



POLİTEKNİK DERGİSİ

*JOURNAL of POLYTECHNIC*

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



# Buzlanma tahmini yapan mobil uygulama geliştirilmesi

## *Development of ice prediction mobile application*

*Yazar(lar) (Author(s)): Hatice KABAOĞLU<sup>1</sup>, Emine UÇAR<sup>2</sup>, Fecir DURAN<sup>3</sup>*

*ORCID<sup>1</sup>: 0000-0002-1077-0012*

*ORCID<sup>2</sup>: 0000-0002-6838-3015*

*ORCID<sup>3</sup>: 0000-0001-7256-5471*

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** Kabaoğlu H., Uçar E. ve Duran F., “Buzlanma tahmini yapan mobil uygulama geliştirilmesi”, *Politeknik Dergisi*, 24(4):1543-1555,(2021).

**Erişim linki (To link to this article):** <http://dergipark.org.tr/politeknik/archive>

**DOI:** 10.2339/politeknik.735408


# Buzlanma Tahmini Yapan Mobil Uygulama Geliştirilmesi

## Development of Ice Prediction Mobile Application

### Önemli noktalar (Highlights)

- ❖ Yollardaki buzlanmadan kaynaklı kazaların önlenmesine yönelik bir buzlanma tahmin algoritması ve mobil uygulama geliştirilmiştir. / An icing prediction algorithm and mobile application have been developed to prevent accidents caused by icing on the roads.
- ❖ Eğitim için kullanılan örnek sayısı arttıkça, önerilen algoritmanın buzlanma tahmin doğruluğunun da arttığı gözlemlenmiştir. / It was observed that as the number of samples used for training increased, the icing prediction accuracy of the proposed algorithm also increased.

### Grafik Özet (Graphical Abstract)



Şekil. Çalışma modeli / Figure. Proposed architecture

### Amaç (Aim)

Bu çalışmada yollardaki buzlanmadan kaynaklı kazaların önlenmesine yönelik bir buzlanma tahmin algoritması ve mobil uygulama geliştirilerek sürücülerin güzergâhları doğrultusunda buzlanma oluşumu ile ilgili ön bilgi verilmesi amaçlanmaktadır. / In this study, it is aimed to provide preliminary information about icing formation in line with the drivers' routes by developing an icing prediction algorithm and mobile application to prevent accidents caused by icing on the roads.

### Tasarım ve Yöntem (Design & Methodology)

Çalışmada yol durum sensörü ve hava istasyonlarından alınan çeşitli parametreler kullanılarak ikili sınıflandırma yapılmıştır. Daha sonra geliştirilen mobil uygulama ile gelecek 12 saat için buzlanma tahmini yapılmaktadır. / In the study, a binary classification was made using the various parameters taken from the road condition sensor and the weather stations. Later, with the developed mobile application, icing is predicted for the next 12 hours.

### Özgünlük (Originality)

Bu çalışmada geleneksel olarak kullanılan lokal noktadan ölçüm ile tespit ya da hava durumuna göre tahmin yerine hibrit bir buzlanma tahmini yapan mobil uygulama geliştirilmiştir. Ayrıca literatürdeki tahmin yöntemlerinin yanında özgün bir tahmin yöntemi geliştirilmiştir. / In this study, a mobile application that makes a hybrid icing prediction has been developed instead of traditionally used local point measurement or weather forecast. In addition to the estimation methods in the literature, a unique estimation method has been developed.

### Bulgular (Findings)

Deneysel çalışmalar sonucunda, toplam doğru sınıflandırılan örnek sayısı temel alındığında ÇKA modelinin %87,26 doğruluk oranı ile en iyi sonucu verdiği, ardından %86,32 ile doğrusal DVM modelinin geldiği önerilen modelimizin ise %75,47 doğruluk oranına sahip olduğu görülmüştür. / As a result of the experimental studies, based on the total number of correctly classified samples, it was seen that the MLP model performed best with 87,26% accuracy rate, followed by the linear SVM model with 86,32% and our proposed model with 75,47% accuracy rate.

### Sonuç (Conclusion)

Geliştirilen tahmin algoritmasında sınıflandırma doğruluğu diğerlerine kıyasla daha az olmasına rağmen eğitimde kullanılan örnek sayısı arttıkça, buzlanma tahmin doğruluğunun da arttığı gözlemlenmiştir. / Although the classification accuracy of the developed prediction algorithm is less than the others, it has been observed that the icing prediction accuracy increases as the number of samples used in training increases.

### Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

# Buzlanma Tahmini Yapan Mobil Uygulama Geliştirilmesi

*Araştırma Makalesi / Research Article*

**Hatice KABAOĞLU<sup>1</sup>, Emine UÇAR<sup>2</sup>, Fecir DURAN<sup>1\*</sup>**

<sup>1</sup>Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Gazi Üniversitesi, Türkiye

<sup>2</sup>İşletme ve Yönetim Bilimleri Fakültesi, Yönetim Bilişim Sistemleri Bölümü, İskenderun Teknik Üniversitesi, Türkiye

(Geliş/Received : 10.05.2020 ; Kabul/Accepted : 20.08.2020 ; Erken Görünüm/Early View : 22.09.2020)

## ÖZ

Soğuk hava ve ağır kış şartları, yollarda buzlanmaya sebep olmakta ve bu nedenle her yıl birçok ölümlü, yaralanmalı ve maddi hasarlı kaza meydana gelmektedir. Bu çalışmada yollardaki buzlanmadan kaynaklı kazaların önlenmesine yönelik bir buzlanma tahmin algoritması ve mobil uygulama geliştirilmiştir. Geliştirilen uygulama ile sürücülerin güzergâhları doğrultusunda buzlanma oluşumu ile ilgili ön bilgi verilmesi amaçlanmaktadır. Çalışmada yol durum sensörü ve hava istasyonlarından alınan sıcaklık, çığ noktası, hissedilen sıcaklık, rüzgâr şiddeti, rüzgâr yönü, bağıl nem, rüzgâr hızı giriş parametreleri olarak kullanılmıştır. Çıkışta ise buzlanma bilgisi ile ikili sınıflandırma yapılmıştır. Sistemin eğitimi tamamlandıktan sonra meteorolojiden hava durumu tahmin bilgisi alınarak, geliştirilen mobil uygulama üzerinde gelecek 12 saat için buzlanma tahmini yapılmaktadır. Ayrıca geliştirilen sistemin doğruluğunu ölçmek ve karşılaştırma yapabilmek için sınıflandırma alanında en çok kullanılan yöntemlerden çok katmanlı algılayıcı (ÇKA) sinir ağı modeli ile doğrusal ve doğrusal olmayan destek vektör makineleri (DVM) yöntemleri kullanılmıştır. Çalışmada kullanılan algoritmaların sınıflandırma doğruluğuna bakıldığında, toplam doğru sınıflandırılan örnek sayısı temel alındığında ÇKA modelinin %87,26 doğruluk oranı ile en iyi sonucu verdiği, ardından %86,32 ile doğrusal DVM modelinin geldiği önerilen modelimizin ise %75,47 doğruluk oranına sahip olduğu görülmüştür. Ancak geliştirilen tahmin algoritmasında sınıflandırma doğruluğu diğerlerine kıyasla daha az olmasına rağmen eğitimde kullanılan örnek sayısı arttıkça, buzlanma tahmin doğruluğunun da doğru orantılı olarak arttığı gözlemlenmiştir.

**Anahtar Kelimeler:** Makine öğrenmesi, mobil uygulama, buzlanma, tahmin algoritması.

## Development of Ice Prediction Mobile Application

### ABSTRACT

Cold weather and heavy winter conditions cause icing on the roads, and therefore many fatal, injured and materially damaged accidents occur every year. In this study, an icing prediction algorithm and mobile application has been developed to prevent accidents caused by icing on the roads. With the developed application, it is aimed to give preliminary information about the formation of icing in line with the routes of the drivers. In the study, the temperature, dew point, sensed temperature, wind intensity, wind direction, relative humidity, wind speed input parameters were taken from the road condition sensor and weather stations. At the exit, double classification was made with icing information. After the training of the system is completed, weather forecast information is obtained from the meteorology and icing forecast is made for the next 12 hours on the developed mobile application. In addition, in order to measure and compare the accuracy of the developed system, the multi-layer perceptron (MLP) neural network model and linear and nonlinear support vector machines (SVM) methods are used. Considering the classification accuracy of the algorithms used in the study, based on the total number of correctly classified samples, it was seen that the model of the MLP performed best with 87,26% accuracy rate, followed by the linear SVM model with 86,32% and our proposed model with 75,47% accuracy rate. However, in the developed prediction algorithm, although the classification accuracy is lower compared to others, it has been observed that the number of samples used in training increases, the icing prediction accuracy increases in direct proportion.

