



## Adaptif Sinyalize Kavşaklar için Derin Öğrenme Yaklaşımı ile Gecikme Modelleri Geliştirilmesi

### Development of Delay Models with a Deep Learning Approach for Adaptive Signalized Intersections

Berk Bayraktar<sup>1</sup>, Erdem Doğan<sup>2</sup>

<sup>1</sup>Çevre ve Şehircilik Bakanlığı, Toplu Konut İdaresi Başkanlığı, Ankara, TÜRKİYE

<sup>2</sup>Kırıkkale Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü, 71451 Kırıkkale, TÜRKİYE

**Başvuru/Received:** 19/12/2020

**Kabul / Accepted:** 10/02/2021

**Çevrimiçi Basım / Published Online:** 13/02/2021

**Son Versiyon/Final Version:** 18/06/2021

#### Öz

Sinyalize kavşak yönetim sistemleri, haberleşme ve detektör sistemlerindeki gelişmeler sayesinde daha verimli hale gelmiştir. Özellikle Adaptif Sinyal Yönetim Sistemleri (ASYS), kavşakları değişken trafik parametrelerine uyum sağlayacak biçimde planlamaktadır. Fakat sinyalize kavşakların etkinliğinin ölçülmesi için geliştirilen geçmiş yaklaşımlar, devre süresi ve faz düzeni gibi denetim parametrelerinin sürekli değişimine uyumlu değildir. Bu çalışmada, derin öğrenme yaklaşımı kullanılarak ASYS ile yönetilen kavşaklar için bir gecikme tahmin modeli (DÖM) geliştirilmiştir. Performanslar, yapay sinir ağı (YSA) modelleri ve analitik modellerle karşılaştırılarak DÖM'ün verimliliği analiz edilmiştir. Ayrıca, DÖM ve YSA modelleri, farklı girdi değişkenleri ile eğitilerek performansları araştırılmıştır. Modellemeler için kullanılan veriler Kırıkkale ili sınırları içindeki ASYS ile yönetilen bir kavşaktan, gözlem yapılarak toplanmıştır. Bu gözlemler araç türlerine göre yapılmış ve toplam 487 adet devrede 6331 adet taşıtın gecikme gözlemi gerçekleştirilmiştir. Analiz sonuçları, DÖM modelinin, gerçek değerleri YSA modelinden yaklaşık 2 kat, analitik modellerden yaklaşık 5 kat daha düşük hata yüzdeleri ile tahmin ettiğini göstermiştir. Bu çalışma, derin öğrenme yaklaşımının, değişken zamanlama ile çalışan sinyalize kavşaklar için etkin bir performans ölçüm modeli olduğunu ortaya koymuştur.

#### Anahtar Kelimeler

“Gecikme modeli, Derin Öğrenme, Adaptif Sinyalizasyon Sistemleri”

#### Abstract

Signalized intersection management systems have become more efficient with the help of developments in communication and detector systems. Especially, Adaptive Signal Management Systems (ASMS) have planned intersections to adapt to variable traffic parameters. However, previous approaches developed to measure the efficiency of signalized intersections are not compatible with the continuous change of control parameters such as cycle length and phase plans. In this study, a delay estimation model (DÖM) has been developed for intersections managed with ASMS using the deep learning approach. The efficiency of the DÖM has been analyzed by comparing the performances with artificial neural network (ANN) models and analytical models. In addition, DÖM and ANN models were trained with different input variables and their performances were investigated. The data used for modeling were collected from the intersection managed by ASMS in Kırıkkale province by making observations. These observations were made according to vehicle types and delay observations of 6331 vehicles in a total of 487 cycles were made. Analysis results showed that the DÖM model predicts the actual delays with error percentages approximately 2 times lower than the ANN model, and approximately 5 times lower than the analytical models. This study revealed that DÖM is an effective performance measurement model for signalized intersections operating with variable timing.

#### Key Words

“Delay model, Deep Learning, Adaptive Signalization Systems”

## 1. Giriş

Son yıllarda artan nüfus ve kentleşme, ulaştırma sektörünü doğrudan etkilemektedir. Bu etki yolculuk talebi ve taşıt sayısında artışa yol açmaktadır. Trafik yoğunluğunun artması ise Ön Zamanlı Sinyal Sisteminin (ÖSS) kavşaklarda yetersiz kalmasına neden olmaktadır. Dolayısıyla yerel yönetimler, trafikte karşılaşılan sorunlara ileri teknolojik uygulamalar kullanarak çözümler üretmektedir. Birçok şehirde bulunan trafik kontrol merkezlerinde, kavşaklardan elde edilen verilerin işlenerek sinyalizasyon sisteminin yönetilmesini sağlayan yapılar bulunmaktadır. Bu yapılar adaptif kavşak kontrol sistemleri olarak adlandırılmakta olup, 2005 yılından itibaren ülkemizde akıllı ulaşım sistemlerinin bir parçası olarak kullanılmaktadır (Katanalp, 2018). Bu nedenle yerel yönetimler Adaptif Sinyal Yönetim Sistemlerini (ASYS) daha fazla tercih etmekte olup, gelecek yıllarda da ASYS'lerin daha yaygın kullanılması beklenmektedir. Diğer taraftan, sinyalize kavşakların performansının ölçülmesinde kullanılan ölçüt olan gecikme değerini tahmin etmek için geliştirilmiş Webster, HCM (Highway Capacity Manual), Avustralya (Akçelik) gibi analitik modeller, ÖSS için genelde tatmin edici sonuçlar üretmeyi başarabilmektedir. Ancak ASYS için gecikme ölçütünü istenilen isabette tahmin edebilen modellere ihtiyaç duyulmaktadır.

Saha ölçümleri, analitik yöntemler, simülasyon programları ve yapay zeka yöntemleri kullanılarak sinyalize kavşaklarda gecikme tahmini yapılabilmektedir. Gerçek gecikme değerleri sadece saha ölçümleri yapılarak tespit edilebilmekte olup, bu ölçümlerin yapılması oldukça zahmetli, zor ve zaman alan işlemlerdir. Çünkü bu işlemleri gerçekleştirmek için teknolojik aletlere ve insan gücüne gereksinim duyulmaktadır. Sinyalize kavşaklardaki trafik hacimlerinin gün geçtikçe artması kavşakların performansının arazi ölçümleri ile belirlenmesini güçleştirmektedir. Bu nedenle saha analizlerinin daha emniyetli, ucuz ve hızlı bir şekilde yapılması ve farklı trafik durumlarının kolayca karşılaştırılması amacıyla simülasyon teknikleri geliştirilmiştir (Akbaş, 2020). Simülasyon programları ile sinyalize kavşakların benzetimi yapılarak, ulaşım performansları ve kavşağın hizmet düzeyi kolayca etüt edilebilmektedir. Trafik mühendisliğinde kullanılan en popüler trafik simülasyon programları CORSIM ve VISSIM'dir. Ancak kavşağın karakteristik özelliklerinin tümüyle temsil edilmemesi, modelin fazla detaylandırılması, performans ölçümünde yanlış kıstasların kullanılması ve modelin geçerliliğinin sınanmaması nedeniyle simülasyon modelleri gerçek sonuçlardan sapabilmektedir (Ocakdan, 2010). Bu nedenle analitik modeller ve simülasyon programları ile ortaya çıkan eksiklikleri gidermek amacıyla yapay zeka yöntemleri ile oluşturulmuş ve gecikme tahmini ortaya koyan modellerin geliştirilmesine ihtiyaç duyulmaktadır.

ASYS'nin ÖSS'ye göre kavşak performansını arttırarak gecikmeleri ve seyahat süresini azalttığı yapılan bilimsel çalışmalarla kanıtlanmış (Tektaş vd., 2002) olmasına rağmen ASYS ile kontrol edilen kavşaklar için geliştirilmiş gecikme modelleri oldukça az sayıdadır. Bu nedenle bu çalışmada, analitik modeller (HCM ve Avustralya) ve yapay zeka modelleri (YSA ve DÖM) kullanılarak, ASYS ile yönetilen izole sinyalize kavşaklardaki taşıt gecikmelerini doğru olarak tahmin eden modeller geliştirilmiştir. Kırıkkale Sanayi kavşağından elde edilen devre bazlı ortalama taşıt gecikmeleri ana kol ve tali kol için ayrı ayrı hesaplanmıştır. Modellerin performansları kavşaktan elde edilen gerçek gecikme değerleri ile karşılaştırılarak, modellerin üstün ve zayıf yönleri ortaya konulmaya çalışılmıştır. Modellerin tahmin sonuçları ana kol ve tali kol için ayrı ayrı ortaya konmuştur. Yapay zeka ile geliştirilen modellerde iki farklı veri kümesi kullanılmıştır. İlk veri kümesinde (GD-1), kırmızı ve sarı süre, yeşil süre, devre süresi, yeşil sürenin devre süresine oranı, toplam taşıt sayısı, ağır ticari taşıt sayısı ve ağır ticari taşıt sayısının toplam taşıt sayısına oranı veri girişinde kullanılmıştır. İkinci veri kümesinde (GD-2) ise kırmızı ve sarı süre, toplam taşıt sayısı, ağır ticari taşıt sayısı veri girişinde kullanılmıştır. Tüm modellerde ana kol ve tali kol için veri setleri eğitim ve test verisi olmak üzere iki gruba ayrılmıştır. Veriler üzerinde 4-katlı çapraz doğrulama (ÇD) tekniği uygulanmıştır. Modellerin değerlendirilmesinde ortalama karesel hata (OKH), Ortalama Karesel Hataların Karekökü (OKHK) ve Ortalama Mutlak Yüzde Hata (OMYH) performans ölçütleri olarak seçilmiştir. Bu çalışmadaki önemli bir kısıt gecikme değerlerinin bir kavşaktan elde edilmiş olmasıdır. Özellikle gecikme verisinin kavşaklardan elde edilmesi zor bir süreç olup, bununla ilgili yerleşmiş bir veri kaynağı da mevcut değildir. Bu nedenle, çalışmadaki incelenen her bir taşıta ait gecikme verileri gözlem ve hesaplamalar sonucunda elde edilmiştir.

