Karegowda ve diğ. (2011) yapay sinir ağlarını ve genetik algoritmaları kullanarak hibrid bir model oluşturmuşlar ve bu modeli tıbbi verilerin tahmininde kullanmışlardır [31]. Ding ve diğ. (2011) geri yayılım sinir ağının dezavantajlarının üstesinden gelmek için genetik algoritmaya dayalı bir geri yayılım algoritmasını optimize etmek için bir yöntem geliştirmişlerdir [32].

Jin ve Zhang (2011) işlem maliyet ekonomisinden faydalanan kamu – özel ortaklık projelerinde risk dağılımının karar verme sürecini modellemek için yapay sinir ağı modellerini kurmayı, doğrulamayı ve test etmeyi amaçlamışlardır [33].

Wang ve diğ. (2010) süper kritik CO2 güç döngüsünün optimum termodinamik parametrelerinin, değişken atık ısı koşulları altında yapay sinir ağı kullanılarak iyi bir doğrulukla tahmin edilebileceğini göstermişlerdir [34].

Magnier ve Haghighat (2010), çalışmalarında sunmuş oldukları GAINN yaklaşımını ilk önce bina davranışını karakterize etmek için simülasyon tabanlı yapay sinir ağı kullanmışlar, daha sonra bu yapay sinir ağını optimize etmek için çok amaçlı genetik algoritma ile birleştirmişlerdir [35].

Khashman (2010), geri yayılım öğrenme algoritmasına dayanan, denetimli sinir ağı modellerini kullanan bir kredi riski değerlendirme sistemi ortaya çıkarmıştır [36]. Sedki ve diğ. (2009) genetik algoritmanın yağış tahmini için sinir ağını geliştirmişler ve geliştirilen bu metodu Fas'ta yarı kurak bir iklimde bulunan havzada yağışları ve yağışın miktarını tahmin etmede uygulamışlardır [37].

Zhou ve diğ. (2009) ürün tasarımında malzeme özellikleri ve seçiminin önemine değinmişlerdir. Daha sürdürülebilir ürünler elde etmek için sadece teknik ve ekonomik faktörleri değil aynı zamanda çevresel faktörleri de göz önünde bulundurmuşlardır. Bu sebeple çevresel etkiler yaşam döngüsü değerlendirme yöntemi ile hesaplamalar yapmışlardır. Malzeme seçiminin optimize edilmesi için yapay sinir ağlarını genetik algoritmalar ile

entegrasyonu önerisini getirmişler ve sürdürülebilir ürünler geliştirmek için geliştirdikleri sistemin uygun malzemeleri seçebileceğini bir örnekle doğrulamışlardır [38].

Schieg (2006) risk yönetiminin benimsenerek inşaat projelerinde tasarrufun gerçekleştirilebileceğini öner sürmüş ve risk yönetim sürecini altı süreç adımında analiz etmiştir. Yaptığı çalışmanın sonucunda kullanılan risk yönetimi sayesinde, projenin genel riskini bireysel risklere bölmüş bu riskler için önlemler alınabileceğini belirtmiştir. Ancak, önlemler alınsa dahi her projede risklerin devam ettiğini ve bu risklerin alınıp alınmadığı ve risklerin ortaya çıkması durumunda oluşabilecek durumlarda stratejik kararlar alınarak yönetilmesi gerektiğini belirtmiştir [39].

Kalogirou (2004) yapay sinir ağları ve genetik algoritmalar gibi yapay zekâ yöntemlerini, ekonomik faydalarını en üst seviyeye çıkarmak için güneş enerjisi sistemini optimize etmeyi amaçlamıştır. Kurulan sistem, bir bilgisayar programı ve tipik bir meteorolojik yıl dosyasına dahil edilen Kıbrıs'ın iklim koşulları kullanılarak modellenmiştir. Kalogirou'nun kurmuş olduğu metodolojiden elde edilen optimum çözümler, geleneksel deneme-yanılma yöntemiyle elde edilen çözümlerle karşılaştırıldığında, sırasıyla sübvanse edilmiş ve sübvanse edilmemiş yakıt fiyatları kullanıldığında, %4,9 ve %3,1 oranında yaşam ömrü tasarrufu sağladığı sonucuna ulaşılmış ve mühendislerin optimum çözümü bulması için gereken süreyi büyük ölçüde azaltmıştır [40].

Al-Balushi ve diğ. (2003) yapay sinir ağları ve destek vektör makineleri olmaz üzere iki farklı sınıflandırıcı kullanarak yatak arıza tespitinin performansını karşılaştırmak için bir çalışma sunmuşlardır. Elde ettikleri sonuçlar ise özeliklerin ve sınıflandırıcıların makine durumunun tespitinde etkinliğini göstermiştir [41].

Baloi ve Price (2003) "İnşaat Maliyet Performansını Etkileyen Küresel Risk Faktörlerinin Modellenmesi" isimli çalışmalarında küresel risk faktörleri modellemesi, değerlendirilmesi ve risk yönetimi ile ilgili temel konuları tartışmışlardır. Belirsizliği ele almak için farklı teknikler değerlendirmişler ve elde ettikleri ön sonuçlar, inşaat maliyeti performansını etkileyen küresel risk faktörlerinin bulanık küme teorisi ve karar destek sistemi teknolojileri kullanılarak başarılı bir şekilde modellenebileceğini, değerlendirilebileceği ve yönetilebileceği sonucuna ulaşmışlardır [42].

Kim ve Han (2000) yaptıkları çalışmada hisse senedi fiyat endeksini tahmin etmek için ayrıklaştırma ve yapay sinir ağları için bağlantı ağırlıklarının belirlenmesi için genetik algoritma yaklaşımını önermişlerdir. Yaptıkları bu çalışmada, genetik algoritma sadece öğrenme algoritmasını geliştirmek için değil, aynı zamanda özellik alanındaki karmaşıklığı azaltmak için de kullanılmıştır. Genetik algoritmadan yararlanılarak geliştirilen ağırlıklar, gradyan iniş algoritmasının iyi bilinen sınırlamalarını azalmış ayrıca, global olarak aranan özellik ayrıklaştırma özelliği, özellik alanının boyutsallığını azaltmış ve alakasız faktörleri ortadan kaldırmıştır. Deneysel sonuçlar, özellikle ayrıklaştırıma modeline genetik algoritma yaklaşımının geleneksel modellere göre daha iyi performans gösterdiği sonucuna ulaşmışlardır [43].

Tah ve Carr (2000) proje risk yönetimi sürecinde genel bir yaklaşımın eksikliğinden yakınmışlardır. Yapmış oldukları çalışmada inşaat risk yönetimine daha iyi bir yaklaşım oluşturmayı amaçlamışlardır. Yapmış oldukları çalışma sonucunda bir entegrasyon tanım dili geliştirmişler, hiyerarşik risk dağılım yapısına dayanan riskler ile eylemlerin taksonomisine dayanan riskleri ve düzeltici eylemleri tanımlamak için ortak bir dil sunmuşlardır. Sunmuş oldukları bu dilin daha sonra genel kataloglarda depolanabilecek genel risk ve işlem terimlerini tanımlamak için çeşitli taksonlar ve yapılar kullandığını belirtmişlerdir [44].

3.MALZEME VE YÖNTEM

3.1. VERİ SETİ

Veri seti, Doğa HSE Group isimli ulusal alanda iş sağlığı ve güvenliği konusunda çalışmalar yürüten bir şirketten alınmıştır. Farklı maliyet ölçeklerine sahip 4 ayrı konut inşaatı şantiyesinden riskli faaliyetler, bu faaliyetlerin yapılması sırasında oluşabilecek riskler ile bu faaliyetlerin maliyet verileri, her şantiyenin iş güvenliği uzmanları ve mühendisleri ile birlikte görüşülerek belirlenmiştir.

Tablo 3.1: Veri Setinin Örnek Bir Kısmı

Faaliyet	Riskler	Risk Kodu	Aktivite Maliyeti	Risk Olasılık	Risk Maliyet	Süreel Etki	Risk Skoru	Risk Sınıfı(Önceki)	Risk Olasılık	Risk Maliyet	Süreel Etki	Risk Skoru	Önlem Maliyeti	Risk Sınıfı (sonraki)
Temel Atma	Yeraltı jeolojisi jeoteknik koşulları	A	89060	5	4	2	15	S	3	4	1	8	9300	S
Temel Atma	Yanlış Tasarım	B	89060	5	4	2	15	S	3	4	1	8	2800	S
Temel Atma	Ekipman arızası	C	89060	7	8	8	56	K	5	4	4	20	4000	S
Temel Atma	İnşaat mesleki kazaları	D	89060	5	8	1	23	S	3	4	1	8	8200	S
Kaba İnşaat	Tasarım planlarının yürütmeyle uyumlu olmaması.	E	153600	5	4	4	20	S	3	4	2	9	5200	S
Kaba İnşaat	Uygunsuz zaman tahsisi	F	153600	5	4	4	20	S	3	2	1	5	6000	B
Kaba İnşaat	Sahada malzeme hırsızlığı	G	153600	7	4	2	21	S	3	1	2	5	14000	B
Kaba İnşaat	İnşaat mesleki kazaları	D	153600	9	8	2	45	K	5	4	2	15	16000	S
Elektrik ve Sıhhi Tesisat İşleri	Tedarik edilen malzemelerin kalitesinin düşük olması	H	193500	9	4	2	27	K	4	1	2	6	32000	S
Elektrik ve Sıhhi Tesisat İşleri	Elektrik yangınlarının meydana gelmesi	J	193500	5	4	2	15	S	3	4	2	9	6500	S
Elektrik ve Sıhhi Tesisat İşleri	Koordine olmayan tasarım (yapısal, mekanik, elektrik	K	193500	7	4	4	28	K	5	4	4	20	8200	S

	vb.)													