**Keywords:** Machine learning, mobile application, icing, prediction algorithm.

### 1. GİRİŞ (INTRODUCTION)

Yollarda buzlanma, hava ve yol durumlarına bağlı olarak meydana gelen doğal bir olaydır. Yollardaki buzlanmadan dolayı yollar kayganlaşır ve yolda sürücülerin yol hâkimiyeti azalır. Bu durum havaalanları, karayolları ve köprüler üzerinde kazaların meydana gelme olasılığının artmasına neden olmaktadır. Kazaların önlenmesi için öncelikle buzlanmanın engellenmesi gerekmektedir.

Yollarda buzlanma oluşumu genellikle, mekanik aletler ve kimyasal maddeler kullanılarak geleneksel yöntemler ile çözümlenmektedir [1]. Yol yüzeyinde buzlanma olduğu tespit edildikten sonra araçlarla yollara tuz dökülmekte veya yol yüzeyine entegre geliştirilmiş sistemler sayesinde kimyasal maddeler yol yüzeyine püskürtülmektedir. Geleneksel yöntemler ile yoldan buz kaldırmak maliyet, işgücü ve zaman almaktadır. Bu nedenle yollarda buz oluşumu öncesinde ve buzlanma oluştuğunda sürücülerin uyarılması hayati önem arz etmektedir. Sürücülerin uyarılması amacıyla hava ve yol durumunun tahmin ve tespit çalışmaları yapılmaktadır.

\*Sorumlu Yazar (Corresponding Author)  
e-posta : fduran@gazi.edu.tr

Hava durumu tahminlerinde geleneksel yöntemlerin dışında, matematiksel yöntemlerden de yararlanılmaktadır[2]. Aynı zamanda, belirli bir alanda özelleşmiş sistemler için farklı hava tahmin modelleri geliştirilmektedir. Tahmin modelleri fiziksel, istatistiksel ve ikisinin beraber kullanıldığı karma modeller olmak üzere ele alınmaktadır. Fiziksel modeller, sayısal hava tahmin modellerinden oluşmaktadır. İstatistiksel modeller, Yapay Sinir Ağı (YSA), Destek Vektör Makineleri (DVM), Bulanık Mantık Teknikleri [2-4] gibi veri madenciliği ve makine öğrenmesi tekniklerini kullanmaktadır. Birçok model olmasına rağmen kesin bir çözüm yoktur ve yaklaşık çözümler aranmaktadır [5].

Buz ve sel gibi yol yüzeyi koşullarının güvenli sürüş üzerinde önemli bir etkisi vardır; bu yüzey koşulları hava ile yakından ilgilidir [6]. Bu nedenle, gözlem araçlarını kullanarak yol koşullarının izlenmesi için, yani karayolu hava durumu bilgi sistemi ve karayolu hava durumu bilgi sistemi üzerinden güvenli sürüş bilgileri sağlamak için akıllı ulaşım sistemi üzerine çeşitli çalışmalar yapılmıştır [7-9].

Yol kenarlarında kurulan hava gözlem cihazlarından toplanan görüntü verilerini ve yol yüzeylerindeki yüzey sensörlerini kullanarak yol koşullarını belirlemeye yönelik çalışmalar aktif olarak sürdürülmektedir [10-12].

Bu çalışmada güvenli sürüş için gerçek zamanlı yol yüzeyi buzlanma koşullarını, hava tahmin verileri ve bölgesel gerçek zamanlı yol durum verileri kullanılarak tahmin eden bir algoritma önerilmiştir. Çalışmanın geri kalanı şu şekilde düzenlenmiştir. Bölüm 2’de ilgili çalışmalar özetlenmiştir. Bölüm 3’te geliştirilen sistemin tasarımı yapılmış, sistemin eğitim verileri hazırlama bileşeni tanımlanmış, kullanılan yöntemler hakkında detaylı bilgi verilmiş ve önerilen sistemin mobil uygulama üzerinde geliştirilmesi sunulmuştur. Bölüm 4’te ilgili çalışmalar incelenerek seçilen makine öğrenmesi sınıflandırıcıları ile buzlanma tahmini doğruluğu sunulmuştur. Sonuçlara bakılarak Doğrusal algoritmaların buzlanma tahmininde daha doğru sonuçlar ürettiği gözlenmiştir ve önerilen doğrusal yaklaşıma dayalı bir algoritma ile ampirik bir çalışma detaylıca anlatılmıştır. Son olarak, çalışmada elde edilen sonuçlar Bölüm 5’te sunulmaktadır.