Bu makalenin devam eden bölümlerinde öncelikle literatür taraması ve analitik gecikme modellerine değinilmiştir. Daha sonra çalışma sahası ve verilerin toplanması hakkında bilgiler verilmiştir. Akabinde modellerin nasıl geliştirildiği hakkında bilgiler verilerek bulgular ortaya konmuştur. Son olarak ise sonuçlar verilerek önerilerde bulunulmuştur.

## 2. Literatür Taraması

### 2.1. Gecikme modelleri

Literatürde, sinyalize kavşaklardaki taşıt gecikmelerini yapay zekâ yöntemleri ile tahmin eden pek çok model yer almaktadır. Sinyalize kavşaklardaki taşıt gecikmelerini, yapay zekâ yöntemlerinden Bulanık Mantık (BM) ile tahmin eden Qiao vd. (2002) ve Murat (2006), ileri beslemeli YSA kullanarak tahmin eden Başkan (2004), hem BM hem de YSA modelleri ile tahmin eden Murat (2006) ve Mutlu&Yavuz (2008), analitik modellerle kıyaslandığında gerçek gecikme değerlerine daha yakın tahminler ortaya koymuşlardır. Atalay (2004) ve Hasiloğlu vd. (2014), uyarlamalı ağ tabanlı nöro-bulanık çıkarım sistemi (ANFIS) modeli ile sinyalize kavşaklardaki taşıt gecikmelerini analitik modellerden daha iyi tahmin etmiştir. Akgüngör (2004) sinyalize kavşaklarda gecikmeyi tahmin eden zamana bağlı bir matematiksel model geliştirmiştir. Literatürde yer alan diğer modeller bulguları ile birlikte kronolojik sırayla Tablo 1'de gösterilmektedir.

Tablo 1. Literatür

Literatür	Model/Uygulama	Bulgular
(Doğan vd.,2016)	YSA	Sinyalize kavşaklardaki taşıt gecikmesi ve durma sayısını tahmin eden iki model YSA ile geliştirilmiştir. YSA-gecikme modelinin, YSA-durma modelinden daha iyi performans gösterdiği belirlenmiştir.
(Korkmaz,2016)	Diferansiyel gelişim algoritması (DGA), Yapay arı kolonisi algoritması (YAKA)	Farklı formlarda oluşturulan gecikme modellerinin DGA ve YAKA ile optimizasyonu gerçekleştirilmiştir. Yarı kuadratik formda oluşturulan ve DGA'ya göre optimize edilen modelin gecikme değerlerini akın tahmin ettiği tespit edilmiştir
(Preethi vd., 2016)	Analitik modeller, YSA	YSA ile üç ayrı trafik durumu için modellenmiştir. YSA modelinin analitik modellerden daha iyi gecikme tahmini yaptığı ortaya konmuştur.
(Masouleh,2017)	Bluetooth teknolojisi	Bluetooth teknolojisi ile gecikme ve seyahat süre tahmin edilmiştir. Yöntemin sinyalize kavşaklardaki kontrol gecikmesini, gerçek gecikme değerlerine yakın tahmin ettiği tespit edilmiştir.
(Garshasebi,2018)	Lineer regresyon (LR) Destek vektör regresyonu (SVR) Rassal orman regresyonu (RF)	LR ve RF ile oluşturulan modellerin taşıt gecikmelerini daha doğru tahmin ettiği tespit edilmiştir.
(Balta&Özçelik, 2019)	Yazılım tanımlı ağlar (SDN) Karıncı kolonisi algoritması (KKA)	SDN temelli KKA'nın ortalama gecikmeyi, geleneksel tekniklerden %15-22 hesaplamalı tekniklerden ise %7-12 daha iyi tahmin ettiği tespit edilmiştir.
(Harb vd.,2019)	Bulanık mantık (BM)	BM yönteminin aynı yeşil sürede daha fazla taşıttan kavşaktan geçmesini sağladığı ve sabit süreli denetimden üstün olduğu tespit edilmiştir.
(Bağdatlı, 2020)	Gen ekspresyonu programlama (GEP)	GEP modelleri analitik modellerden daha başarılı sonuçlar üretmiş olup YSA ile Bulanık-Ağ modelleri kadar tutarlı sonuçlar ortaya koymuştur.

## 2.2. Adaptif sinyal yönetim sistemleri

Günümüzde kullanılan birçok ASYS türü model temelli çalışmaktadır. Model temelli ASYS'ler trafiğin mevcut durumunu tahmin etmek için makroskobik, mezoskobik ve mikroskobik modeller kullanmaktadır. Tahmin değerleri sinyal sürelerini ayarlamak için bir girdi olarak kullanılmaktadır. Model temelli olmayan ASYS'ler ise, trafik koşullarının değişimini tanımlayan parametreler arasındaki fonksiyonel ilişki üzerinde çalışmakta olup, önceki aralıkta ölçülen trafiğin geri bildirimlerini kullanmaktadır (Aavani vd.,2017). Sinyal kontrolü üzerine bilimsel araştırmalar yapan ülkeler kendilerine özgü sinyal kontrol sistemlerini hayata geçirmişlerdir (Akbaş&Akdoğan,2001).

Literatüde ASYS ile kontrol edilen kavşaklar üzerine yapılmış önemli sayıda çalışma bulunmaktadır. Shoufeng vd. (2008), izole sinyalize bir kavşağın performansını, sabit süreli sinyal denetimi ve Q-learning algoritması temelli ASYS'i karşılaştırarak analiz etmiştir. Analiz sonuçlarına göre Q-learning tabanlı yöntemin gecikmeleri azalttığı tespit edilmiştir. Samadi vd. (2012), bir ASYS olan SCATS'ın performansını, trafik uyarımlı kontrol sisteminin performansı ile karşılaştırmıştır. Karşılaştırma sonuçlarına göre SCATS'ın sürekli olarak taşıtların seyahat süreleri ile ortalama durma ve yaklaşım gecikmelerini azalttığı belirlenmiştir. Gündoğan vd. (2014), ATAK isimli bir ASYS geliştirmişlerdir. Bu sistemde genetik algoritma (GA) ve bulanık mantık (BM) optimizasyon tekniği kullanılmıştır. Sinyal sürelerini optimize etmek için GA, kontrol cihazlarının çalışması sırasında meydana gelebilecek istisnai durumları kontrol etmek için ise BM kullanılmıştır. Bu çalışmada ATAK ile optimum sabit süreli kontrol sisteminin performansı karşılaştırılmış olup ATAK ile seyahat sürelerinin yaklaşık %15 oranında kısaldığı tespit edilmiştir. Yulianto&Sutanto (2014), BM temelli bir ASYS modeli geliştirmiş olup, ASYS'nin etkinliği VISSIM simülasyon programı ile ölçülmüştür. Bu çalışma ile ASYS'nin, yüksek trafik hacimlerinde kavşak performansını arttırdığı ortaya konmuştur. Studer vd. (2015), ASYS'lerden SCATS, SCOOT, INSYNC ve UTOPIA trafik kontrol sistemlerinin performansları karşılaştırılmıştır. SCATS ve UTOPIA'nın metropol alanlarda, SCOOT'ın kentsel ve bölgesel alanlarda, INSYNC'nin ise sınırlı sayıdaki kavşaklarda kullanımının uygun olacağı belirlenmiştir. Bu çalışmada INSYNC'in performansının diğer ASYS'lerden daha yüksek olduğu ve gecikmeleri ortalama %30-70 arasında azalttığı tespit edilmiştir. Jin& Ma (2015), bir makine öğrenmesi yaklaşımı olan pekiştirmeli öğrenme yöntemi ile grup bazlı faz planları kullanılan bir ASYS modeli geliştirmişlerdir. Bu çalışmada iki farklı öğrenme algoritması olan SARSA ve Q-learning, SUMO simülasyon programı ile oluşturulmuş olan 4-kollu bir kavşak üzerinde test edilmiştir. Ayrıca grup bazlı sabit süreli kontrol sistemi, grup bazlı adaptif kontrol sistemi ile kıyaslanmıştır. Ortalama gecikmede SARSA (grup bazlı adaptif kontrol)'nin en iyi performansı gösterdiği, Q-learning (grup bazlı adaptif kontrol)'nin en iyi ikinci performansı gösterdiği, grup bazlı sabit süreli kontrolün ise en kötü performansı gösterdiği tespit edilmiştir. Odeh vd. (2015), BM ve GA'yı birleştiren hibrit bir algoritmayı ASYS üzerinde

kullanmışlardır. Ön zamanlı sinyal denetim sistemine göre hibrit algoritmanın %34'e varan iyileşme sağladığı tespit edilmiştir. Hibrit algoritmanın BM tabanlı denetim sistemine göre de %31'e varan iyileşme sağladığı belirlenmiştir. Adebıy vd. (2018), yapay zeka öğrenme algoritmalarından biri olan Yapay Arı Kolonisi algoritması (YAKA) ile fazların sinyal sürelerini optimize eden bir ASYS geliştirmiştir. Geliştirilen bu sistemin ortalama bekleme sürelerini azalttığı belirlenmiştir. Manandhar&Joshi (2018), yapay zeka algoritmalarından parçacık sürü optimizasyonu (PSO) ve istatistiksel çoklamının beraber kullanıldığı bir hibrit algoritmayı ASYS üzerinde test etmişlerdir. Hibrit algoritmanın ön zamanlı sistemlere göre bekleme sürelerini azalttığı tespit edilmiştir. Wu vd. (2019), Guguk Kuşu Arama (GKA) algoritması ile optimize edilmiş ve BM kontrolüne dayanan bir model geliştirmişlerdir. Bu modelin performansı, gerçek zamanlı sinyal kontrol sistemi ile yönetilen dört kollu kavşak üzerinde simülasyon deneyleri ile test edilmiştir. Ön zamanlı denetim sistemlerine kıyasla söz konusu modelin ortalama taşıt gecikmelerini azalttığı belirlenmiştir.