Tablo 3.1: Veri Setinin Örnek Bir Kısmı (devamı)

Elektrik ve Sıhhi Tesisat İşleri	İnşaat mesleki kazaları	D	193500	5	4	1	13	S	3	2	1	5	4000	B
Çatı İşleri	Gerekli teknik becerilerin mevcut olmaması	L	93000	5	4	4	20	S	3	2	4	9	6500	S
Çatı İşleri	Malzeme ve ekipman seçimi	M	93000	5	4	2	15	S	1	2	2	2	25000	B
Çatı İşleri	Ekipmanda hasar meydana gelmesi	N	93000	7	4	2	21	S	7	1	2	11	2500	S
Çatı İşleri	İnşaat mesleki kazaları	D	93000	9	8	2	45	K	5	4	2	15	7200	S
Fayans, Duvar ve Döşeme İşleri	Uygulama sırasında tasarımlarda birçok değişiklik yapılması	O	85680	5	4	2	15	S	3	2	1	5	4150	B
Fayans, Duvar ve Döşeme İşleri	Fiyatlandırma projelerinde rekabet.	P	85680	3	8	1	14	S	3	2	1	5	3300	B
Fayans, Duvar ve Döşeme İşleri	Eğitimli insan gücünün yokluğu	R	85680	9	4	2	27	K	3	2	1	5	15650	B
Fayans, Duvar ve Döşeme İşleri	İnşaat mesleki kazaları	D	85680	3	2	1	5	B	1	1	0,5	1	3100	B
Dış Sıva ve Cephe Kaplama İşleri	Malzeme ve ekipman seçimi	M	266000	7	8	2	35	K	3	2	2	6	27000	S
Dış Sıva ve Cephe Kaplama İşleri	Gerçek miktarların sözleşme miktarlarından farklı olması	S	266000	7	4	1	18	S	3	4	1	8	3000	S
Dış Sıva ve Cephe Kaplama İşleri	Malzemelerin işçiler tarafından israfı	T	266000	9	4	2	27	K	5	4	2	15	2500	S
Dış Sıva ve Cephe Kaplama İşleri	İnşaat mesleki kazaları	D	266000	9	4	2	27	K	3	1	2	5	5000	B

Tablo 3.1 bir şantiyede en çok karşılaşılan riskli faaliyetleri, bu faaliyetlerin kodlarını, faaliyetlerin maliyetini, önlem alınmadan önceki risk skorunu ve önlem alındıktan sonraki risk skoru verilerini içermektedir. Belirlenen veri setleri tabloya aktarıldıktan sonra, risk matrisi oluşturuldu her bir veri için risk analizi yapıldı. Bir inşaat sırasında meydana gelebilecek riskleri etkin bir şekilde işleme koyabilmek adına riskler kodlanmıştır. Riskler ve kodları Tablo 3.2'de gösterilmiştir.

Tablo 3.2 Riskler ve Risk Kodları

Riskler	**Risk Kodu**
Yeraltı Jeolojisi Jeoteknik Koşulları	1
Yanlış Tasarım	2
Ekipman Arızası	3
İnşaat Mesleki Kazaları	4
Tasarım ve Planların Yürütmeyle Uygun Olmaması	5
Uygunsuz Zaman Tahsisi	6
Sahada Malzeme Hırsızlığı	7
Tedarik Edilen Malzemelerin Kalitesinin Düşük Olması	8
Elektrik Yangınlarının Meydana Gelmesi	9
Koordine Olmayan Tasarım (Yapısal, mekanik, elektrik vb.)	10
Gerekli Teknik Becerilerin Mevcut Olmaması	11
Malzeme ve Ekipman Seçimi	12
Ekipmanda Hasar Meydana Gelmesi	13
Uygulama Sırasında Tasarımlarda Birçok Değişiklik Yapılması	14
Fiyatlandırma Projelerinde Rekabet	15
Nitelikli İş Gücünün Yokluğu	16
Malzeme ve Ekipman Seçimi	17
Gerçek Miktarların Sözleşme Miktarlarından Farklı Olması	18
Malzemelerin İşçiler Tarafından İsrafı	19

3.2.RİSK SKORUNUN HESAPLANMASI

Risk skoru PMI PMBOK'a (2008) göre hesaplanmıştır. Risk skoru hesaplanırken aşağıda belirtilen adımlara göre hesaplama yapılmıştır:

- Risk puanlama
- Olasılık ve etki puanlama tablosuna girilen puanlar
- Risk olasılığı
- Puanı olan her risk faaliyetinin etkilerinin kontrol edilmesi

Risk hesaplamaları sonucunda en yüksek etki değeri seçilir ve riskin genel etkisi tüm etkilerin en yüksek seviyesine ayarlanır. Genel etki daha sonra olasılık ve etki puanlama kılavuzundan bakılarak risk puanı seçme olasılığı ile birleştirilmiştir.

Etkilerin ortalaması seçeneği; ortalama etki seçeneği kullanıldığında her bir risk etkisine sayısal bir değer verilir.

- İhmal Edilebilir: 0
- VL (Very Low): 1 (çok düşük olasılık)
- L (Low): 2 (düşük olasılık)
- M (Medium): 3 (orta düzey olasılık)
- H (High): 4 (yüksek olasılık)
- VH (Very High): 5 (çok yüksek olasılık)

Yukarıda belirtilen 0,1,2,3,4,5 gibi değerlerin ortalaması genel etkiyi belirlemek için kullanılır. Örneğin: Bir risk kaydı 3 etki tipine ve 5 etki değerine (VL, L, M, H ve VH) sahiptir. Bir risk aşağıdaki gibi değerlendirilir:

Maliyet Etkisi: L

Programlama Etkisi: M

Performans Etkisi: VH

L=2, M=3 ve VH=5 değerlerine sahip olduklarını yukarıda belirtmiştik. O halde ortalama sayısal etkisi;

Ortalama Sayısal Etki: (2+3+5) / 3=3,33 değerine sahip olur. 3,33 değeri 3,5 değerinden küçük olduğu için ortalama sayısal etki 3 değerine yuvarlanır. Bu değer ise M değerinin karşılığıdır. Böylece genel etki daha sonra olasılık ve etki puanlamasına göre risk puanını seçmek için olasılık ile birleştirilir. Örneğin; yukarıdaki riskin olasılığı M ise, risk puanı 10 olacaktır (aşağıda yer alan Tablo 3.3'e dayanarak).

Tablo 3.3: Olasılık ve Etki Skoru Matrisi

	Etkiler				
	Çok Düşük	**Düşük**	**Orta**	**Yüksek**	**Çok Yüksek**
Çok Yüksek %	6	12	18	36	72
Yüksek %	4	7	14	28	56
Orta %	3	5	10	20	40
Düşük %	2	3	6	12	24
Çok Düşük %	1	1	2	4	8

Tablo 3.4: Aralık Ölçeği

	Renk	**Skor**
Yüksek		**>23**
Orta		**>5**
Düşük		**<=5**

Bir riskin, skoruna göre hangi risk bölgesinde yer alacağı ve bu risk bölgesinin renkleri Tablo 3.4'de gösterilmiştir. Örneğin; risk skoru 24 ise Tablo 3.4'e dayanarak bu riskin tehlikeli risk sınıfında (kırmızı bölgede) olacağı söylenebilir.

Özel etki ortalaması seçeneği; özel etki ortalaması seçeneği kullanılırken her etki türü, olasılık ve etki puanlama tablosundan bir puan değeri alır. Risk puanı ise bu puanların ortalamasıdır. Özel etki seçeneği seçildikten sonra genel etki, olasılık ve etki puanlama tablosundaki risk olasılığını ifade eden satırı seçerek ve o satırda, risk puanına en yakın hücreyi seçerek belirlenir.

Örneğin, bir riskin değerleri aşağıdaki gibi olsun:

Olasılık = H, Maliyet = L, Program = M ve Performans = VH.

Olasılık ve etki puanlama tablosuna bakılarak, H ve L için maliyet etkisinin puanın 7 olduğu belirlenir. Yine olasılık ve etki puanlama tablosuna bakılarak, H ve M için program etkisinin puanının 14 olduğu görülür. Olasılık ve etki puanlama tablosunda H ve VH için performans etkisinin puanının 56 olduğu görülür. Ortalama etki puanı = (7 + 14 + 56) /3 = 26 olarak hesaplanır. Genel etki ise M değerine karşılık gelir çünkü M değeri 14 ile 27 arasındaki değerleri kapsar.

Bu çalışmada genetik algoritma ve yapay sinir ağları yöntemleri entegre edilerek bir risk yönetim modeli geliştirilmiştir. Ortaya konulan modelde yapay sinir ağları modelinin girdi elemanlarını oluşturan niteliklerden bir tanesi, genetik algoritma yönteminin değişken değeri olarak tanımlanmaktadır. Genetik algoritma amaç fonksiyonu için ise yapay sinir ağları algoritmasının çıktı niteliği yani tahmin sonucu tanımlanır. Model amaç fonksiyonunda belirlenen değere ulaşabilmek için iterasyonlar yapar ve her iterasyonda genetik algoritma yöntemi değişken nitelik değerine yeni bir değer atayarak yapay sinir ağları yönteminin yeni bir tahmin yapmasını sağlamaktadır. Gerçekleşen tahmin tanımlanan amaç fonksiyonuna ulaşamadıysa genetik algoritma yöntemi değişken nitelik değeri için yeni girdi değerleri türetir.

Bu çalışmada genetik algoritma tabanlı yapay sinir ağları yöntemiyle konut inşaatlarında faaliyetlere ait risklerin risk önlem paketleriyle ve faaliyetleriyle hedeflenen risk sınıfına indirgenmesi gerçekleştirilmiştir. Geliştirilen modelde "Önlem Maliyeti" olarak adlandırılan

girdi niteliği değişken nitelik olarak alınmıştır. Genetik algoritma amaç fonksiyonu olarak da olasılıksal sinir ağları tabanlı yapay sinir ağları yöntemiyle tahmin edilen faaliyete ait riskin sınıfı tanımlanmıştır. Olasılıksal sinir ağları tabanlı yapay sinir ağları yönteminde tahmin çıktıları hangi olasılık değeriyle hangi sınıfa ait olduğu tahmin edilmektedir. Sonuç olarak çalışma kapsamında bir faaliyete ait riskin hangi risk sınıfına hangi olasılık yüzdesi ile ait olacağı kullanıcılar tarafından belirlenerek optimum önlem maliyeti ile o amaca ulaşması sağlanmaktadır.