## 2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Bu bölümde, hava tahmini modelleri ve buzlanma tahmini ile ilgili mevcut çalışmalar aşağıdaki kategorilere ayrılarak incelenmiştir.

### 2.1. Sayısal Modeller (Numerical Models)

Hava tahmini birden fazla uzmanlık alanı içeren karmaşık bir prosedürdür. Bunun için meteorolojik değişkenlerin tahminlerinin analizi yapılmalıdır. Sayısal anlamda havanın tahmini için meteorologlar atmosferik modeller geliştirmişlerdir. Bu modeller atmosferik sıcaklıkların, basıncın ve nemin zamanla nasıl değiştiğini tanımlamak için matematiksel yöntemler kullanılarak

çıkarılan yaklaşımlardır. Matematiksel çözümlerini yapılarak çıkarılan denklemler bilgisayarda programlanır ve şimdiki atmosfer verileri ile bilgisayar beslenir. Bu denklemler sayesinde gelecek zamanda atmosferin nasıl değişebileceğine dair tahminler üretilebilmektedir [2].

### 2.2. İstatistiksel Modeller (Statistical Models)

Sayısal hava tahmin modellerinin yanında çalışmalarda çeşitli makine öğrenmesi modelleri de kullanılmaktadır. Drezga ve Rahman kaba tahminleri tekrar eğitime sokarak daha iyi bir tahmin elde edebilmek için Yapay Sinir Ağları ile K-en yakın komşu metodunu kullanmışlardır [13]. Taylor ve Buizza yaptıkları çalışma ile YSA ile yapılan tahminlerin kullanılmasının (numerik) geleneksel yöntemlerden daha iyi sonuçlar ortaya koyduğunu gözlemlemişlerdir. Hava çok hızlı değişen bir yapıdadır. Bu yüzden tahminde yapılan küçük hatalar önlem alınmazsa hızla büyür ve tahmin edilebilirliği olumsuz etkiler. Numerik tahmin modelinde tahmin edilebilirlik, hava süreç simülasyonlarının gösterdiği model hatalarından dolayı kısıtlanmaktadır [14]. YSA algoritmasının yanı sıra DVM algoritması da yağış tahmini belirleme ve hava tahmini yapma gibi çevresel parametrelerin tahmini için kullanılabilir [15]. Lu ve diğerleri kısa süreli yapılan hava tahminlerinin kalitesinin doğrusal olmayan bağlanım metodlarının kullanılmasına dayandığı için doğrusal olmayan DVM modelini önermişlerdir [16]. Rao ve diğerleri hava tahmini için ÇKA öğrenme algoritması ile DVM yöntemini karşılaştırmış ve DVM’in daha iyi olduğunu gözlemlemişlerdir [17].

### 2.3. Melez Modeller (Hybrid Models)

Literatüre bakıldığında hava tahminlerinde birden fazla yöntemin kullanılmasının tahmin doğruluğunu iyileştirdiği düşünüldüğü için karma modeller tercih edilmektedir [18]. Nikhil ve diğerleri öz denetim nitelik haritalandırma veya nitelik seçimi ile ÇKA modelini birlikte kullanarak mevsimsel değişimlerle beraber bir karma sinir ağı modeli önermişlerdir. Uygun nitelik seçimi hem nitelik sayısının azaltılmasını hem de tahmin doğruluk oranının artmasını sağlar [19]. De Giorgi ve diğerleri güç üretim sistemi için YSA (Elman ağı ve Çok katmanlı Algılayıcı ağı) ve Numerik hava tahmin modellerini birlikte kullanarak bir model geliştirmişlerdir. Burada YSA yapısına dayalı bir karma model ile daha iyi sonuçların elde edildiği gözlemlenmiştir [5]. Chen ve diğerleri rüzgâr gücü tahmini için numerik hava tahmini ile olasılık yöntemlerinin (gauss işlemi) birlikte kullanıldığı bir model geliştirmiştir. Geliştirilen model YSA ve klasik model ile karşılaştırıldığında iyi sonuç vermiştir [20]. Costa ve Pasero, YSA yöntemi ile buz oluşumunu tahmin etme, tuz dağıtımının yapılması ve ince buz katmanının oluşmasını engellemek üzerine çalışmalar yapmışlardır [21].