### 3. Analitik Gecikme Modelleri

Sinyalize kavşaklarda gecikmeyi tahmin etmek için farklı varsayımlara dayanan ve çeşitli trafik durumları için çok sayıda analitik model geliştirilmiştir. Bu modeller üç gruba ayrılmaktadır. Bunlardan birincisi doygun altı durumlar için Webster, Tanner ve Miller tarafından geliştirilen stokastik sabit ve dengeli gecikme modelleri, ikincisi doygun üstü durumlar için May&Keller, Neuberger ve Pignataro tarafında geliştirilen deterministik gecikme modelleri, üçüncüsü ise doygun altı ve doygun üstü durumları kapsayan ve Burrow, Catling, Brilon, Wu, Akçelik, Teply, HCM ve Kimber tarafından geliştirilen zaman esaslı gecikme modelleridir (Doğan vd., 2016). Söz konusu analitik modellerden yaygın olarak kullanılanlar Webster, HCM ve Avustralya (Akçelik) gecikme bağıntılarıdır.

Webster (Webster,1958), gecikme modelinde taşıt başına düşen gecikmeyi (d) üniform ve rastgele gecikmelerin toplamı olarak Denklem 1'deki şekliyle ifade etmiştir.

$$d = \left( \frac{0,5 C [1 - (\frac{g}{C})]^2}{[1 - (\frac{g}{C})x]} \right) + \left( \frac{x^2}{2v(1-x)} \right) \quad (1)$$

Burada,

- C : devre süresi (sn.),
- g : şerit başına etkili yeşil süre (sn.),
- x : doygunluk derecesi (v/c),
- v : trafik hacmi (ta/st),
- d : taşıt başına düşen gecikme (sn/ta),

olarak ifade edilmektedir.

HCM (HCM,2000) gecikme modelinde, bir şeritteki ortalama gecikmenin tespit edilmesi için sırasıyla üniform gecikme ( $d_1$ ) Denklem 2, taşma gecikmesi ( $d_2$ ) Denklem 3, başlangıç kuyruğundan dolayı tüm araçlara etkiyen gecikme değeri ( $d_3$ ) ve taşıt başına kontrol gecikmesi (d) Denklem 4 yardımıyla hesaplanır.

$$d_1 = 0,50 C \frac{(1 - \frac{g}{C})^2}{1 - [\min(1,x) * \frac{g}{C}]} \quad (2)$$

$$d_2 = 900 T \left[ (x - 1) + \sqrt{(x - 1)^2 + \frac{8kIx}{cT}} \right] \quad (3)$$

$$d = d_1(PF) + d_2 + d_3 \quad (4)$$

Burada,

- C : devre süresi (sn.),
- g : şerit başına etkili yeşil süre (sn.),
- x : doygunluk derecesi (v/c),
- $d_1$  : üniform gecikme (sn/ta),
- T : analiz periyodu (st),
- k : artan gecikme faktörü,
- I : filtreleme faktörü,
- c : şerit kapasitesi (ta/st),

$d_2$  : taşma gecikmesi (sn/ta),

PF : üniform gecikme dizisi düzeltme faktörü,

$d_3$  : başlangıç kuyruğundan dolayı tüm araçlara etkiyen gecikme değeri (sn/ta),

$d$  : taşıt başına kontrol gecikmesi (sn/ta),

olarak ifade edilmektedir.

Denklem 3’de yer alan artan gecikme faktörü (k), sinyalizasyon türünün (ön zamanlı, uyarmalı vb.) etkisini gecikmeye dahil etmektedir. ÖSS’de, rastgele gelişlere bağlı kuyruklanma esasına göre k değeri 0,50 olarak kullanılmaktadır. Ancak uyarmalı sinyal yönetim sistemleri, yeşil süreyi trafik talebine göre uyarlayabildiği için artan gecikmeyi azaltma becerisine sahiptir. Gecikmenin azalması ise birim uzatma süresi ve  $x$ ’e bağlıdır. Birim uzatma süresi azaldıkça, artan k ve  $d_2$  değeri de azalmaktadır. Ancak  $x=1$  olduğunda uyarmalı sinyal yönetim sistemi, ÖSS gibi davranmaya başladığı için k değeri 0,50 olmaktadır. Ön zamanlı ve uyarmalı sinyal yönetim sistemlerine göre k değerleri Tablo 2’de yer almaktadır. HCM modelinde, ana kol için k değeri 0,5 alınmış olup, tali kol için k değerleri, Tablo 2 yardımıyla bulunarak gecikmeler hesaplanmıştır.

**Tablo 2.** Sinyalizasyon türüne göre artan gecikme faktörü (k) değerleri (HCM,2000).

Birim Uzatma Süresi (sn.)	Doğunluk Derecesi (x)					
	$\leq 0,50$	0,60	0,70	0,80	0,90	$\geq 1,00$
$\leq 2,00$	0,04	0,13	0,22	0,32	0,41	0,50
2,50	0,08	0,16	0,25	0,33	0,42	0,50
3,00	0,11	0,19	0,27	0,34	0,42	0,50
3,50	0,13	0,20	0,28	0,35	0,43	0,50
4,00	0,15	0,22	0,29	0,36	0,43	0,50
4,50	0,19	0,25	0,31	0,38	0,44	0,50
5,00	0,23	0,28	0,34	0,39	0,45	0,50
Ön zamanlı sistemler	0,50	0,50	0,50	0,50	0,50	0,50

Avustralya (Akçelik) gecikme modelinde, kuyruğun “0” olduğu doğunluk derecesi ( $x_0$ ) Denklem 5’deki şekliyle, taşıtların ortalama gecikmesi (d) ise üniform ve taşma gecikmesinin toplamı olarak Denklem 6’daki şekliyle ifade edilmektedir (Roess vd., 2011).

$$x_0 = 0,67 + \left[ \frac{sg}{600} \right] \quad (5)$$

$$d = \frac{c(1-\lambda)^2}{2[1-(\lambda x)]} + 900 T \left[ (x - 1) + \sqrt{(x - 1)^2 + \frac{12(x-x_0)}{cT}} \right] \quad (6)$$

Burada,

$x_0$  :kuyruğun 0 olduğu doğunluk derecesi,

s : doğun akım oranı (ta/st/şerit),

g : şerit başına etkili yeşil süre (sn.),

C : devre süresi (sn.),

$\lambda$  : etkin yeşil sürenin devre süresine oranı,

x : doğunluk derecesi (v/c)

T : analiz periyodu

c : şerit kapasitesi (ta/st),


d : toplam gecikme (sn/ta),

olarak ifade edilmektedir.

#### 4. Verilerin Toplanması ve Modellerin Geliştirilmesi


##### 4.1. Uygulama kavşağı ve verilerin toplanması

Bu çalışmada kullanılan trafik verileri, Kırıkkale ili sınırlarında bulunan Yeni Sanayi Kavşağı'ndan toplanmıştır. Bu kavşak D-200 karayolu üstünde olup ASYS ile yönetilmektedir. Kavşak 4-kollu bir geometriye sahiptir. Ana arterlerde bulunan Ankara Caddesi (Kırıkkale İstikameti) ve Ankara Caddesi (Ankara İstikameti) yaklaşım kollarında 3.5' metre genişliğinde 4 adet kavşağa giriş şeridi bulunmaktadır. Bu şeritlerden 2 adedi düz giden taşıtlara, 1 adedi korumalı sol dönüş cebi olarak sola dönen taşıtlara, 1 adedi ise sağa dönen taşıtlara hizmet etmektedir. Ana arterlerde 2 adet de kavşaktan çıkış şeridi vardır. Tali arterlerde bulunan 254. Sokak ve Yavuz Sultan Selim Caddesi yaklaşım kollarında 3.5'er metre genişliğinde 3 adet kavşağa giriş şeridi bulunmaktadır. Bu şeritlerden 1 adedi düz giden taşıtlara, 1 adedi sola dönen taşıtlara, 1 adedi ise sağa dönen taşıtlara hizmet etmektedir. Tali arterlerde 2 adet de kavşaktan çıkış şeridi bulunmaktadır. Şekil 1' de Yeni Sanayi Kavşağı'nın şerit kullanım şeması bulunmaktadır. Bu şemada yaklaşım kollarının kavşağa giriş ve çıkış referans noktaları, sinyalizasyon sisteminden olan mesafeleri ile birlikte gösterilmektedir.



Şekil 1. Yeni sanayi kavşağı şerit kullanım şeması

Çalışma için seçilen Yeni Sanayi Kavşağı gerçek zamanlı adaptif kavşak yönetim sistemi ile denetlenmektedir. Kavşakta alan algılaması yapan bir adet balıkgözü kamera ve her şerit için birer tane de detektör bulunmaktadır. Elde edilen veriler Şekil 2' de görüldüğü gibi, AIMSUN programına gönderilmektedir. Bu veriler bilgisayar ortamında AIMSUN tarafından işlenerek kavşaktaki faz ve çevrim süreleri belirlenmektedir. Gerçek zamanlı olarak belirlenen faz ve çevrim süreleri kavşak kontrol cihazına aktarılarak sinyal süreleri tespit edilmektedir. Kavşağın kontrolü dört fazlı olarak gerçekleştirilmektedir. Sanayi kavşağında sırasıyla A, B, C ve D faz planları çalışmaktadır. Kavşağın faz planı Şekil 2'de gösterilmektedir.



Şekil 2. Yeni sanayi kavşağı ASYS yöntem şeması ve faz düzeni

Kırıkkale Sanayi Kavşağı'nda bulunan detektörler sayesinde taşıtın hangi yönden geldiği ve hangi yöne gittiği verisi elde edilmektedir. Ayrıca kavşak içi tıkanıklık, kavşağa girişlerde yoğunluk ve kavşakta geçirilen süre gibi çok önemli veriler anlık olarak toplanmaktadır. Detektörler, taşıt tipine göre sayımları da yapmakta olup, böylece taşıtların sınıflarına göre kavşak içindeki seyirinden elde edilen verilere göre kavşağın karakteristiği belirlenebilmekte ve simülasyona yansıtılabilmektedir. Sonuç olarak detektörlerden ve kavşak kontrol cihazlarından alınan trafik verileri, AIMSUN trafik modelleme ve simülasyon programı kullanılarak ve anlık sinyalizasyon verileri ile eşleştirilerek, yaklaşım kollarında bulunan kırmızı, sarı ve yeşil süreler gerçek zamanlı olarak ayarlanmaktadır.