4.BULGULAR

Tablo 4.1: Faaliyet 1 Önlem Maliyeti 10000 TL

Önlem Maliyeti	Faaliyet	Aktivite Maliyeti	Risk Olasılık	Risk Maliyet	Süresel Etki	Önceki Risk Sınıfı	Risk Kodu	Sonraki Risk Sınıfı		Kullanılan Etiket	Tahmin	Tahmin %	Yanlış %	İyi/Kötü	S%	B%
10000	Temel Atma	89060	M	H	M	S	1			tahmin	B	74,94%			25,06%	74,94%
1000	Temel Atma	89060	H	VH	VH	K	3	S		eğitim	S	100,00%	0,00%	İyi	100,00%	0,00%
2800	Temel Atma	89060	M	H	M	S	2	S		eğitim	S	76,85%	23,15%	İyi	76,85%	23,15%
8200	Temel Atma	89060	M	VH	L	S	4	S		eğitim	S	99,57%	0,43%	İyi	99,57%	0,43%
5200	Kaba İnşaat	153600	M	H	H	S	5	S		eğitim	S	77,93%	22,07%	İyi	77,93%	22,07%
6000	Kaba İnşaat	153600	M	H	H	S	6	B		eğitim	S	76,28%	76,28%	Kötü	76,28%	23,72%
14000	Kaba İnşaat	153600	H	H	M	S	7	B		eğitim	B	92,01%	7,99%	İyi	7,99%	92,01%
16000	Kaba İnşaat	153600	VH	VH	M	K	4	S		eğitim	S	100,00%	0,00%	İyi	100,00%	0,00%
32000	Elektrik ve Sıhhi Tesisat İşleri	193500	VH	H	M	K	8	S		eğitim	S	93,03%	6,97%	İyi	93,03%	6,97%

Tablo 4.1 (devam)

6500	Elektrik ve Sıhhi Tesisat İşleri	193500	M	H	M	S	9	S		eğitim	S	88,72%	11,28%	İyi	88,72%	11,28%
8200	Elektrik ve Sıhhi Tesisat İşleri	193500	H	H	H	K	10	S		eğitim	S	99,11%	0,89%	İyi	99,11%	0,89%
4000	Elektrik ve Sıhhi Tesisat İşleri	193500	M	H	L	S	4	B		test	B	94,24%	5,76%	İyi	5,76%	94,24%
6500	Çatı İşleri	93000	M	H	H	S	11	S		eğitim	S	77,29%	22,71%	İyi	77,29%	22,71%
25000	Çatı İşleri	93000	M	H	M	S	12	B		eğitim	B	95,89%	4,11%	İyi	4,11%	95,89%
2500	Çatı İşleri	93000	H	H	M	S	13	S		eğitim	S	99,97%	0,03%	İyi	99,97%	0,03%
7200	Çatı İşleri	93000	VH	VH	M	K	4	S		eğitim	S	99,99%	0,01%	İyi	99,99%	0,01%
7100	Fayans, Duvar ve Döşeme İşleri	85680	M	H	M	S	14	B		test	B	59,60%	40,40%	İyi	40,40%	59,60%
3300	Fayans, Duvar ve Döşeme İşleri	85680	L	VH	L	S	15	B		eğitim	B	100,00%	0,00%	İyi	0,00%	100,00%
15650	Fayans, Duvar ve Döşeme İşleri	85680	VH	H	M	K	16	B		eğitim	B	83,86%	16,14%	İyi	16,14%	83,86%
3100	Fayans, Duvar ve Döşeme İşleri	85680	L	M	L	B	4	B		eğitim	B	100,00%	0,00%	İyi	0,00%	100,00%

Tablo 4.1 (devam)

27000	Dış Sıva ve Cephe Kaplama İşleri	266000	H	VH	M	K	12	S		eğitim	S	99,96%	0,04%	İyi	99,96%	0,04%
3000	Dış Sıva ve Cephe Kaplama İşleri	266000	H	H	L	S	17	S		eğitim	S	99,83%	0,17%	İyi	99,83%	0,17%
2500	Dış Sıva ve Cephe Kaplama İşleri	266000	VH	H	M	K	18	S		eğitim	S	99,99%	0,01%	İyi	99,99%	0,01%
15000	Dış Sıva ve Cephe Kaplama İşleri	266000	VH	H	M	K	4	B		test	B	85,02%	14,98%	İyi	14,98%	85,02%

İlk analiz verileri Tablo 4.1'de gösterilmiştir. İlk analizde proje 1'e ait temel atma faaliyeti ele alınmıştır. Bu faaliyete ait risk kodu "1" olan Yeraltı Jeolojisi Jeoteknik Koşulları riski ilk analizde risk matrisinde Sarı bölgede olduğu hesaplanmıştır.

Risk önlem faaliyetleriyle riskin indirgenebileceği bilinmektedir. Örnek çalışmada 1 kod numaralı risk içeren 89.060 TL maliyetli temel atma faaliyeti 10.000 TL tutarındaki bir önlem paketiyle %74,94 aidiyet olasılığı ile "Beyaz" risk sınıfında olduğu yapay sinir ağları yönetimi ile tahmin edilmiştir.

Tablo 4.2: Faaliyet 1 Önlem Maliyeti 8000 TL

Önlem Maliyeti	Faaliyet	Aktivite Maliyeti	Risk Olasılık	Risk Maliyet	Süresel Etki	Önceki Risk Sınıfı	Risk Kodu	Sonraki Risk Sınıfı		Kullanılan Etiket	Tahmin	Tahmin %	Yanlış %	İyi/Kötü	S%	B%
8000	Temel Atma	89060	M	H	M	S	1			tahmin	B	64,93%			35,07%	64,93%

Tablo 4.2'de yine 1 kod numaralı riski içeren 89.060 TL maliyetli temel atma faaliyeti için bu kez 8000 TL tutarındaki bir önlem paketi ile tahmin aşaması gerçekleştirilmiştir. 8000 TL'lik önlem paketi ile %64,93 aidiyet olasılığı ile "Beyaz" risk sınıfında olduğu yapay sinir ağları yönetimi ile tahmin edilmiştir. Bu durum göstermiştir ki önlem maliyetinin azaldığı takdirde risk "Beyaz" risk sınıfında tahmin edilen 1 kod numaralı riskin "Beyaz" sınıfında olma olasılığı azalarak "Sarı" sınıfına yaklaşmıştır.

Tablo 4.3: Faaliyet 1 Önlem Maliyeti 5000

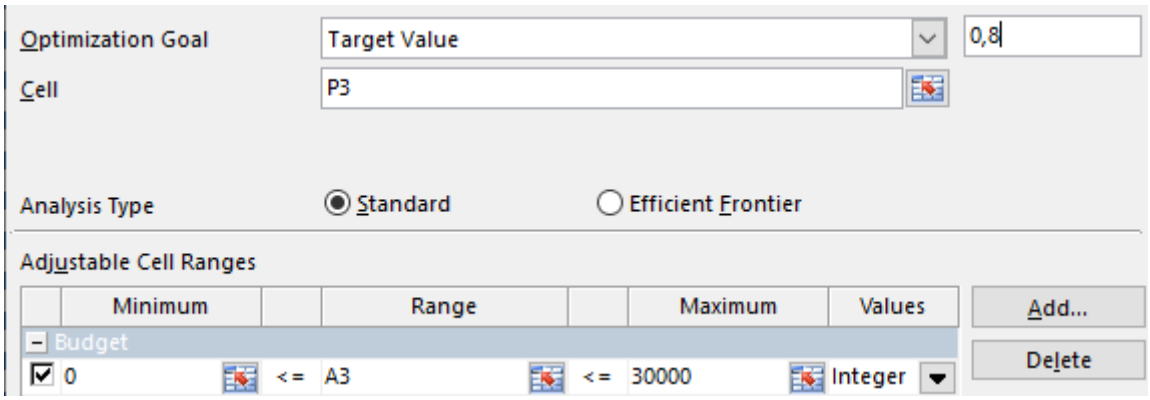
Önlem Maliyeti	Faaliyet	Aktivite Maliyeti	Risk Olasılık	Risk Maliyet	Süresel Etki	Önceki Risk Sınıfı	Risk Kodu	Sonraki Risk Sınıfı		Kullanılan Etiket	Tahmin	Tahmin %	Yanlış %	İyi/Kötü	S%	B%
5000	Temel Atma	89060	M	H	M	S	1			tahmin	S	58,74%			58,74 %	41,26 %

Tablo 4.3'de bu kez 1 kod numaralı riski içeren 89060 TL maliyetli temel atma faaliyeti için 5000 TL'lik bir önlem paketi ile tahmin aşaması gerçekleştirilmiştir. 5000 TL'lik önlem paketi ile artık 1 kod numaralı risk "Beyaz" risk sınıfında yer alamamakta; %58,74 aidiyet olasılığı ile daha tehlikeli risk sınıf bölgesi olan "Sarı" risk sınıfında yer aldığı yapay sinir ağı yönetimi ile tahmin edilmiştir.