Yapılan çalışmalara bakıldığında, tahmin oluşturmada meteorolojik değişkenlerin bazılarının veya tamamının kullanılabilirliği görülmüştür. Burada önemli olan nokta, buzlanma tahmini için doğru bir tahmin algoritması ile

beraber doğru değişkenlerin seçilmesidir. Hangi niteliğin daha az etkili olduğu veya hangisinin tahmin doğruluğunu daha fazla arttırdığının bulunmasında nitelik seçim yöntemlerinden yararlanılmaktadır. Jian, karayolu buzlanma tahmininde sınıflandırma doğruluğunu artırmak için özellikleri eş zamanlı olarak seçebilen değiştirilmiş bir diferansiyel dönüşüm kullanmıştır [22]. Tüm değişkenler tahmin doğruluğunda etkin olmadığı için tahmin doğruluğunu arttırmak için nitelik seçim yöntemleri kullanılmaktadır. Çok fazla veri olması da hava tahminini zorlaştırmaktadır [23].

#### 2.4. Buzlanma önleme çalışmalarının kullanıldığı alanlar (Research on icing prevention)

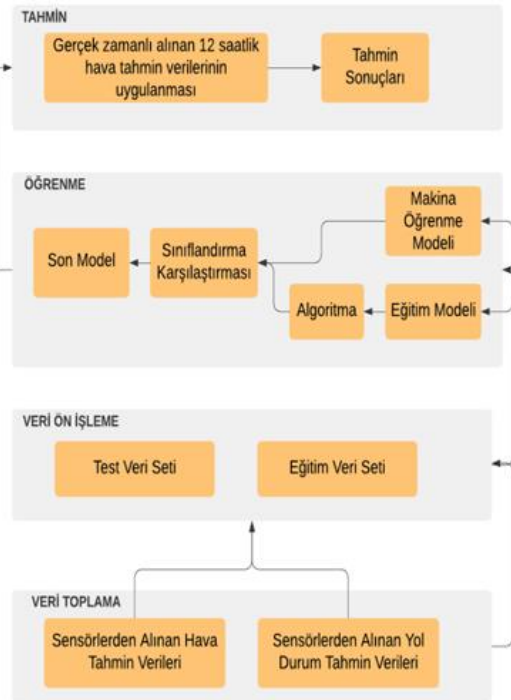
Uçuş sırasında uçak üzerinde meydana gelen buzlanmalar genel havacılık kazalarına neden olan faktörlerden birisidir [24]. McCann, yapmış olduğu çalışmada uçaklarda buzlanmayı önlemek için sıcaklık ve bağıl nemin yanı sıra uçuş seviyesinin yukarıya ve aşağısındaki nem verilerinin işlenmesi sebebiyle sinir ağı yöntemi kullanılmasının buzlanma tahmininde doğru bir seçim olduğunu bildirmiştir [25]. Farklı bir çalışma olarak, nehir üzerindeki buz oluşumu tahmininin yapılmasında genetik algoritmalar ve sinir ağılar beraber kullanılmıştır. Karma buz tahmin sinir ağı modelleri yüksek performans göstermiştir [26]. Buzlanma tahmininin kullanıldığı bir diğer saha, enerji hat iletkenleri üzerinde buzlanma ve buz dökülmesi için kullanılmasıdır [27]. İletişim hatları üzerindeki buzlanmanın önlenmesi için çalışmalar yapılmıştır [28-30]. Güç şebekelerinde buz oluşumunun tahmini için DVM kullanılmıştır. [31]. GY (Geri Yayılım) sinir ağı modeli ile DVM karşılaştırılmıştır ve DVM modelinin örnek sayısının az olduğu durumlarda buzlanma yük tahmininde sinir ağı modelinden daha uygun olduğu öngörülmüştür. DVM daha az sayıda öğretilmiş veri ile doğru tahmin yapabilir. Eğitilmiş veri ve tahmin verileri buzlanma sürecinde farklı olsa bile DVM uygulanabilir [32].

#### 2.5. Mobil Uygulamalar (Mobile Applications)

Mobil cihazlar herhangi bir rekabet olmadan hızla büyümektedir. Akıllı telefon numaralarındaki hızlı artış ve akıllı telefon uygulamalarının kolayca yüklenebildiği yerler olan pazarlar mobil geliştirmeyi büyük bir market haline dönüştürmüştür. Kullanıcı sayısı arttığı gibi, mobil uygulamalara olan talep de artmıştır. Bu da hızlı sonuçlar için hızlı geliştirme döngüsüne yol açmıştır. Android platform üzerinde uygulama geliştirmenin en iyi yöntem olmasının sebebi şu anda en hızlı büyüyen ve çok yaygın bir platform olmasıdır [33]. Günümüzde mobil telefonlarda kısa mesajlar yoluyla uyarı mekanizmalarının kullanılması büyük ölçüde artmıştır. Erken uyarı sistemi şimdilerde en çok önerilen sistemlerden birisidir [34]. Bu uygulamanın en iyi temsilcileri Amerika Birleşik Devletleri ve Japonya'dır. Mobil telefonlar kullanılarak erken uyarı sistemleri geliştirilmiştir [35-36].