Kavşaktaki gecikme gözlemleri, hem kavşaktaki tüm yaklaşım kollarını ve bu yaklaşım kollarındaki taşıtların kavşağa giriş ve kavşaktan çıkış referans noktalarını gören bir adet balık gözü video kamera yardımıyla gerçekleştirilmiştir. Şekil 3' de video kamera görüntüsü yer almaktadır. Gözlemler hafta içi perşembe ve cuma iki gün, hafta sonu ise cumartesi bir gün olmak üzere toplam 3 gün süre ile yapılmıştır. Böylece, farklı trafik akım örüntüsü gösteren hafta içi ve hafta sonu günleri modelin eğitilmesine katılmıştır.



Şekil 3. Video kamera görüntüsü

Ele alınana kavşak, birçok ili birbirine bağlayan Türkiye'nin önemli ve yoğun kavşaklarından biridir. Bu nedenle günün önemli bir bölümünde yoğunluk ana kollarında yüksek olmaktadır. Fakat, video kameranın tipinden dolayı video işleme tekniği ile otomatik sayım yapabilen programlar kullanılamamış, gözlem ile sayımlar yapılmıştır. Bu nedenle, ana kollarından bir tanesi için sayım işlemi gerçekleştirilmiştir ve tüm gün yerine seçilen devreler analizler için kullanılmıştır. Devre seçiminde, taşıt kuyruğunun giriş referans noktasını geçmediği devreler ele alınmıştır. Böylece gözlemler sırasında oluşabilecek karışıklığın önüne geçilmesi amaçlanmıştır. Bu yaklaşım kollarına ait devre adedi ve taşıt tiplerine göre ortalama bir saatlik akım oranları Tablo 3' de verilmiştir.

**Tablo 3.** Taşıt tiplerine göre yaklaşım için kullanılan devre adedi ve akım oranları

Yaklaşım Kolu	Devre Sayısı (adet)	Ağır Ticari Taşıt Akım Oranı	Hafif Ticari Taşıt Akım Oranı	Otomobil Akım Oranı	Toplam Akım Oranı
Ankara Caddesi (Kırıkkale İstikameti)	40	179	133	1406	1718
254. Sokak Tarafı	240	10	23	99	132
Yavuz Sultan Selim Caddesi Tarafı	207	10	15	48	73
<b>Toplam</b>	<b>487</b>	<b>199</b>	<b>171</b>	<b>1553</b>	<b>1923</b>

Bir kavşaktaki gecikme, kontrol sisteminden dolayı oluşan fazladan beklemedir. Bir taşıtın giriş ve çıkış referans noktasından geçtiği zaman sırasıyla,  $t_g$  ve  $t_c$  olsun. Bu durumda, yaklaşım koluna geçiş hakkı verilmiş ve taşıt kuyruğu yok ise, bu taşıtın kavşağı serbest boşaltma süresi,  $t_s = t_c - t_g$  olur. Diğer taraftan taşıt, geçiş hakkına sahip olmayan bir kolda kontrol sisteminden kaynaklanan bir gecikmeye ( $d$ ) maruz kalır. Kavşağı kontrollü boşaltma süresi,  $t_k$  ise; bu durumda taşıt gecikmesi  $d = t_k - t_s$  olacaktır.  $t_s$  değerini tespit edebilmek için, taşıtların, kolun geçiş hakkına sahip olduğu ve taşıt kuyruğunun olmadığı durumlar için kavşağı serbest boşaltma süresi ( $t_s$ ) farklı taşıt türlerine göre gözlenmiş ve Tablo 4’ de sunulmuştur.

**Tablo 4.** Bir devredeki taşıt gecikmesi hesabı için örnek durum

Yaklaşım Kolu	Video Kayıt Zamanı						
	Taşıt Cinsi	Taşıt Hareket Yönü	Giriş Zamanı (tg)	Çıkış Zamanı (tc)	$t_s$ (sn.)	Kavşak Boşaltma Süresi (sn.)	Taşıt Gecikmesi (sn.)
Ankara Caddesi (Kırıkkale İstikameti)	Otomobil	Düz	00:53:07	00:54:25	78	7	71
	Ağır Ticari Taşıt	Düz	00:38:00	00:39:25	85	10	75
	Hafif Ticari Taşıt	Düz	00:45:08	00:45:20	12	8	4
Yavuz Sultan Selim Caddesi	Otomobil	Sol	00:14:02	00:15:45	103	10	93
	Ağır Ticari Taşıt	Sol	00:12:49	00:15:54	185	18	167
	Hafif Ticari Taşıt	Düz	00:15:03	00:15:51	48	13	35
254. Sokak	Otomobil	Düz	00:07:22	00:09:20	118	10	108
	Ağır Ticari Taşıt	Sol	00:07:11	00:09:25	134	18	116
	Hafif Ticari Taşıt	Sol	00:07:15	00:09:14	119	13	106

Gecikme değerleri, kavşağın sahip olduğu sinyal ve trafik değişkenlerine bağlı olarak değişmektedir. Bu nedenle adaptif olarak yönetilen kavşağa ait değişkenler devre bazlı ele alınmış ve değişken isimleri numaralandırılarak Tablo 5’ de verilmiştir. Veriler ana kol (Ankara Caddesi) ve tali kol (254. Sokak ve Yavuz Sultan Selim Caddesi) olmak üzere iki grup halinde toplanmıştır. Veriler hem ana kol hem de tali kol için 7 adet kategoride toplanmış olup bu kategoriler Tablo 5’ de gösterilmektedir.

**Tablo 5.** Girdi değişkenleri

Girdi Değişkenleri Numarası (GDN)	Girdi Değişkeni Adı
1	Kırmızı ve sarı süre
2	Yeşil süre (g)
3	Devre süresi (c)
4	Yeşil sürenin devre süresine oranı (g/c)
5	Toplam taşıt sayısı (TTS)
6	Ağır ticari taşıt sayısı (ATS)
7	Ağır ticari taşıt sayısının toplam taşıt sayısına oranı (ATS/TTS)

Toplanan verilerde düzenli eğilimlerden büyük ölçüde sapmış aykırı verilere rastlanmış olup aykırı verileri veri setinden çıkartmak için temizleme tekniği olarak SPSS istatistik programından faydalanılmıştır. Gecikme dahil 8 kategorili verilerin bulunduğu veri setindeki çok değişkenli aykırı değerleri bulmak için değişkenlerin puanlarının kombinasyonunda olağan dışı olan puanlar tespit edilmiştir. Bunu yapabilmek için SPSS programının doğrusal regresyon analizi kısmı kullanılmış olup, bağımlı ve bağımsız değişkenler tespit edilerek



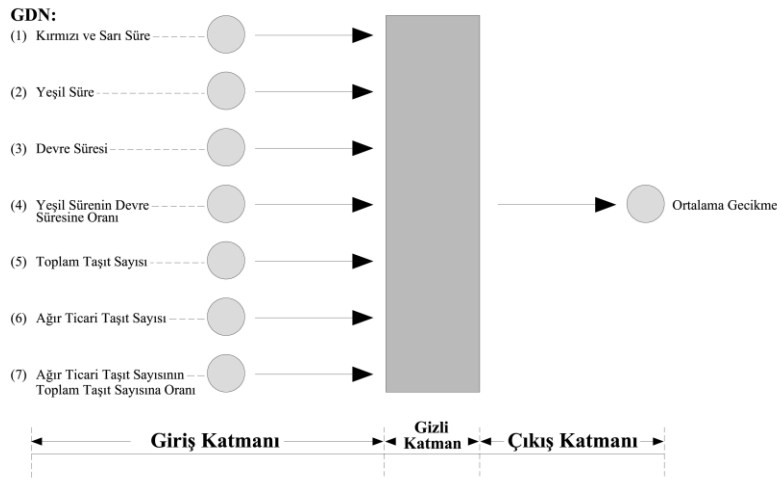
her bir devre için Mahalanobis mesafeleri oluşturulmuştur. Mahalanobis uzaklığı, çok değişkenli aykırı değer tespitinde kullanılan tekniklerden biridir (Esen&Timor,2019). Doğrusal regresyon analizinde bağımlı değişken gecikme olarak girilmiş olup, kırmızı ve sarı süre, yeşil süre, devre süresi, yeşil sürenin devre süresine oranı, toplam taşıt sayısı, ağır ticari taşıt sayısı, ağır ticari taşıt sayısının toplam taşıt sayısına oranı ise bağımsız değişkenler olarak girilmiştir. Daha sonra ise Mahalanobis mesafe puanları tekrar analiz edilerek en yüksek ve en düşük puanlar belirlenmiştir. Böylece hangi değerlerin çoklu değişkenlerde aykırı değer olduğu tespit edilmiştir. Sonuç olarak 254. sokak yaklaşım kolu için toplanan ham veri sayısı 240 iken bu sayı aykırı veriler çıkartıldıktan sonra 230'e düşmüştür. Yine Yavuz Sultan Selim Caddesi yaklaşım kolu için toplanan ham veri sayısı 207 iken bu sayı aykırı veriler çıkartıldıktan sonra 206'ya düşmüştür. Ankara Caddesi yaklaşım kolunda ise aykırı veriye rastlanmamıştır.

#### 4.2. YSA ile model geliştirilmesi

Yapay sinir ağları (YSA), insan beynindeki biyolojik nöronların çalıştığı mekanizmalardan ilham alan ve insan beyninin öğrenme fonksiyonunu örnekler yardımı ile gerçekleştiren bilgisayar sistemleridir (Ding, 2007; Öztemel, 2006). YSA, verilerden elde ettikleri bilgiler ile insan beyninin fonksiyonel özelliklerine benzer bir şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon yapabilmektedir (Öztemel, 2006). Nöronlar içeren sinir hücrelerinin çeşitli şekillerde birbirine bağlanması ile oluşan YSA üç ana katmandan oluşmaktadır. Bu katmanlar giriş katmanı, gizli (ara) katman ve çıkış katmanı olarak adlandırılmaktadır. Giriş katmanında, yapay sinir ağına dışarıdan gelen veriler bulunmaktadır. Giriş katmanından çıkan verilerin iletiildiği ve işlendiği katmana gizli (ara) katman denmekte olup, YSA ile oluşturulan mimarilerde hiç gizli (ara) katman bulunmadığı gibi birden çok gizli (ara) katman da bulunabilmektedir. Gizli (ara) katman veya katmanlardan gelen bilgiler ile ağıdaki çıktıları üreten katmana ise çıkış katmanı denmektedir.