Tablo 4.4: Faaliyet 1 Önlem Maliyeti 2000

Önlem Maliyeti	Faaliyet	Aktivite Maliyeti	Risk Olasılık	Risk Maliyet	Süresel Etki	Önceki Risk Sınıfı	Risk Kodu	Sonraki Risk Sınıfı		Kullanılan Etiket	Tahmin	Tahmin %	Yanlış %	İyi/Kötü	S%	B%
2000	Temel Atma	89060	M	H	M	S	1			tahmin	S	82,09%			82,09%	17,91%

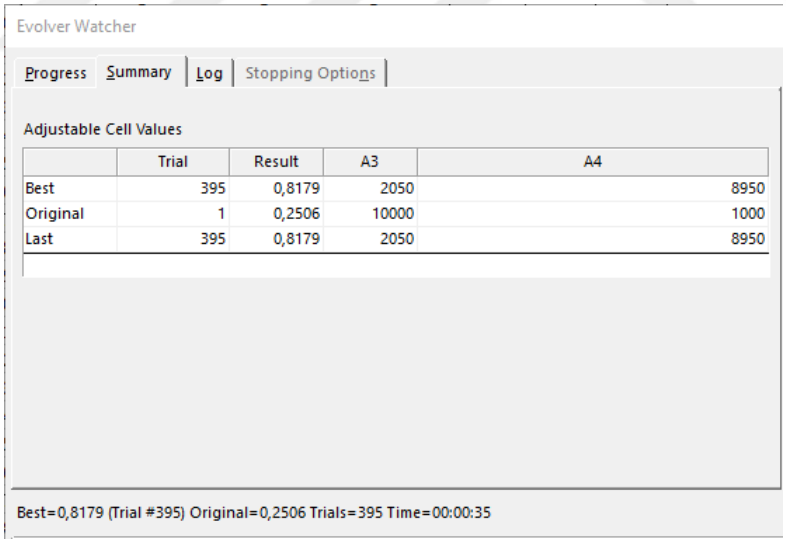
Tablo 4.4'de 1 kod numaralı riski içeren 89060 TL maliyetli temel atma faaliyeti için 2000 TL'lik bir önlem paketi ile tahmin aşaması gerçekleştirilmiştir. 2000 TL'lik önlem paketi ile 1 kod numaralı riskin yine "Sarı" sınıfında yer aldığı, ancak 5000 TL'lik önlem paketinde %58,74 olan aidiyet olasılığının %82,09 değerine yükseldiği olduğu yapay sinir ağı yönetimi ile tahmin edilmiştir.



Şekil 4.1: Genetik Algoritma Entegre Sonuç (%80 Sarı için)

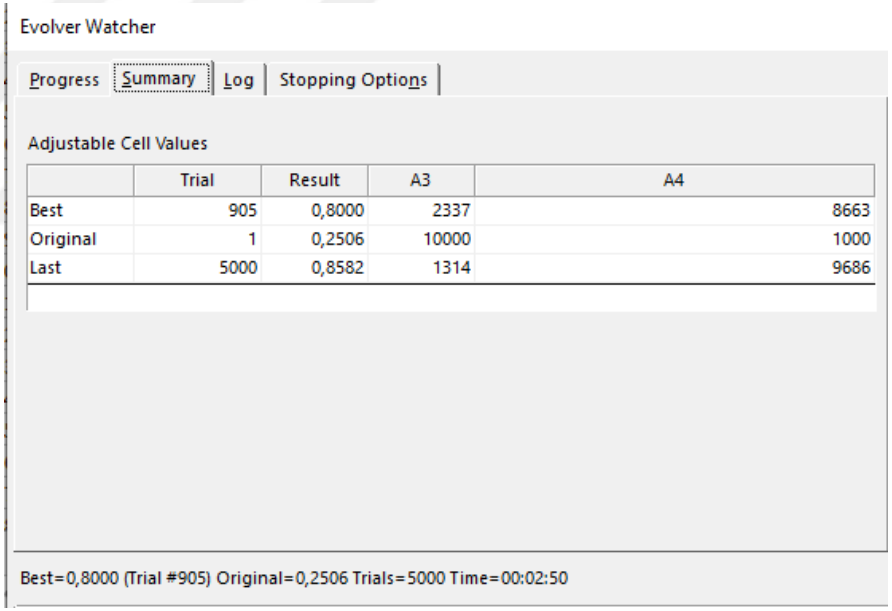
Şekil 4.1'de genetik algoritma modelimizin amaç fonksiyonu ve ayarlanabilir hücrenin maksimum ve minimum limitlerinin girildiği alanlar görülmektedir. Bu örnekte Proje 1'e ait temel atma faaliyetinin 1 kod numaralı riskin, ait olduğu risk sınıfının, yapay sinir ağları algoritması kullanılarak %80 olasılıkla "Sarı" risk bölgesinde tahmin edilmesi amaçlanmıştır. Bu sebeple genetik algoritmada modelinin optimizasyon hedef değeri olan 0,8 alınmıştır. 0,8 değeri yapay sinir ağları tarafından tahmin edilen risk sınıfı aidiyetinin olasılık değeridir.

Geliştirilen modelde ayarlanabilir niteliğimiz önlem maliyetidir. Şekil 4.1'de önlem maliyetinin değer aralığı 0 TL ile 30000 TL arasında sınırlandırıldığı görülmektedir.



Şekil 4.2: Genetik Algoritma Canlı Analiz Ekranı

Şekil 4.2'de 395.iterasyonda önlem maliyetinin 2050 TL olduğu durumda yapay sinir ağları algoritması risk sınıfını %81,79 olasılık ile "Sarı" bölgede olduğunu tahmin etmektedir.



Şekil 4.3: Genetik Algoritma Canlı Analiz Sonuç Ekranı

Şekil 4.3'de görüldüğü üzere genetik algoritma modeli 905. iterasyonda 2337 TL'lik önlem maliyeti değeri ile amaçlanan %80 aidiyet olasılığı ile proje 1' ait temel atma faaliyetinin 1 kod numaralı riskin "Sarı" bölgede olduğunu tahmin etmiştir.

9300	Fayans, Duvar ve Döşeme İşleri	68000	M	H	L	S	16	B	eğitim	B	86,65%	13,35%	İyi	86,65%	13,35%

2100	Fayans, Duvar ve Döşeme İşleri	68000	L	M	VL	B	4	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
30000	Dış Sıva ve Cephe Kaplama İşleri	200000	VH	H	M	K	12	B	eğitim	B	99,58%	0,42%	İyi	99,58%	0,42%
3000	Dış Sıva ve Cephe Kaplama İşleri	200000	L	H	L	S	17	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
2200	**Dış Sıva ve Cephe Kaplama İşleri**	**200000**	**VH**	**VH**	**VH**	**K**	**18**		tahmin	B	77,04%			77,04%	22,96%
2500	Dış Sıva ve Cephe Kaplama İşleri	200000	H	VH	L	K	4	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
2500	Temel Atma	115778	M	VH	H	K	3	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
32000	Temel Atma	115778	H	H	M	S	1	B	test	S	100,00%	100,00%	Kötü	0,00%	100,00%
3500	Temel Atma	115778	M	H	H	S	2	S	eğitim	S	78,23%	21,77%	İyi	21,77%	78,23%
12500	Temel Atma	115778	H	H	L	S	4	B	eğitim	B	99,89%	0,11%	İyi	99,89%	0,11%
9300	Kaba İnşaat	207360	H	H	H	K	5	S	test	S	100,00%	0,00%	İyi	0,00%	100,00%
7000	Kaba İnşaat	207360	M	H	M	S	6	B	eğitim	B	69,53%	30,47%	İyi	69,53%	30,47%

Şekil 4.4: Örnek Faaliyet (2200 TL, Dış Sıva ve Cephe Kaplama İşleri) Seçimi

Şekil 4.4'de örnek olarak 200000 TL bütçeli "Dış Sıva ve Cephe Kaplama İşleri" faaliyeti seçilmiştir. 2200 TL önlem paketi ile aidiyet olasılığı %77,04 olasılık ile "Beyaz" bölgede olduğu yapay sinir ağları algoritması ile tahmin edilmiştir.

9300	Fayans, Duvar ve Döşeme İşleri	68000	M	H	L	S	16	B	eğitim	B	86,65%	13,35%	İyi	86,65%	13,35%
2100	Fayans, Duvar ve Döşeme İşleri	68000	L	M	VL	B	4	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
30000	Dış Sıva ve Cephe Kaplama İşleri	200000	VH	H	M	K	12	B	eğitim	B	99,58%	0,42%	İyi	99,58%	0,42%
3000	Dış Sıva ve Cephe Kaplama İşleri	200000	L	H	L	S	17	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
3000	Dış Sıva ve Cephe Kaplama İşleri	**200000**	**VH**	**VH**	**VH**	**K**	**18**		**tahmin**	**B**	**85,44%**			**85,44%**	**14,56%**
2500	Dış Sıva ve Cephe Kaplama İşleri	200000	H	VH	L	K	4	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
2500	Temel Atma	115778	M	VH	H	K	3	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
32000	Temel Atma	115778	H	H	M	S	1	B	test	S	100,00%	100,00%	Kötü	0,00%	100,00%
3500	Temel Atma	115778	M	H	H	S	2	S	eğitim	S	78,23%	21,77%	İyi	21,77%	78,23%
12500	Temel Atma	115778	H	H	L	S	4	B	eğitim	B	99,89%	0,11%	İyi	99,89%	0,11%
9300	Kaba İnşaat	207360	H	H	H	K	5	S	test	S	100,00%	0,00%	İyi	0,00%	100,00%
7000	Kaba İnşaat	207360	M	H	M	S	6	B	eğitim	B	69,53%	30,47%	İyi	69,53%	30,47%

Şekil 4.5: Örnek Faaliyet (3000 TL, Dış Sıva ve Cephe Kaplama İşleri) Seçimi

Şekil 4.5'de "Dış Sıva ve Cephe Kaplama İşleri" aktivitesinin önlem paketi 3000 TL alınmıştır. 3000 TL'lik önlem paketi ile bu kez aidiyet olasılığı %85,44 olasılık ile yine "Beyaz" bölgede olmaktadır. Buradan, önlem maliyeti arttıkça risk sınıfının güvenli tarafta kalma olasılığının arttığı görülmektedir.