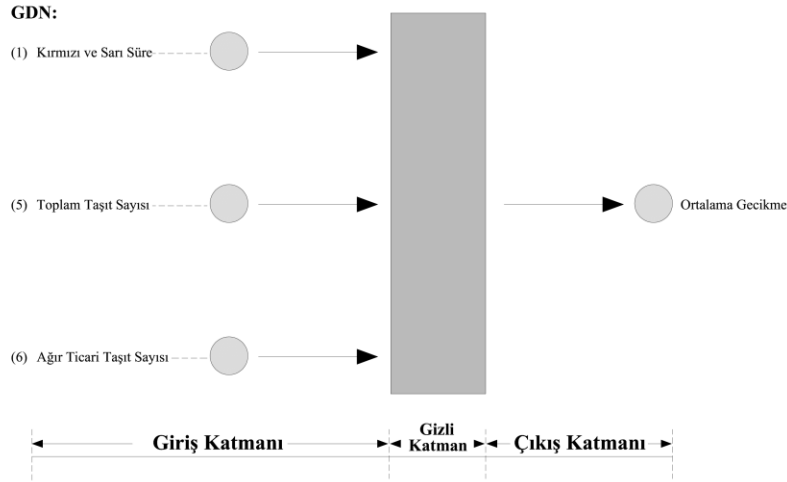
Bu çalışmada YSA modeli ileri beslemeli geri yayılım sinir ağı kullanılarak modellenmiştir. Bu modelde 1 adet giriş katmanı, 1 adet gizli katman ve 1 adet te çıkış katmanı kullanılmıştır. Gizli katmandaki nöron sayısı 1'den 50'ye kadar artırılarak model test edilmiştir. Böylelikle 50 adet senaryo oluşturulmuş olup, bu senaryoların performanslarının karşılaştırılması yapılarak en uygun gizli katman nöron sayısı belirlenmiştir.

YSA modelinin eğitilmesinde girdi parametreleri olarak Şekil 4 ve 5' de sunulan iki ayrı girdi kümesi (GD-1 ve GD-2) kullanılmıştır. Tüm girdi değişkenleri (GDN:1,2,3,4,5,6,7) arasında korelasyon analizi yapılmış olup, böylece değişkenler arasındaki doğrusal ilişki irdelenmiştir. Yapılan korelasyon analizi sonucunda kırmızı ve sarı süre (GDN:1), toplam taşıt sayısı (GDN:5) ve ağır ticari taşıt sayısı (GDN:6) arasında bir ilişkiye rastlanmıştır. Bu nedenle veri kümesi tüm girdi değişkenlerini içeren GD-1'e göre ve kırmızı ve sarı süre, toplam taşıt sayısı, ağır ticari taşıt sayısını içeren GD-2'ye göre iki gruba ayrılmıştır. İlk veri kümesinde (GD-1), Şekil 4' de belirtilen değişkenler YSA'nın eğitilmesinde girdi parametreleri olarak kullanılmıştır. Ortalama gecikme ise çıkış parametresi olarak kullanılmıştır.



Şekil 4. GD-1'e göre YSA modeli parametreleri

İkinci veri kümesinde (GD-2), Şekil 5'de belirtilen değişkenler YSA'nın eğitilmesinde girdi parametreleri olarak kullanılmıştır. Ortalama gecikme ise çıkış parametresi olarak kullanılmıştır.



Şekil 5. GD-2'ye göre YSA modeli parametreleri

YSA modelinde kullanılan geri yayılım algoritması, tekrarlı öğrenme sergileyen ve daha doğru tahmin sonuçları ortaya koyan bir metottur (Siregar&Wanto, 2017). Bu nedenle YSA modelinde GD-1 ve GD-2'den oluşan veri kümelerini eğitmek için yapay sinir ağlarının eğitilmesinde geri yayılım algoritması kullanılmıştır. YSA'ların eğitilmesinde sağladığı hız ve kararlılık nedeniyle Levenberg–Marquardt (LM) algoritması tercih edilmiştir (Çavuşlu vd., 2012). Ağın eğitiminde ana kol için 40 adet veri, tali kol için ise 436 adet veri kullanılmıştır.

Literatürde yapay zeka modellerinin başarısının değerlendirilmesinde K-katlamalı çapraz doğrulama (ÇD) yöntemi sıklıkla uygulanmaktadır (Anguita vd., 2012). Bu nedenle ana kol ve tali koldaki veriler üzerinde K-katlamalı ÇD yöntemi uygulanmıştır. Bu yöntemde K değeri 4 olarak (K=4) seçilmiş olup veri kümesi 4 eşit parçaya bölünmüştür. Ana koldaki 40 adet veri ve tali koldaki 436 adet veri dört gruba ayrılmıştır. YSA modelinde K-katlamalı ÇD yöntemi kullanılarak tüm veri üzerinde hem test hem de eğitim işlemi yapılmıştır.

Eğitim ve test veri setlerinde kırmızı süre, yeşil süre, devre süresi, yeşil süre/devre süresi, TTS, ATS, ATS/TTS ve gecikme parametreleri yer almakta olup, örnek olarak 10 adet eğitim ve test verisi Tablo 6' da gösterilmektedir.

Tablo 6. YSA modeli örnek eğitim ve test verileri

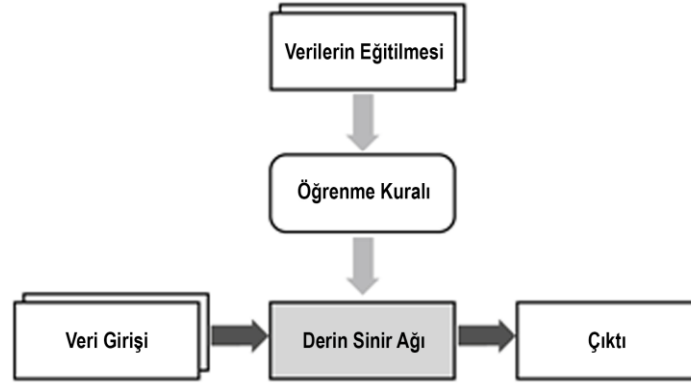
Kırmızı Süre (sn)	Yeşil Süre (sn)	Devre Süresi (sn)	Yeşil Süre / Devre Süresi	TTS (adet)	ATS (adet)	ATS / TTS	Gecikme (sn/ta)
66	143	209	0.68	87	16	0.18	22.69
81	136	217	0.63	88	8	0.09	30.76
74	138	212	0.65	89	12	0.13	26.89
89	135	224	0.60	94	3	0.03	29.98
75	127	202	0.63	95	11	0.12	24.62
70	150	220	0.68	97	8	0.08	17.30
70	128	198	0.65	98	9	0.09	26.77
90	118	208	0.57	98	6	0.06	28.76
76	147	223	0.66	99	16	0.16	18.20
82	126	208	0.61	102	14	0.14	35.45

Yapay sinir ağlarının eğitim ve test işleminde Matlab R2018b paket programının yapay sinir ağları araç kutusu (Neural Network toolbox) kullanılmıştır. Ana kol ve tali kolda hem GD-1'e göre hem de GD-2'ye göre YSA modeli oluşturulmuştur. Sonuç olarak YSA modeli ile bulunan gecikme değerleri ile gerçek gecikme değerleri karşılaştırılmış olup, mukayese yapılırken performans ölçütleri olan OKH, OKHK ve OMYH değerleri hesaplanmıştır. 4 farklı veri kümesi ile çalıştırılan YSA modelinin performans sonuçları ayrı ayrı 4 sonuç şeklinde elde edilmiş olup, genel bir sonuç bulmak için bu sonuçların aritmetik ortalaması alınmıştır.

#### 4.3. Derin öğrenme ile model geliştirilmesi

Beynin yapısal ve işlevsel özelliklerinden esinlenilerek tasarlanmış, çok katmanlı ağ yapıları olan yapay sinir ağları üzerinde çalışan algoritmalar ve modeller kümesine Derin Öğrenme denir (Akbaş, 2018). Derin öğrenme makine öğrenmesinin bir alt dalı olup, derin kelimesi birden fazla gizli katmanı ifade etmektedir. Nitekim YSA modellerinde bir veya iki gizli katman ile öğrenme sağlanırken

Derin Öğrenme modellerindeki gizli katman sayıları oldukça fazladır (Özdağ, 2019). Tarihte ilk derin öğrenme algoritması 1965 yılında Ivakhnenko ve Lapa tarafından yayınlanmıştır. Bu çalışmada çok katmanlı ağ mimarisi kullanılmış olup, her katmandaki en iyi özellikler bir sonraki katmana iletilmiştir (Şeker vd., 2017). Şekil 6’da makine öğrenmesi ile derin öğrenme arasındaki ilişki gösterilmektedir (Kim, 2017).

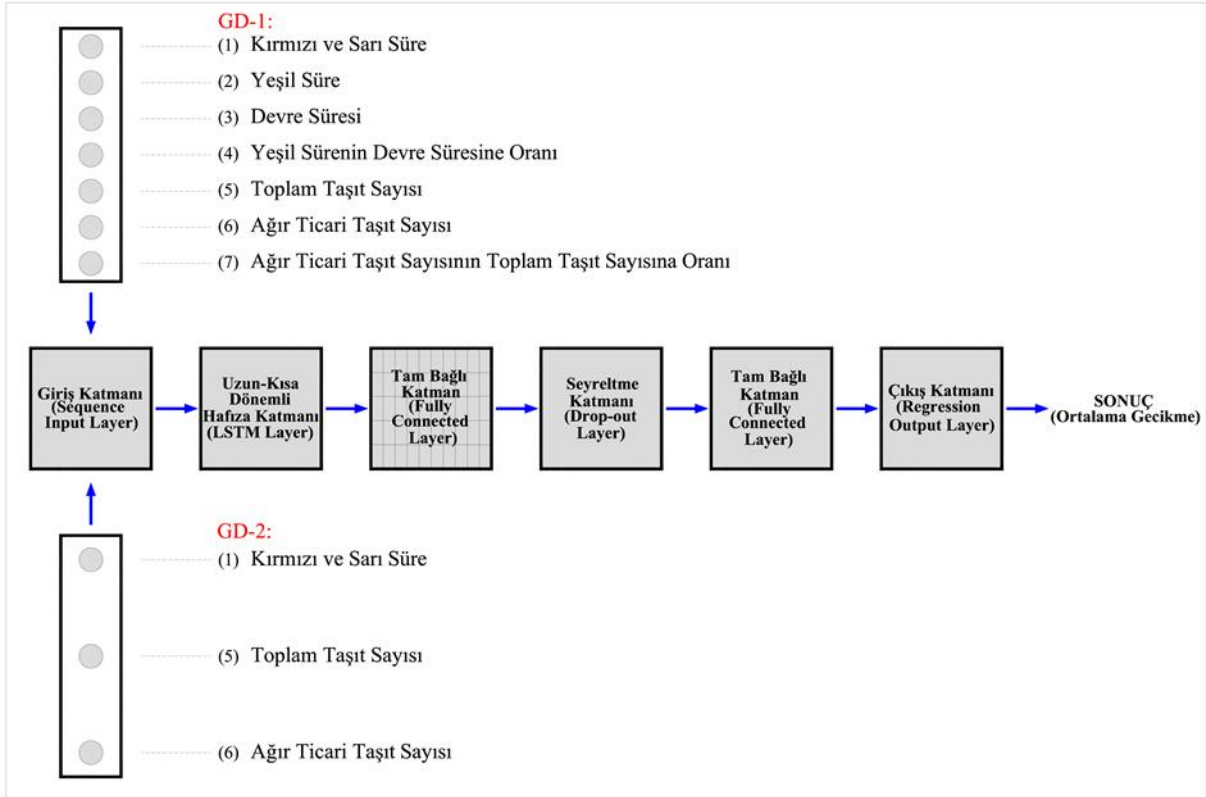


Şekil 6. Makine öğrenmesi ile derin sinir ağı arasındaki ilişki

Derin öğrenme modellerini klasik YSA’dan ayıran en önemli özellik derin öğrenme modellerinin daha çok veri ile daha çok işlem gücüne sahip olmasıdır. Diğer bir özellik ise derin öğrenme modellerinin, doğrusal olmayan aktivasyon fonksiyonları, ilkleme ve düzenleme yöntemlerini barındırmasıdır (Akbaş, 2018). Derin öğrenmeyi, derin evrişimli sinir ağı olarak, evrişimli kelimesini ise çok katmanlı olarak tanımlamak mümkündür. Evrişimli sinir ağı kullanılırken ön işlem, özellik çıkarımı ve sınıflandırma-tespit olmak üzere üç evre ortaya konmaktadır. Ancak derin evrişimli sinir ağına ön işlem ve özellik çıkarımı evreleri yok sayılmakta olup, bu evrelerin yaptığı işlemler sinir ağı içerisinde otomatik olarak yapılmaktadır (Doğan&Türkoğlu, 2018).

Bu çalışmada DÖM modellerinin geliştirilmesinde sıkça tercih edilen sinir ağı olan evrişimli sinir ağları kullanılmıştır. DÖM’de dizi giriş katmanı, uzun kısa dönem hafıza (LSTM) katmanı, tam bağlı katman, seyreltme katmanı, regresyon katmanı olmak üzere 5 tip katman kullanılmıştır. Dizi giriş katmanı ile 4-katlı ÇD yöntemi kullanılarak oluşturulmuş olan eğitim ve test veri setlerinin ağa giriş yapması sağlanmıştır. LSTM’de eğitim ve test veri setlerini hafızada tutan bellek hücreleri yer almaktadır. Bu bellek hücreleri hangi verinin tutulup hangi verinin atılacağına karar vererek veri dizilerinin devam ettirilmesini sağlamaktadır. LSTM katmanı kullanılarak ağın, veri dizileri ve zaman arasındaki uzun vadeli bağımlılıkları öğrenmesi sağlanmıştır. LSTM katmanında 250 adet nöron kullanılmıştır. Tam bağlı katmanlar kendinden önceki katmanların tüm alanlarına bağlı olduğu için ve katman sayısı arttıkça model daha iyi öğrendiği için DÖM’de 50 adet tam bağlı katman kullanılmıştır. Literatürde seyreltme değeri 0 ile 1 aralığında bir değer olarak tanımlanmakta (Çarkacı, 2018) olup DÖM’de seyreltme katmanında, seyreltme değeri 0,5 alınmıştır. Son olarak çıkış katmanı regresyon katmanı olarak tanımlanmış olup bu katmanda OKH değerleri hesaplanmıştır.


YSA modelinde 4-katlı ÇD yöntemi kullanılarak oluşturulmuş olan eğitim ve test veri setleri DÖM’de de kullanılmıştır. Böylece DÖM’de de tıpkı YSA modelinde olduğu gibi tüm veri üzerinde hem test hem de eğitim işlemi uygulanmıştır. Ağın eğitilmesinde ana kol için 40 adet veri, tali kol için ise 436 adet veri kullanılmıştır. Sinyalizasyon parametreleri ve trafik akışını oluşturan ulaşım modlarının özellikleri gecikmeyi etkileyen önemli değişkenleri barındırmaktadır. Bu nedenle trafik akışını ve sinyalizasyonu birlikte ele alan iki girdi değişken kümesi (GD-1 ve GD-2) DÖM’nin eğitilmesinde kullanılmıştır. GD-1 yedi farklı sinyal ve trafik değişkenini içeren ve sahadan toplanması kolay olan veri tipleridir. GD-2 ise üç değişkenden oluşmaktadır. Şekil 7’de DÖM’nin mimarisi ve bu girdiler sunulmuştur. Bu girdilerin seçilmesinde ilgili korelasyon matrisi oluşturulmuş; kendi aralarında en düşük, bağımlı değişkenle en yüksek korelasyona sahip değişkenler seçilmiştir.



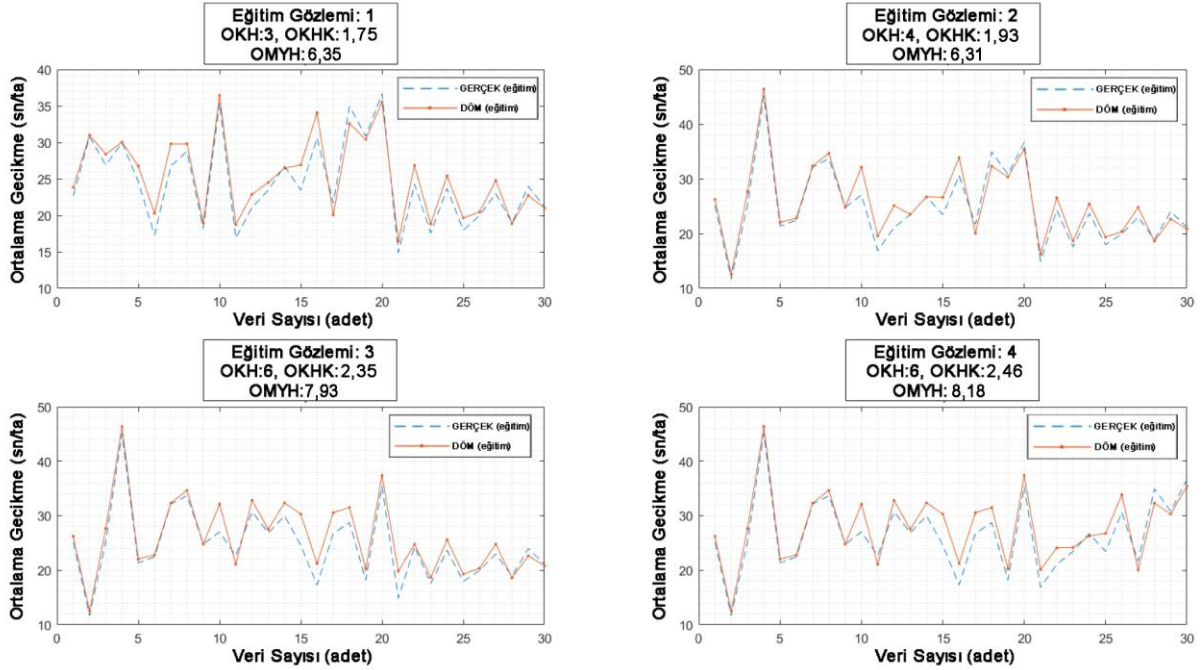
Şekil 7. DÖM'nin mimarisi

Derin öğrenme uygulamalarında adam, adamax, SGDM, adagrad ve adadelta gibi optimizasyon algoritmaları kullanılmaktadır (Çarkacı, 2018). DÖM'de, derin sinir ağlarını eğitmek için özel olarak tasarlanmış adaptif bir öğrenme oranı optimizasyon algoritması olan adam tercih edilmiştir. Bu algoritmada kullanılan momentum parametresi adam'ı diğer algoritmalarından ayırmaktadır (<http://www.mathworks.com/help/deeplearning/ref/trainingoptions.html>)

Veri setinde yer alan tüm değişkenlerin aynı anda işlenerek ağırlık öğrenmesi zaman alan ve belleği yoran işlemlerdir. Veri sayısı arttıkça hesaplama süreleri de uzamaktadır. Bu nedenle derin öğrenme uygulamalarında bu sorunu bertaraf etmek için veri seti küçük gruplara ayrılmakta ve ağırlık öğrenmesi seçilen bu küçük gruplar vasıtasıyla yapılmaktadır. Veri setinin küçük gruplar olarak işlenmesine "mini-batch" denmektedir (Çarkacı, 2018). DÖM'de mini batch değeri 32 olarak alınmış olup, böylece modelin aynı anda 32 adet veriyi işlemesi sağlanmıştır. Ayrıca DÖM'de eğitim için maksimum adım sayısı 250, başlangıç öğrenme hızı değeri 0,01 olarak seçilmiştir. Şekil 8'de DÖM'e ait bir eğitim işleminin adımlar boyunca hata değişimi verilmiştir. Hatalarda hızlı bir düşüş olduktan sonra, hata değerlerinin düşüşü azalarak devam etmektedir. Şekil 9' da ise ana kol için DÖM (GD-1)'e ait eğitim verilerinin, gerçek gecikme değerleri ile olan ilişkisi görülmektedir. DÖM tahminlerinin, gerçek değerlere yakın değerler ürettiği göze çarpmaktadır.