9300	Fayans, Duvar ve Döşeme İşleri	68000	M	H	L	S	16	B	eğitim	B	86,65%	13,35%	İyi	86,65%	13,35%
2100	Fayans, Duvar ve Döşeme İşleri	68000	L	M	VL	B	4	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
30000	Dış Sıva ve Cephe Kaplama İşleri	200000	VH	H	M	K	12	B	eğitim	B	99,58%	0,42%	İyi	99,58%	0,42%
3000	Dış Sıva ve Cephe Kaplama İşleri	200000	L	H	L	S	17	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
1750	**Dış Sıva ve Cephe Kaplama İşleri**	**200000**	**VH**	**VH**	**VH**	**K**	**18**		**tahmin**	**B**	**71,09%**			**71,09%**	**28,91%**
2500	Dış Sıva ve Cephe Kaplama İşleri	200000	H	VH	L	K	4	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
2500	Temel Atma	115778	M	VH	H	K	3	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
32000	Temel Atma	115778	H	H	M	S	1	B	test	S	100,00%	100,00%	Kötü	0,00%	100,00%
3500	Temel Atma	115778	M	H	H	S	2	S	eğitim	S	78,23%	21,77%	İyi	21,77%	78,23%
12500	Temel Atma	115778	H	H	L	S	4	B	eğitim	B	99,89%	0,11%	İyi	99,89%	0,11%
9300	Kaba İnşaat	207360	H	H	H	K	5	S	test	S	100,00%	0,00%	İyi	0,00%	100,00%
7000	Kaba İnşaat	207360	M	H	M	S	6	B	eğitim	B	69,53%	30,47%	İyi	69,53%	30,47%

Şekil 4.6: **Örnek Faaliyet (1750 TL, Dış Sıva ve Cephe Kaplama İşleri) Seçimi**

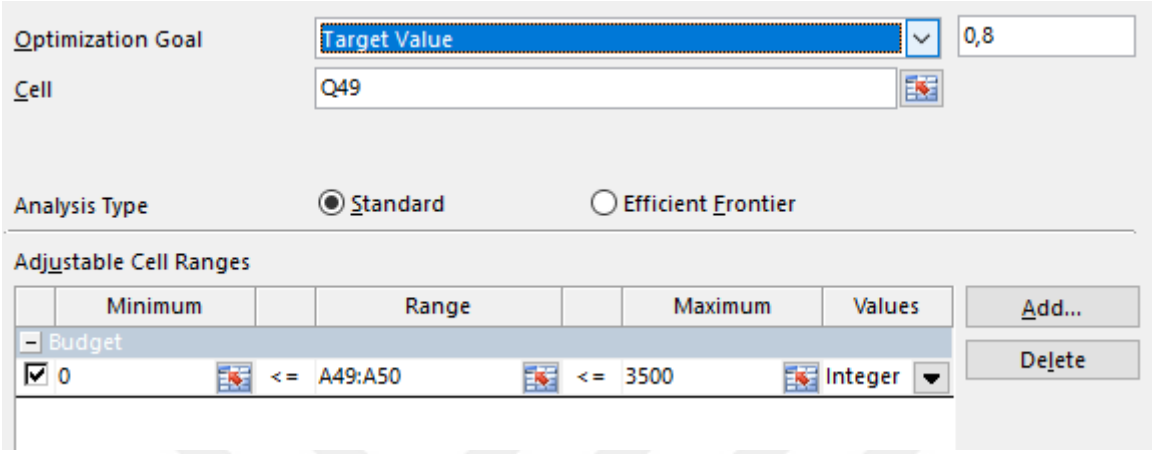
Şekil 4.6'da "Dış Sıva ve Cephe Kaplama İşleri" faaliyeti 1750 TL'lik bir önlem paketi ile işleme alınmıştır. Burada da görüldüğü üzere önlem paketinin maliyeti azaldıkça risk sınıfının B sınıfında kalma olasılığının azaldığı, tahmin değerinin S sınıfına doğru ilerlediği görülmektedir.

9300	Fayans, Duvar ve Döşeme İşleri	68000	M	H	L	S	16	B	eğitim	B	86,65%	13,35%	İyi	86,65%	13,35%
2100	Fayans, Duvar ve Döşeme İşleri	68000	L	M	VL	B	4	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
30000	Dış Sıva ve Cephe Kaplama İşleri	200000	VH	H	M	K	12	B	eğitim	B	99,58%	0,42%	İyi	99,58%	0,42%
3000	Dış Sıva ve Cephe Kaplama İşleri	200000	L	H	L	S	17	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
300	**Dış Sıva ve Cephe Kaplama İşleri**	**200000**	**VH**	**VH**	**VH**	**K**	**18**		**tahmin**	**S**	**52,21%**			**47,79%**	**52,21%**
2500	Dış Sıva ve Cephe Kaplama İşleri	200000	H	VH	L	K	4	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
2500	Temel Atma	115778	M	VH	H	K	3	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
32000	Temel Atma	115778	H	H	M	S	1	B	test	S	100,00%	100,00%	Kötü	0,00%	100,00%
3500	Temel Atma	115778	M	H	H	S	2	S	eğitim	S	78,23%	21,77%	İyi	21,77%	78,23%
12500	Temel Atma	115778	H	H	L	S	4	B	eğitim	B	99,89%	0,11%	İyi	99,89%	0,11%
9300	Kaba İnşaat	207360	H	H	H	K	5	S	test	S	100,00%	0,00%	İyi	0,00%	100,00%
7000	Kaba İnşaat	207360	M	H	M	S	6	B	eğitim	B	69,53%	30,47%	İyi	69,53%	30,47%

Şekil 4.7: Örnek Faaliyet 300 TL, Dış Sıva ve Cephe Kaplama İşleri) Seçimi

Şekil 4.7'de Dış Sıva ve Cephe Kaplama İşleri aktivitesi için önlem paketinin maliyeti 300 TL'ye düşürülmüştür. Önlem paketinin maliyetinin bu derece düşük olması, risklerin yeterince önlenemeyeceğine sebep olacaktır ve risk sınıfının aidiyet değeri %52,21 olasılık ile "Sarı" sınıfında kalacağı yapay sinir ağları algoritması tarafından tahmin edilmiştir.

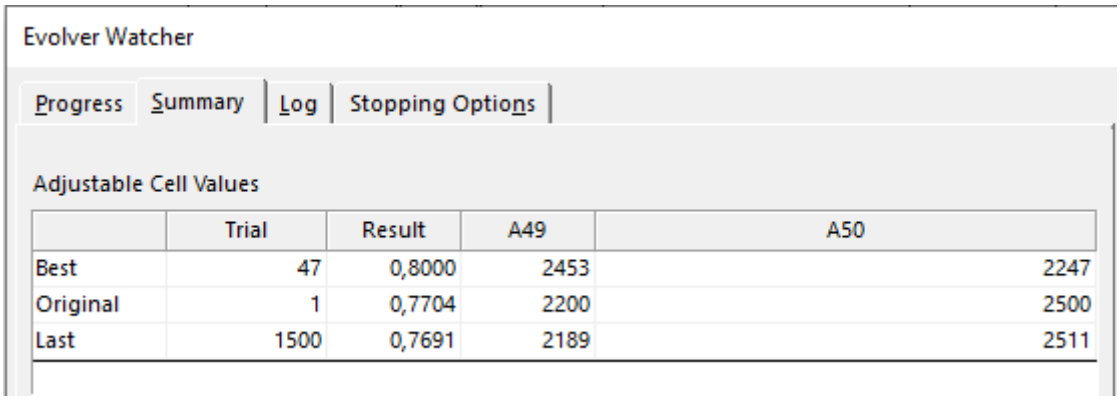
Yapay sinir ağları algoritması ile elde edilen sonuçlar, geliştirdiğimiz yapay sinir ağları tabanlı genetik algoritma modeli ile çözümlendirilecektir.



Şekil 4.8: Genetik Algoritma Entegre Sonuç (%80 Aidiyet Olasılığı ile "Sarı" Bölge İçin)

Şekil 4.8'de yapay sinir ağı tabanlı genetik algoritma modelimizin, amaç fonksiyonu ve ayarlanabilir hücrenin maksimum ve minimum limitlerinin girildiği alanlar görülmektedir. Bu örnekte Proje 2'ye ait dış sıva ve cephe kaplama faaliyetinin 18 kod numaralı riskin, ait olduğu risk sınıfının, yapay sinir ağları algoritması kullanılarak %80 olasılıkla "Sarı" risk bölgesinde tahmin edilmesi amaçlanmıştır. Bu sebeple genetik algoritmada modelinin optimizasyon hedef değeri olan 0,8 alınmıştır. 0,8 değeri yapay sinir ağları tarafından tahmin edilen risk sınıfı aidiyetinin olasılık değeridir.

Geliştirilen modelde ayarlanabilir niteliğimiz önlem maliyetidir. Şekil 4.8'de önlem maliyetinin değer aralığının 0 TL ile 3500 TL arasında sınırlandırıldığı görülmektedir.



	Trial	Result	A49	A50
Best	47	0,8000	2453	2247
Original	1	0,7704	2200	2500
Last	1500	0,7691	2189	2511

Şekil 4.9: Dış Sıva ve Cephe Kaplama Faaliyetinin 18 Kod Numaralı Riski İçin Genetik Algoritma Canlı Analiz Ekranı

Şekil 4.9'da görüldüğü üzere genetik algoritma modeli 47. iterasyonda 2453 TL'lik önlem maliyeti değeri ile amaçlanan %80 aidiyet olasılığı ile proje 2'ye ait dış sıva ve cephe kaplama faaliyetinin 18 kod numaralı riskin "Beyaz" bölgede olduğunu tahmin etmiştir.

36	00:00:03	79,81%	2436	2264
37	00:00:03	80,25%	2475	2225
38	00:00:03	80,31%	2481	2219
39	00:00:03	80,36%	2485	2215
40	00:00:03	80,42%	2491	2209
41	00:00:03	80,03%	2455	2245
42	00:00:04	80,02%	2454	2246
43	00:00:04	80,09%	2461	2239
44	00:00:04	80,59%	2506	2194
45	00:00:04	77,65%	2250	2450
46	00:00:04	80,17%	2468	2232
47	00:00:04	80,00%	2453	2247
48	00:00:04	79,99%	2452	2248
49	00:00:04	80,06%	2458	2242
50	00:00:04	80,04%	2456	2244
51	00:00:04	80,07%	2459	2241
52	00:00:04	77,60%	2246	2454
53	00:00:04	79,98%	2451	2249
54	00:00:04	77,61%	2247	2453
55	00:00:04	64,79%	1327	3373
56	00:00:04	88,32%	3359	1341

Şekil 4.10: YSA Tabanlı GA Deneme Sonuçları Kesit Ekranı

Şekil 4.10’da geliştirilen modelin canlı analiz ekranı yer almaktadır. Ekranın en solundaki değerler iterasyon sayılarını ifade etmektedir. İterasyon sayılarının hemen sağ tarafında yer alan değerler iterasyonların kaçıncı saniyede denendiğini göstermektedir. %’lik değerlerin yer aldığı sütun ve son iki sütun ise kullanıcının belirlemiş olduğu optimizasyon hedef değerine (%80) hangi önlem paketi değeri verildiğinde hangi %’lik değere ulaşıldığını göstermektedir. Görüldüğü üzere 47. İterasyonda 2453 TL’lik önlem paketi ile %80 hedef değerine ulaşılmıştır.

15000	Elektrik ve Sıhhi Tesisat İşleri	490400	M	VH	H	K	9	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
25000	Elektrik ve Sıhhi Tesisat İşleri	490400	M	H	H	S	10	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
10000	Elektrik ve Sıhhi Tesisat İşleri	490400	L	VH	H	S	4	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
20000	Çatı İşleri	227850	M	H	VH	K	11	S	eğitim	S	83,34%	16,66%	İyi	16,66%	83,34%
60000	Çatı İşleri	227850	H	VH	H	K	12	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
5000	**Çatı İşleri**	**227850**	**M**	**H**	**H**	**S**	**13**		**tahmin**	**S**	**59,82%**			**40,18%**	**59,82%**
24000	Çatı İşleri	227850	H	H	H	K	4	B	test	B	84,09%	15,91%	İyi	84,09%	15,91%
17100	Fayans, Duvar ve Döşeme İşleri	224910	H	H	VH	K	14	S	eğitim	S	78,14%	21,86%	İyi	21,86%	78,14%
8500	Fayans, Duvar ve Döşeme İşleri	224910	L	VH	H	S	15	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
22500	Fayans, Duvar ve Döşeme İşleri	224910	M	H	H	S	16	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
6500	Fayans, Duvar ve Döşeme İşleri	224910	L	H	M	S	4	B	test	B	100,00%	0,00%	İyi	100,00%	0,00%
54000	Dış Sıva ve Cephe Kaplama İşleri	982072	L	VH	M	S	12	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
15000	Dış Sıva ve Cephe Kaplama İşleri	982072	H	VH	VH	K	17	S	eğitim	S	65,65%	34,35%	İyi	34,35%	65,65%
7800	Dış Sıva ve Cephe Kaplama İşleri	982072	M	H	H	S	18	B	test	B	53,51%	46,49%	İyi	53,51%	46,49%

Şekil 4.11: Proje 3 "Çatı İşleri" Faaliyeti 13 Kodlu Risk İçin Önlem Paketi 5000 TL Olduğunda Ekran Kesiti

Şekil 4.11'de, 3.projenin "Çatı İşleri" faaliyeti 13 kodlu riski örnek olarak seçilmiştir. Bu örnek faaliyet için önlem paketi 5000 TL olduğunda %59,82 aidiyet olasılığı ile "Sarı" sınıfında olduğu yapay sinir ağları tarafından tahmin edilmiştir.

15000	Elektrik ve Sıhhi Tesisat İşleri	490400	M	VH	H	K	9	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
25000	Elektrik ve Sıhhi Tesisat İşleri	490400	M	H	H	S	10	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
10000	Elektrik ve Sıhhi Tesisat İşleri	490400	L	VH	H	S	4	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
20000	Çatı İşleri	227850	M	H	VH	K	11	S	eğitim	S	83,34%	16,66%	İyi	16,66%	83,34%
60000	Çatı İşleri	227850	H	VH	H	K	12	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
3000	**Çatı İşleri**	**227850**	**M**	**H**	**H**	**S**	**13**		**tahmin**	**S**	**68,92%**			**31,08%**	**68,92%**
24000	Çatı İşleri	227850	H	H	H	K	4	B	test	B	84,09%	15,91%	İyi	84,09%	15,91%
17100	Fayans, Duvar ve Döşeme İşleri	224910	H	H	VH	K	14	S	eğitim	S	78,14%	21,86%	İyi	21,86%	78,14%
8500	Fayans, Duvar ve Döşeme İşleri	224910	L	VH	H	S	15	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
22500	Fayans, Duvar ve Döşeme İşleri	224910	M	H	H	S	16	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
6500	Fayans, Duvar ve Döşeme İşleri	224910	L	H	M	S	4	B	test	B	100,00%	0,00%	İyi	100,00%	0,00%
54000	Dış Sıva ve Cephe Kaplama İşleri	982072	L	VH	M	S	12	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
15000	Dış Sıva ve Cephe Kaplama İşleri	982072	H	VH	VH	K	17	S	eğitim	S	65,65%	34,35%	İyi	34,35%	65,65%
7800	Dış Sıva ve Cephe Kaplama İşleri	982072	M	H	H	S	18	B	test	B	53,51%	46,49%	İyi	53,51%	46,49%

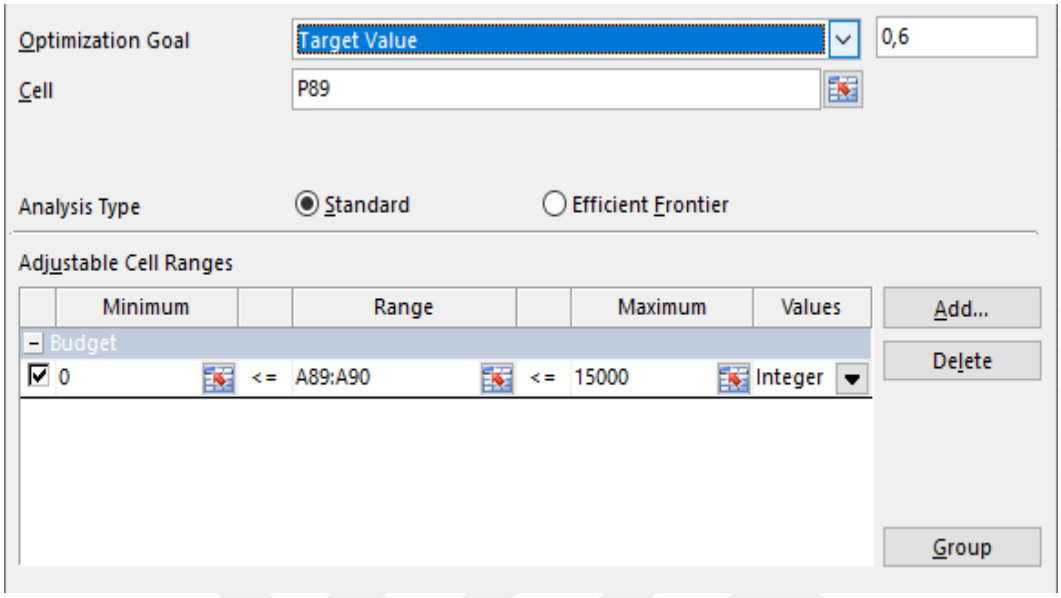
Şekil 4.12: Proje 3 "Çatı İşleri" Faaliyeti 13 Kodlu Risk Önlem Paketi 3000 TL Olduğunda Ekran Kesiti

3.projenin "Çatı İşleri" faaliyetinin 13 kodlu riskinin önlem paketi 5000 TL yerine 3000 TL olarak alındığında Şekil 4.12'de görüldüğü üzere önlem paketindeki bu düşüş, aidiyet olasılığı riskini %59,82'den &68,92'ye çıkarmıştır. Riskin yine "Sarı" sınıfta yer aldığı ancak olasılık yüzdesinin arttığı yapay sinir ağları tarafından tahmin edilmiştir.

15000	Elektrik ve Sıhhi Tesisat İşleri	490400	M	VH	H	K	9	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
25000	Elektrik ve Sıhhi Tesisat İşleri	490400	M	H	H	S	10	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
10000	Elektrik ve Sıhhi Tesisat İşleri	490400	L	VH	H	S	4	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
20000	Çatı İşleri	227850	M	H	VH	K	11	S	eğitim	S	83,34%	16,66%	İyi	16,66%	83,34%
60000	Çatı İşleri	227850	H	VH	H	K	12	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
8000	**Çatı İşleri**	**227850**	**M**	**H**	**H**	**S**	**13**		**tahmin**	**B**	**54,49%**			**54,49%**	**45,51%**
24000	Çatı İşleri	227850	H	H	H	K	4	B	test	B	84,09%	15,91%	İyi	84,09%	15,91%
17100	Fayans, Duvar ve Döşeme İşleri	224910	H	H	VH	K	14	S	eğitim	S	78,14%	21,86%	İyi	21,86%	78,14%
8500	Fayans, Duvar ve Döşeme İşleri	224910	L	VH	H	S	15	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
22500	Fayans, Duvar ve Döşeme İşleri	224910	M	H	H	S	16	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
6500	Fayans, Duvar ve Döşeme İşleri	224910	L	H	M	S	4	B	test	B	100,00%	0,00%	İyi	100,00%	0,00%
54000	Dış Sıva ve Cephe Kaplama İşleri	982072	L	VH	M	S	12	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
15000	Dış Sıva ve Cephe Kaplama İşleri	982072	H	VH	VH	K	17	S	eğitim	S	65,65%	34,35%	İyi	34,35%	65,65%
7800	Dış Sıva ve Cephe Kaplama İşleri	982072	M	H	H	S	18	B	test	B	53,51%	46,49%	İyi	53,51%	46,49%

Şekil 4.13: Proje 3 "Çatı İşleri" Faaliyeti 13 Kodlu Risk Önlem Paketi 8000 TL Olduğunda Ekran Kesiti