Şekil 8. DÖM'nin eğitim işlemi



Şekil 9. Ana kol için DÖM (GD-1) eğitim verilerinin sonuçları

Ana kol ve tali koldaki veriler üzerinde K-katlamalı çapraz doğrulama (ÇD) yöntemi uygulanmıştır. Bu yöntemde K değeri 4 olarak seçilmiştir. Tüm modellerde K-katlamalı ÇD yöntemi kullanılarak tüm veri üzerinde hem test hem de eğitim işlemi yapılmıştır.

## 5. Bulgular ve Değerlendirme

Bu çalışmada, DÖM, adaptif sistemlerle yönetilen bir kavşağın gecikmelerini tahmin etmek için kullanılmıştır. Geliştirilen modelin etkinliğini test etmek amacıyla model, gecikme tahmininde sıklıkla kullanılan modeller ile karşılaştırılmıştır. Bu modellerden ikisi literatürde geçerliliği kabul edilmiş analitik modellerden HCM ve Avustralya (Akçelik) modeli olup, diğeri ise YSA modelidir. Bu bölümde söz konusu modeller saha ölçümleri ile karşılaştırılarak performansları değerlendirilmiştir. Bu değerlendirmelerde, OKH, OKHK ve OMYH olmak üzere üç adet performans ölçütü kullanılmıştır.

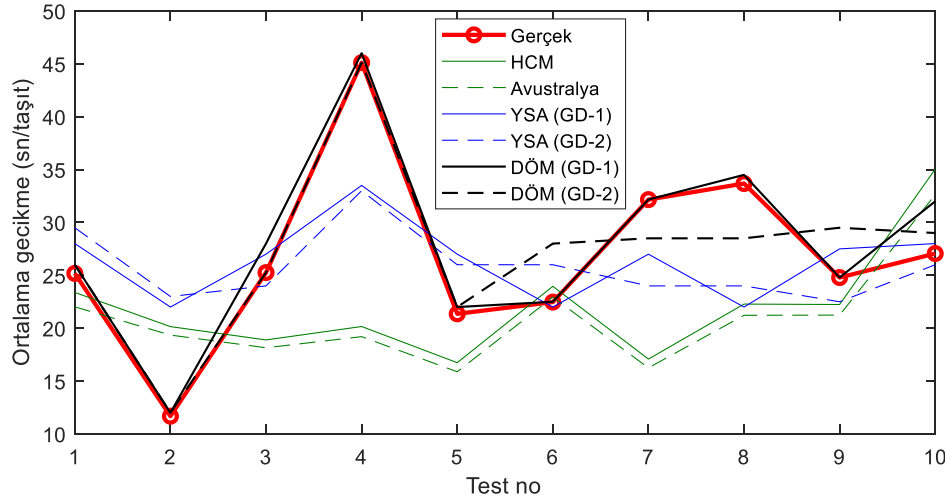
Yeni Sanayi kavşağı bir devlet yolu üstünde bulunduğundan, kavşak kolları hacim ve araç türlerinin dağılımı bakımından farklılık göstermektedir. Bu nedenle, karşılaştırmalar, ana ve tali kol olarak iki grup altında incelenmiştir. Modellerin ana kol ve tali kolda göstermiş olduğu performanslar Tablo 7' de sunulmuştur. İlk veri kümesi (GD-1) kullanılarak geliştirilen tüm modellerin OKH, OKHK ve OMYH değerine göre göstermiş olduğu performans sonuçları incelendiğinde, YSA ve DÖM modellerinin diğer modellerden önemli derecede düşük hata değerlerine sahip olduğu göze çarpmaktadır. Bu durum, yapay zeka modellerinin veriye daha iyi adapte yeteneği olduğunu ortaya koymaktadır. Diğer taraftan, DÖM modelinin her iki girdi kümesinde, YSA'dan daha düşük hatalar ürettiği görülmektedir. Analitik metotların bütün karşılaştırma ölçütleri için DÖM ve YSA modellerinden düşük performans gösterdiği anlaşılmaktadır.

Tablo 7. Modellerin yaklaşım kollarına göre hata değerleri

Model	Ana Kol			Tali Kol		
	OKH	OKHK	OMYH	OKH	OKHK	OMYH
DÖM (GD-1)	18	3,74	10,91	345	18,43	23,96
DÖM (GD-2)	39	5,63	19,41	760	27,11	46,04
YSA (GD-1)	28	5,17	17,98	795	27,66	45,87
YSA (GD-2)	37	6,06	21,54	793	27,55	44,35
Avustralya	88	8,69	30,86	1120	32,99	46,50
HCM	105	9,40	34,91	1072	32,13	46,66

Modellerin ana kol test kümesi için tahminleri ile gerçek gecikme değerleri Şekil 10'da verilmiştir. Avustralya ve HCM modellerinin birbirine yakın ve çoğu noktada gerçek değer altında gecikme değerleri ürettiği görülmektedir. Bu modellerin, test no: 1,6 ve 9 da

gerçek değerlere yakın tahminlerde bulunsa da, artış ve azalış durumlarına uyum sağlamadığı bir ortamda etrafında salındığı görülmektedir. Yani bir adaptif sistemde, devre başına inceleme ve modellemeler yapılsa bile yeterli uyumu sağlayamamaktadırlar. YSA modelinin değişimlere analitik modellerden daha iyi uyum sağladığı anlaşılmaktadır. Fakat özellikle gecikmenin yüksek olduğu 4, 7 ve 8 gibi noktalar için tahminleri gerçek değerlerden düşük kalmaktadır. Diğer taraftan düşük gecikmeye sahip olan "2" noktası için yaklaşık iki kat daha fazla gecikme değeri üretmiştir. Bu nedenle YSA yaklaşımının yüksek ve düşük değerlerdeki tahmin yeteneği beklenenin altındadır. Şekil 10'da DÖM modellerinin tahminleri siyah çizgi ile ifade edilmiştir ve bu çizgi çok az sapma dışında gerçek değerler ile örtüşmektedir. Bu da DÖM modelinin başarısının bütün değerler için oldukça tatmin edici olduğunu ortaya koymaktadır.



Şekil 10. Modellerin ana kol için test sonuçları

GD-1 ile eğitilen DÖM modeli sonuçlarının GD-2 ile eğitilenlerden daha isabetli olduğu da diğer önemli bir sonuç olarak ortaya çıkmıştır. Fakat, daha az değişkene sahip olan GD-2'nin sahadan kolayca elde edilebilecek olması önemli bir avantajdır. Özellikle DÖM (GD-2) modelinin YSA ve analitik modellerden daha iyi sonuçlar vermediği açıktır. Bu nedenle, DÖM (GD-2) modeli, hızlı sonuçların gerektiği ön çalışmalar için avantajlı bir seçenek olarak değerlendirilmektedir.

## 6. Sonuçlar ve Öneriler

Bu çalışmada, adaptif sinyalizasyon bir kavşağın gecikmelerinin ölçülmesi için bir derin öğrenme modeli (DÖM) sunulmuştur. Ayrıca, bu model farklı girdiler ile eğitilerek sonuçlar irdelenmiştir. Geliştirilen DÖM gecikme modeli, literatürde kullanılan gecikme modelleri ile karşılaştırılarak etkinliği araştırılmıştır. Yapılan analizler sonucunda, DÖM modelinin adaptif sistemlerde gecikme tahmini için uygun bir model olduğu belirlenmiştir. Gecikme tahmini için sıkça başvurulan analitik modellerin adaptif sistemlerdeki değişken parametrelere uyum sağlayamadığı ele alınan hata kriterinden açıkça görülmüştür. Bu nedenle ön zamanlı sistemler için etkin olan bu modellerin hızla yaygınlaşmakta olan ASYS kullanan kavşaklar için uygun olmadığı elde edilen sonuçlar arasındadır. YSA modelinin kapasitesinin ise analitik modellerden daha az hata yaptığı belirlense de DÖM modeli kadar gecikmeleri isabetli tahmin edemediği anlaşılmıştır. Bu nedenle, DÖM modellerinin ASYS'ye sahip kavşaklarda gecikme tahmini için kullanılması uygun olacaktır. Diğer taraftan DÖM modelinden tam verim alabilmek için DÖM, diğer modellerden daha fazla sayıda girdi çeşidine ve sayısına ihtiyaç duymaktadır. Bu durum bir dezavantaj olarak görülebilir. Fakat gelişen detektör ve iletişim teknolojileri bu bilgilerin elde edilmesini kolaylaştırmaktadır. Ayrıca yapılan analizler, az girdi çeşidi ile modellenen DÖM modellerinin, ele alınan diğer model yaklaşımlarından halen daha iyi sonuçlar üretebildiğine de göstermiştir. Bu nedenle DÖM kısıtlı veri çeşidinin toplanabildiği kavşaklar için önemli bir alternatif olma özelliğini taşımaktadır. Bu çalışmada uygulama bölgesinin sınırlı olması çalışmanın en önemli kısıtını teşkil etmektedir. İleri çalışmalarda, gecikme verisi sunan kaynak ve olanakların artmasıyla, DÖM modelinin farklı kavşaklardan alınan veriler ile de eğitilerek genelleme kabiliyetinin artırılması ve farklı kavşak geometrileri için etkinliğinin araştırılması amaçlanmaktadır.