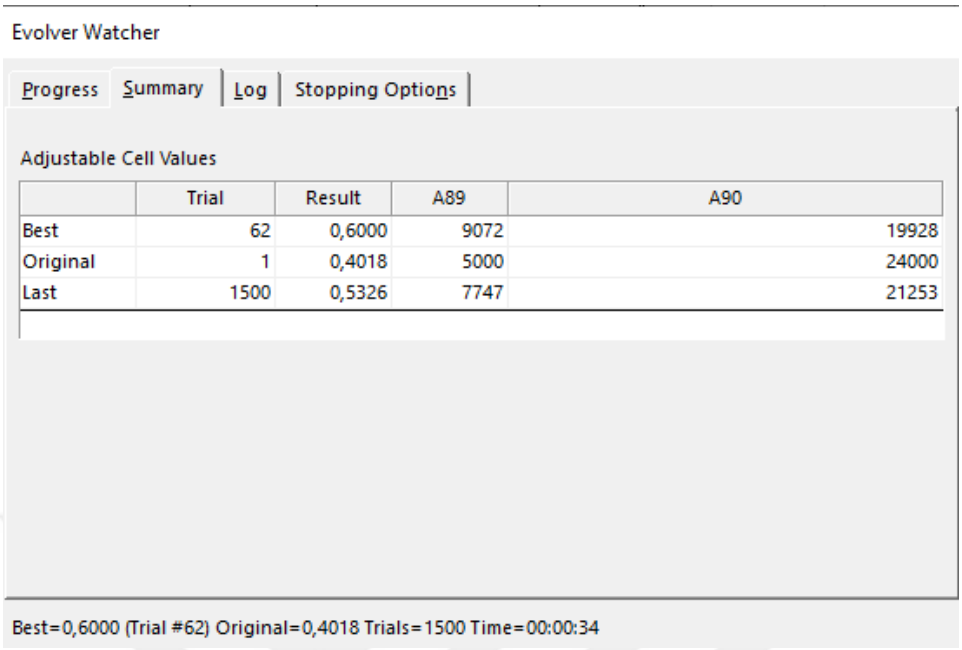
3.projenin "Çatı İşleri" faaliyetinin 13 kodlu riskinin önlem paketi 8000 TL olarak alındığında Şekil 4.13'de görüldüğü üzere önlem paketindeki yükseliş, risk sınıfının değişmesine yani "Sarı" bölgeden, daha az riskli olan "Beyaz" bölgede yer almasına neden olmuştur. Aynı zamanda, aidiyet yüzdesinin %54,49 olasılık ile "Beyaz" sınıfında olduğu da yapay sinir ağları algoritması tarafından tahmin edilmiştir.



Şekil 4.14: Genetik Algoritma Entegre Sonuç (%60 Aidiyet Olasılığı ile "Beyaz" Bölge İçin)

Şekil 4.14'de yapay sinir ağı tabanlı genetik algoritma modelimizin, amaç fonksiyonu ve ayarlanabilir hücrenin maksimum ve minimum limitlerinin girildiği alanlar görülmektedir. Proje 3'ye ait "Çatı İşleri" faaliyetinin 13 kodlu riskinin, ait olduğu risk sınıfının, yapay sinir ağları algoritması kullanılarak %60 olasılıkla "Beyaz" risk bölgesinde tahmin edilmesi amaçlanmıştır. Bu sebeple genetik algoritmada modelinin optimizasyon hedef değeri olan 0,6 alınmıştır. 0,6 değeri yapay sinir ağları tarafından tahmin edilen risk sınıfı aidiyetinin olasılık değeridir.

Geliştirilen modelde ayarlanabilir niteliğimiz önlem maliyetidir. Şekil 4.14'de önlem maliyetinin değer aralığının 0 TL ile 15000 TL arasında sınırlandırıldığı görülmektedir.



Şekil 4.15: Çatı İşleri Faaliyetinin 13 Kod Numaralı Riski İçin Genetik Algoritma Canlı Analiz Ekranı

Şekil 4.15'de görüldüğü üzere genetik algoritma modeli 62. iterasyonda 9072 TL'lik önlem paketi ile amaçlanan %60 aidiyet olasılığı ile proje 3'e ait çatı işleri faaliyetinin 13 kod numaralı riskin "Beyaz" bölgede olduğunu tahmin etmiştir.

15000	Elektrik ve Sıhhi Tesisat İşleri	490400	M	VH	H	K	9	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
25000	Elektrik ve Sıhhi Tesisat İşleri	490400	M	H	H	S	10	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
10000	Elektrik ve Sıhhi Tesisat İşleri	490400	L	VH	H	S	4	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
20000	Çatı İşleri	227850	M	H	VH	K	11	S	eğitim	S	83,34%	16,66%	İyi	16,66%	83,34%
60000	Çatı İşleri	227850	H	VH	H	K	12	S	eğitim	S	100,00%	0,00%	İyi	0,00%	100,00%
9072	**Çatı İşleri**	**227850**	**M**	**H**	**H**	**S**	**13**		**tahmin**	**B**	**60,00%**			**60,00%**	**40,00%**
19928	Çatı İşleri	227850	H	H	H	K	4	B	test	B	84,09%	15,91%	İyi	84,09%	15,91%
17100	Fayans, Duvar ve Döşeme İşleri	224910	H	H	VH	K	14	S	eğitim	S	78,14%	21,86%	İyi	21,86%	78,14%
8500	Fayans, Duvar ve Döşeme İşleri	224910	L	VH	H	S	15	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
22500	Fayans, Duvar ve Döşeme İşleri	224910	M	H	H	S	16	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
6500	Fayans, Duvar ve Döşeme İşleri	224910	L	H	M	S	4	B	test	B	100,00%	0,00%	İyi	100,00%	0,00%
54000	Dış Sıva ve Cephe Kaplama İşleri	982072	L	VH	M	S	12	B	eğitim	B	100,00%	0,00%	İyi	100,00%	0,00%
15000	Dış Sıva ve Cephe Kaplama İşleri	982072	H	VH	VH	K	17	S	eğitim	S	65,65%	34,35%	İyi	34,35%	65,65%
7800	Dış Sıva ve Cephe Kaplama İşleri	982072	M	H	H	S	18	B	test	B	53,51%	46,49%	İyi	53,51%	46,49%

Şekil 4.16: Proje 3 "Çatı İşleri" Faaliyeti 13 Kodlu Risk Önlem Paketi 8000 TL Olduğunda Ekran Kesiti

Şekil 4.16'da görüldüğü üzere %60 aidiyet olasılığı ile "Beyaz" risk sınıfında olma olasılığı tahmini için GA ile hesaplanan önlem maliyeti değeri 9072 TL olmuştur.

5. TARTIŞMA VE SONUÇ

20/6/2012 tarihinde yürürlüğe giren 6331 sayılı İş Sağlığı ve Güvenliği Kanunu'ndan bu yana toplam İş kazaları içinde İnşaat sektöründeki yaralanmalı ve ölümlü iş kazalarının payının çok az arttığı gözlenmektedir. Türkiye'de son 2012 – 2016 yılları arasında toplam 1.015.241 adet iş kazası meydana gelmiştir. Bu iş kazaları içeresinde, 143.788 âdeti inşaat sektöründe meydana gelmiştir. Başka bir ifade ile inşaat iş kazalarının toplam iş kazaları içerisindeki payı ortalama %13,83'dür [45, 46]. Meydana gelen bu iş kazaları iş gücü kaybına, maddi kayıplara, manevi kayıplara sebep olmakta ve tüm bu kayıplar daha büyük olumsuzlukların meydana gelmesine sebep olmaktadır.

Yaşanan teknolojik gelişmelerle birlikte önümüzdeki yıllarda ülkemizde ve dünyada inşaat sektörünün büyümeye devam edeceği öngörülmektedir. Bu bağlamda inşaat sektöründe başarıyı nitelikli iş gücünün sektöre dâhil olması, eldeki verilerin doğru kullanılarak iyi analiz edilmesi ve sektörel faaliyetlerin ileri teknoloji ile güçlendirilmesi parametrelerinin belirleyeceği düşünülmektedir [47].

İş kazalarının önlenmesi eğer önlenemiyorsa gerekli tedbirlerin alınmasıyla risklerin indirgenmesi ve dahi iş kazası meydana geldiğinde en az zarar ile bu olayın atlatılması amacıyla bu tez çalışmasında başta inşaat sektörü olmak üzere diğer sektörlere de uyarlanıp kullanılabilecek genetik algoritma tabanlı bir yapay sinir ağı modeli geliştirilmiştir.

Bu çalışma kapsamında, inşaat sektöründe çalışmalar yürüten kişi, kurum ve kuruluşlar ile görüşülmüş, modelin oluşturulmasında kullanılan veriler yapılan bu görüşmelerin sonucunda elde edilen bilgilere dayanarak belirlenmiştir. Konut inşaatı şantiyelerinden alınan veriler, genetik algoritma tabanlı yapay sinir ağları algoritmaları ile bir karar destek modelinin geliştirilmesinde kullanılmıştır. Geliştirilen bu model için farklı büyüklüklerde 4 adet konut inşaatı projesi değerlendirilmeye alınmış ve saha araştırması yapılarak risk skorları hesaplanmıştır. Daha sonra risk önlem paketleri üzerinde çalışılarak önlem maliyetleri belirlenmiştir ve risklerin indirgenme işlemlerinden sonra risk skor değerleri hesaplanmıştır.

İndirgenmiş risk skor değerleri hesaplandıktan sonra değişken nitelik olarak tanımlanan "Önlem Maliyeti" girdi niteliği, genetik algoritma amaç fonksiyonu olarak da tahmin edilen faaliyete ait riskin sınıfı tanımlanmıştır. Çalışmanın sonucunda bir faaliyete ait riskin ait olacağı risk sınıfı ve o risk sınıfına hangi olasılık yüzde değeri ile ait olacağı kullanıcılar tarafından seçilerek o riskin istenilen seviyeye indirgenmesi için gerekli önlem maliyeti genetik algoritma ve yapay sinir ağları entegre modeliyle hesaplanmaktadır.

Tez çalışmasının bulgular kısmında, geliştirilen model birçok riskli faaliyet örneği ile işlem yapılmış, yapılan işlemlerin belirlenen sınırlar dahilinde tutarlı ve güvenilir sonuçlar verdiği görülmüştür. Bazı riskli olaylardan (deprem, sel vb. doğal afetler, ekonomik kriz vb.) kaçınılamadığı için önlem paketi ya da önlem maliyetleri de ne kadar fazla olursa olsun riskin belirli bir noktadan sonra azalmadığı tespit edilmiştir. Bu durum göstermektedir ki geliştirilen model ile son kullanıcı hedef risk sınıfını ve hangi olasılıkla bu risk sınıfında olacağına karar verdikten sonra yapay sinir ağları ve genetik algoritma yöntemlerinin entegrasyonu ile önlem maliyeti model tarafından hesaplanacaktır.

Geliştirilen modelin gelecek çalışmalar için iyi bir altyapı niteliği taşımaktadır gelecek çalışmalarda veri sayıları ve girdi nitelikleri artırılarak daha doğru tahmin değerlerine ulaşabilen algoritmalar ile geliştirilen risk yönetim modeli daha da geliştirilebilir bunun yanında inşaat sektörü haricindeki sektörlerde de örnek çalışmalar yapılabilir.

6.KAYNAKLAR

[1] PMBOK, PMI., 2008, *A guide to the project management body of knowledge*,PMI TR, Türkiye, ISBN: 978-605-889-470-9.

[2] Kerzner, H., 2017, *Project management: a systems approach to planning, scheduling, and controlling*. John Wiley & Sons, New York, ISBN: 0-471-39342-8.

[3] Sears, S.K., Sears G.A., Clough R.H., Rounds J.L., Segner, R.O., 2015, *Construction project management*. John Wiley & Sons, New York, ISBN 978-1-118-74505-2.

[4] Lewis, J. P. 2005. *Project Planning, Scheduling & Control, 4E*. McGraw-Hill Pub. Co..

[5] Christoffersen, P. 2003, *Elements of financial risk management*. Academic Press.

[6] Molak, V. 1997, *Fundamentals of risk analysis and risk management* (pp. 233-245). V. Molak (Ed.). Boca Raton, FL, USA: Lewis Publishers.

[7] Seykota, E., 2003, Risk Management, http://www.seykota.com/tribe/risk/index.htm, [Ziyaret tarihi: 5 Haziran 2018]

[8] Chavas, J. P. (2004). *Risk analysis in theory and practice*. Elsevier.

[9] Smith, P. G., & Merritt, G. M. (2002). *Proactive risk management: Controlling uncertainty in product development*. Productivity Press.

[10] Goldman, L., 2000, Risk analysis and Monte Carlo simulation. *Decisioneering, Inc*.

[11] Linsmeier, T. J., & Pearson, N. D., 1996, *Risk measurement: An introduction to value at risk* (No. 1629-2016-134959).

[12] Schroeck, G., 2002, *Risk management and value creation in financial institutions*, John Wiley & Sons, Inc., Hoboken, USA, ISBN:0-471-25476-2

[13] Benninga, S., Wiener, Z., 1998, Value-at-Risk (VaR), *Mathematica in Education and R*esearch, 7 (4), 1-7.

[14] Christoffersen, P.F., 2003, Elements of Financial Risk Management, Academic Press, USA, ISBN: 0-12-174232-6

[15] Krishnamoorthy, C.S., Rajeev, S., 1996, *Artificial Intelligence and Expert Systems for Engineers*, CRC Press LLC, ISBN: 0849391253

[16] Rabuñal, J.R., Dorado, J., 2006, *Artificial Neural Networks in real-life applications*, Idea Group Publishing, ISBN:1-59140-902-0

[17] Looney, C.G. 2019, Probabilistic Neural Network Tutorial, https://www.cse.unr.edu/~looney/cs773b/PNNtutorial.pdf, [Ziyaret tarihi: 4 Mayıs 2018]

[18] Bozdogan, H., 2000, *Statistical Data Mining and Knowledge Discovery*, CRC Press LLC, Boca Raton, ISBN:1-58488-344-8

[19] Luger, G.F., 2005, A*rtificial Intelligence Structures and Strategies for Complex Problem Solving 5th Edition*, Pearson Education Limited, England, ISBN:978-0-321-26318-6

[20] Jorion, P., 2003, Financial Risk Manager Handbook, John Wiley & Sons, Inc., Hoboken, USA, ISBN: 0-471-43003-X

[21] Hegde, j., Rokseth, B., 2020, Applications of machine learning methods for engineering risk assessment – a review, *Safety Science*, 122, 104492 1-1

[22] Changwei, Y., Zonghao, L., Xueyan, G., Wenying, Y., Jing, J., Liang, Z., 2019, Application of BP neural network model in risk evaluation of railway construction, *Complexity*, 2019, 2946158 1-12.

[23] Ivarsson, A., & Stachowicz, J., 2019, Evaluating machine learning methods for detecting sleep arousal.

[24] Martínez, D.M., Fernández-Rodríguez, J.C., 2017, Artificial Intelligence applied to project success: a literature review, *International Journal of Artificial Intelligence and Interactive Multimedia*, 3, 77-82

[25] Chiroma, H., Noor, A.S.M., Abdulkareem, A., Abubakar, A.I., Hermawan, A., Qin, H., Hamza, M.F., Herawan, T., 2017, Neural networks optimization through genetic algorithm searches: a review, *Applied Mathematics & Information Sciences*, 11 (6), 1543-1564.

[26] Sheikh, M.J., Mehrani, K., 2016, A genetic algorithm-based neural network for forecasting the risk of high-tech projects, *Journal of Power*, 160 (12), 1-13

[27] Serpella, A. F., Ferrada, X., Howard, R., & Rubio, L., 2014, Risk management in construction projects: a knowledge-based approach. *Procedia-Social and Behavioral Sciences*, *119*, 653-662.

[28] Yu, F., & Xu, X., 2014, A short-term load forecasting model of natural gas based on optimized genetic algorithm and improved BP neural network. *Applied Energy*, *134*, 102-113.

[29] Unal, M., Onat, M., Demetgul, M., & Kucuk, H., (2014). Fault diagnosis of rolling bearings using a genetic algorithm optimized neural network. *Measurement*, *58*, 187-196.

[30] Feng, N., Wang, H. J., & Li, M., 2014. A security risk analysis model for information systems: Causal relationships of risk factors and vulnerability propagation analysis. *Information sciences*, *256*, 57-73.

[31] Karegowda, A. G., Manjunath, A. S., & Jayaram, M. A., 2011, Application of genetic algorithm optimized neural network connection weights for medical diagnosis of pima Indians diabetes. *International Journal on Soft Computing*, *2*(2), 15-23.

[32] Ding, S., Su, C., & Yu, J., 2011, An optimizing BP neural network algorithm based on genetic algorithm. *Artificial intelligence review*, *36*(2), 153-162.

[33] Jin, X. H., & Zhang, G., 2011, Modelling optimal risk allocation in PPP projects using artificial neural networks. *International journal of project management*, *29*(5), 591-603.

[34] Wang, J., Sun, Z., Dai, Y., & Ma, S., 2010, Parametric optimization design for supercritical CO2 power cycle using genetic algorithm and artificial neural network. *Applied Energy*, *87*(4), 1317-1324.

[35] Magnier, L., & Haghighat, F., 2010, Multiobjective optimization of building design using TRNSYS simulations, genetic algorithm, and Artificial Neural Network. *Building and Environment*, *45*(3), 739-746.

[36] Khashman, A., 2010, Neural networks for credit risk evaluation: Investigation of different neural models and learning schemes. *Expert Systems with Applications*, *37*(9), 6233-6239.

[37] Sedki, A., Ouazar, D., & El Mazoudi, E., 2009, Evolving neural network using real coded genetic algorithm for daily rainfall–runoff forecasting. *Expert Systems with Applications*, *36*(3), 4523-4527.

[38] Zhou, C. C., Yin, G. F., & Hu, X. B., 2009, Multi-objective optimization of material selection for sustainable products: artificial neural networks and genetic algorithm approach, *Materials & Design*, 30(4), 1209-1215.

[39] Schieg, M., 2006, Risk management in construction project management. *Journal of Business Economics and Management*, *7*(2), 77-83.

[40] Kalogirou, S. A., 2004, Optimization of solar systems using artificial neural-networks and genetic algorithms, *Applied Energy*, 77(4), 383-405.

[41] Samanta, B. I. S. W. A. J. I. T., Al-Balushi, K. R., & Al-Araimi, S. A., 2003, Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection. *Engineering applications of artificial intelligence*, *16*(7-8), 657-665.

[42] Baloi, D., & Price, A. D., 2003, Modelling global risk factors affecting construction cost performance. *International journal of project management*, *21*(4), 261-269.

[43] Kim, K. J., & Han, I., 2000, Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert systems with Applications*, *19*(2), 125-132.

[44] Tah, J. H. M., & Carr, V., 2000, Information modelling for a construction project risk management system. *Engineering, Construction and Architectural Management*, *7*(2), 107-119.

[45] Bilim, A., & ÇELİK, O. N. (2018). TÜRKİYE'DEKİ İNŞAAT SEKTÖRÜNDE MEYDANA GELEN İŞ KAZALARININ GENEL DEĞERLENDİRMESİ. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, *7*(2), 725-731.

[46] İş Sağlığı ve Güvenliği Kanunu, Kanun no: 6331, Kabul Tarihi: 20/06/2012, Sayı: 28339, Tertip: 5, Cilt: 52

[47] HACIBEKTAŞOĞLU, S. E. İNŞAAT SEKTÖRÜNDE YAŞANAN İŞ KAZALARININ ANALİZİ VE BU KAZALARA NEDEN OLAN ETKENLERİN İNCELENMESİ. *Stratejik ve Sosyal Araştırmalar Dergisi*, *2*(3), 159-177.

EKLER

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Mehmet Alp AYTEKİN
Doğum Yeri	Seyhan
Doğum Tarihi	27.04.1993
Uyruğu	☑ T.C. ❒ Diğer:
Telefon	0536 391 18 17
E-Posta Adresi	alpaytekin@entertech.com.tr
Web Adresi	-



Eğitim Bilgileri	
Lisans	
Üniversite	Süleyman Demirel Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Endüstri Mühendisliği Bölümü
Mezuniyet Yılı	2015

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi-Cerrahpaşa
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Endüstri Mühendisliği Anabilim Dalı
Programı	Endüstri Mühendisliği Programı

Makale ve Bildiriler