## Referanslar

- Aavani, P., Sawant, M.K., Sawant, S., & Deshmukh, R.S. (2017). A Review on Adaptive Traffic Control Systems. International Journal of Latest Engineering and Management Research (IJLEMR), Volume 02, Issue 01, PP. 52-57, January 2017.
- Adebiyi, R. F., Abubilal, K. A., Mu'azu, M. B., & Adebiyi, B. H. (2018). Development and Simulation of Adaptive Traffic Light Controller using Artificial Bee Colony Algorithm. Int J Intell Syst Appl, 10 (8), 68-74.
- Akbaş, A., Kent İçi Ulaşımında Ana Arterlerdeki Ulaşım Performansının Simülasyon Tabanlı Olarak Değerlendirilmesi. <http://www.imo.org.tr/resimler/ekutuphane/pdf/12065.pdf> (Erişim tarihi:31.10.2020)

- Akbaş, E. (2018). Derin Yapay Sinir Ağları ve Derin Öğrenme'ye Kısa Bir Giriş. Bilgisayar Mühendisleri Odası Semineri, Ankara.
- Akbaş, A., & Akdoğan, E. (2001). İstanbul Kent İçi Trafik Kontrol Sistemi Üzerine Bir Durum Değerlendirmesi. TMMOB Makine Mühendisleri Odası "İstanbul'da Kent İçi Ulaşım Sempozyumu" 28-29-30 Haziran 2001.
- Akgüngör, A.P. (2004). Sinyalize Kavşaklarda Gecikme Tahmininin Matematiksel Modellenmesi: Farklı Çözümleme Süreleri için Zamana Bağlı Yeni Bir Gecikme Modeli. Teknoloji, Cilt 7, (2004), Sayı 3, s.369-379.
- Anguita, D., Ghelardoni, L., Ghio, Allesandro, Oneto, L., & Ridella, S. (2012). The 'K' in K-fold Cross Validation. ESANN 2012 proceedings, European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning. Bruges, Belgium. i6doc.com publ., ISBN 978-2-87419-049-0. Available from <http://www.i6doc.com/en/livre/?GCOI=28001100967420>.2012.
- Atalay, A. (2004). Sinyalize Kavşaklardaki Gecikme Tahmininde Yapay Zeka Yöntemi İle Farklı Yöntemlerin Karşılaştırılması. Yüksek Lisans Tezi. Atatürk Üniversitesi, Erzurum.
- Bağdatlı, M.E.C. (2020). Vehicle Delay Modeling at Signalized Intersections with Gene-Expression Programming. Journal of Transportation Engineering, Part A: Systems, 2020, 146 (9): 04020107.
- Balta, M., & Özçelik, İ. (2019). Şehir İçi Kavşak Yönetim Sistemleri için SDN Temelli Bir VANET Mimari Önerisi. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 34:3 (2019) 1451-1468.
- Başkan, Ö. (2004). İzole Sinyalize Kavşaklardaki Ortalama Taşıt Gecikmelerinin Yapay Sinir Ağları ile Modellenmesi. Yüksek Lisans Tezi. Pamukkale Üniversitesi, Denizli.
- Çarkacı, N. (2018). Derin öğrenme uygulamalarında en sık kullanılan hiper parameteler. <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilanhiper-parametreler-ece8e9125c4>. (Erişim tarihi: 31.10.2020)
- Çavuşlu, M.A., Becerikli, Y., & Karakuzu, C. (2012). Levenberg-Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi. Dergi Park, Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, Archive, Volume 5, Issue 1.
- Ding, Z. (2007). A Static Traffic Assignment Model Combined with an Artificial Neural Network Delay Model. Ph.D. thesis. Florida International University, Miami, Florida, USA.
- Doğan, E., Akgüngör, A.P., & Arslan, T. (2016). Estimation of Delay and Vehicle Stops at Signalized Intersections Using Artificial Neural Network. Engineering Review, Vol. 36, Issue 2, 157-165.
- Doğan, F., & Türkoğlu, İ. (2018). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. DÜMF Mühendislik Dergisi 10:2 (2019): 409-445.
- Esen, M.F., & Timor, M. (2019). Çok Değişkenli Aykırı Değer Tespiti için Klasik ve Dayanıklı Mahalanobis Uzaklık Ölçütleri: Finansal Veri ile Bir Uygulama. Uluslararası İktisadi ve İdari İncelemeler Dergisi UIİİD-IJEAS, 2019 (25):267-282 ISSN 1307-9832.
- Garshasebi, B. (2018). Machine Learning Based Vehicle Delay Prediction at Signalized Intersections. M.Sc. thesis. University of Illinois at Urbana-Champaign, Urbana, Illinois, USA.
- Gundogan, F., Karagoz, Z., Kocyyigit, N., Karadag, A., Ceylan, H., & Murat, Y. S. (2014). An Evolution of Adaptive Traffic Control System in Istanbul, Turkey. J Traffic Logist Eng, 2 (3), 198-201.
- Harb, A.A.M., Durdu, A., & Terzioğlu, H. (2019). Kavşak Trafik Sinyalizasyon Kontrolü için Bulanık Mantık Yöntemi ile Gerçek Zamanlı Sistemin Tasarımı ve Uygulaması. Avrupa Bilim ve Teknoloji Dergisi Özel Sayı, S. 490-497, Ekim 2019.
- Hasiloğlu, A.S., Gökdağ, M., & Karşı, N. (2014). Comparison an artificial intelligence-based model and other models signalized intersection delay estimates. International Journal of Engineering and Innovative Technology (IJEIT) Volume 4, Issue 3.
- HCM,(2000).Transportation Research Board, National Research Council, Highway Capacity Manual, Transportation Research Board Publications, Washington DC.
- <https://www.mathworks.com/help/deeplearning/ref/trainingoptions.html> (Erişim tarihi:31.10.2020)
- Jin, J., & Ma, X. (2015). Adaptive Group-Based Signal Control By Reinforcement Learning. Transportation Research Procedia 10 (2015) 207-216.
- Katanalp, B.Y., Yıldırım, Z.B., Eren, E., & Uz, V.E. (2018). Akıllı Ulaşım Sistemleri Üzerine Bir Değerlendirme. Second International Symposium on Innovative Approaches in Scientific Studies, November 30 – December 2, 2018, Samsun, Turkey. SETSCI Conference Indexing System, Volume 3 (2018), 1503-1506.
- Kim, P. (2017). MatLab Deep Learning with Machine Learning, Neural Networks and Artificial Intelligence. Apress, Seoul, Korea.

- Korkmaz, E. (2016). Yapay Zeka Teknikleri Kullanılarak Sinyalize Kavşaklarda Gecikme Modelleri. Yüksek Lisans Tezi. Kırıkkale Üniversitesi, Kırıkkale.
- Manandhar, B., & Joshi, B. (2018). Adaptive Traffic Light Control with Statistical Multiplexing Technique and Particle Swarm Optimization in Smart Cities. IEEE 3rd International Conference on Computing, Communication and Security, Kathmandu – Nepal, 210-217.
- Masouleh, A.S. (2017). Adaptive Traffic Signal Optimization Using Bluetooth Data. Ph.D. thesis. University of Waterloo, Ontario, Canada.
- Murat, Y.Ş. (2006). Sinyalize Kavşaklardaki Taşıt Gecikmelerinin Bulanık Mantık ile Modellenmesi. İMO Teknik Dergi, 2006 3903 -3916, Yazı 258.
- Murat, Y.Ş. (2006). Comparison of Fuzzy Logic and Artificial Neural Networks Approaches in Vehicle Delay Modeling. Transportation Research Part C 14 (2006) 316–334.
- Mutlu, E., & Yavuz, M.E. (2008). Bulanık Mantık ve Yapay Sinir Ağı ile Sinyalize Kavşaklardaki Taşıt Gecikmelerinin Modellenmesi. Electronic Letters on Science & Engineering, vol. 4(2), pg. 11-18. <http://e-lse.org>.
- Ocakdan, S. (2010). Arterlerin Yeniden Yapılandırılmasında Simülasyon Tekniği ile Karar Verme ve Bir Kavşak Uygulaması. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, İstanbul.
- Odeh, S. M., Mora, A. M., Moreno, M. N. & Merelo, J. J. (2015). A Hybrid Fuzzy Genetic Algorithm for an Adaptive Traffic Signal System. Adv Fuzzy Syst, Article ID: 378156, 1-11.
- Özdağ, M.E. (2019). Derin Öğrenme Teknikleri Kullanılarak Anayol Trafik Analizi. Yüksek Lisans Tezi. Karabük Üniversitesi, Karabük.
- Öztemel, E. (2006). Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul.
- Preethi, P., Aby, V., & Ashalatha, R. (2016). Modelling Delay at Signalized Intersections Under Heterogeneous Traffic Conditions. Transportation Research Procedia 17 (2016), 529 – 538.
- Qiao, F., Yi, P., Yang, H., & Devarokonda, S. (2002). Fuzzy Logic Based Intersection Delay Estimation. Pergamon Mathematical and Computer Modelling. 36 (2002) 1425-1434, <http://elsevier.com/locate/mcm>.
- Roess, P.R., Prassas, S.E., & McShane, R.W. (2011). Traffic Engineering, Fourth Edition, Pearson Higher Education Inc, USA.
- Samadi, S., Rad, A. P., Kazemi, F. M., & Jafarian, H. (2012). Performance Evaluation of Intelligent Adaptive Traffic Control Systems: A Case Study. Open J Transp Technol, 2, 248-259.
- Shoufeng, L., Ximin, L., & Shiqiang, D. (2008). Q-Learning for Adaptive Traffic Signal Control Based on Delay Minimization Strategy. 2008 IEEE International Conference on Networking, Sensing and Control, Sanya – China, 687-691.
- Studer, L., Ketabdari, M., & Marchionni, G. (2015). Analysis of Adaptive Traffic Control Systems Design of a Decision Support System for Better Choices. J Civil Environ Eng, 5 (6), 1-10.
- Siregar, S.P., & Wanto, A. (2017). Analysis Accuracy of Artificial Neural Network Using Backpropagation Algorithm In Predicting Process (Forecasting). International Journal Of Information System & Technology Vol. 1, No. 1, (2017), pp. 34-42.
- Şeker, A., Diri, B., & Balık, H.H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi 2017, 3(3): 47-64, Gazi Akademi Yayıncılık, Ankara.
- Tektaş, M., Akbaş, A., & Topuz, V. (2002). Yapay Zeka Tekniklerinin Trafik Kontrolünde Kullanılması Üzerine Bir İnceleme. Uluslararası Trafik ve Yol Güvenliği Kongresi ve Fuarı, Ankara. <http://kadirgurbetci.com.tr/yonetim/dosya/0444e4fab9hnc.pdf> (Erişim tarihi:31.10.2020)
- Webster, F. (1958). Traffic Signal Settings. HMSO, London.
- Wu, S., Bi, Y., Wang, G., Ma, Y., Lu, M., & Xu, K. (2019). Adaptive Fuzzy Logic Traffic Signal Control Based on Cuckoo Search Algorithm. International Symposium for Intelligent Transportation and Smart City (ITASC) 2019, Singapore – Singapore, 107-117.
- Yulianto, B., & Sutanto, B. (2014). Adaptive Traffic Signal Control for Mixed Traffic Conditions. 1st International Conference on Engineering Technology and Industrial Application, Surakarta – Indonesia, 111-116.