### 3. MATERYAL VE METOD (MATERIAL and METHOD)

Bu çalışmada geliştirilen sistemin saatlik buzlanma tahmini yapması amaçlandığından, sistemin buzlanmanın hangi hava koşullarında meydana geldiğini öğrenebilmesi için belirli bir bölgedeki yer ve hava istasyonlarından veriler alınmıştır. Alınan veriler işlenerek eğitim ve test verisi olarak ayrılmıştır. Daha sonra düzenlenen bu veriler kullanılarak bir makine öğrenmesi modeli oluşturulmuştur. Öğrenme verileri eğitim aşamasından sonra YSA ve DVM modellerine uygulanarak buzlanma tahmini doğruluk yönünden sınıflandırılmıştır ve gerçek zamanlı buzlanma tahmini yapan bir model ortaya çıkarılmıştır. Sistemin öğrenimi tamamlandıktan sonra sistemin gerçek verilerle test edilmesi için önümüzdeki 12 saatin saatlik sıcaklık, hissedilen sıcaklık, çığ noktası, rüzgâr hızı, rüzgâr yönü, bağıl nem ve rüzgâr şiddeti verileri AccuWeather.com meteoroloji sitesinden gerçek zamanlı olarak alınmaktadır. Alınan veriler geçmiş veriler olarak sistemde kaydedilmekte ve sistemin iyileştirilmesi için kullanılmaktadır. Mobil uygulama üzerinde geliştirilen çalışmanın grafiksel gösterimi Şekil 1' deki gibidir.



Şekil 1. Çalışma modeli (Proposed architecture)

#### 3.1. Veri Seti (Data Set)

Çalışmada seçili bir bölgedeki yer ve hava istasyonundan alınan 2017 yılı kış ayının hava tahmin raporları/verileri kullanılmıştır. Lufft firmasının ürettiği WS-600 modeli hava istasyonu ve ARS31-UMB, IRS31-UMB yol durum sensörler kullanılan materyallerdir. Bu sensörler; yol yüzeyinin sıcaklığı, yol altı sıcaklığı, yol yüzeyi sıvı miktarı, sıvının donma noktası, Sıcaklık, bağıl nem, rüzgâr hızı, rüzgâr yönü, hava basıncı, yağış tipi ve yağış miktarı gibi hava verileri ölçülmektedir.



### 3.2. Veri Önileme (Data Preprocessing)

Çalışmada kullanılan veriler gerçek ortamdan alındığı için her zaman sağlıklı veri elde edilememektedir. Alınan veriler sistemde kullanılmadan önce temizlenip işlenecek kullanılır hale getirilmektedir.

Gözlemlenebilen/Ölçülebilen bütün sistemler de belirli oranlarda- az ya da çok- kayıp veri varlığı kaçınılmazdır. Veri kaybı belirlenen ya da belirlenemeyen pek çok nedenden kaynaklanabilir. Doğru ve güvenilir analizler için veri kümesinin eksiksiz olması oldukça önemlidir. Kayıp verilerin değerlendirilmesinde ilk yöntem kayıp veri olan satırı yok saymaktır. Ancak kayıp verinin çok olduğu ya da az kayda sahip olan testlerde bu çözüm yanlış değerlere neden olmaktadır. Bu yüzden veri satırının silinmesinin kullanışsız olduğu durumlarda, kayıp verilerin yerine bir değer ataması yapılarak daha doğru sonuçlar elde edilebilmektedir [37]. Bu çalışmada buzlanma tahmininin doğruluğunu arttırmak için veriler işlenerek dengeli hale getirilmektedir.

Kayıp ya da eksik verilerin değerlendirilmesi için sırasıyla aşağıdaki yöntemler kullanılarak veri kümesi dengeli hale getirilmektedir:

- Liste boyunca silme yöntemi
- Doğrusal regresyon yöntemi
- Rastgele alt küme üretilmesi yöntemi

#### 3.2.1. Liste boyunca silme yöntemi (Listwise deletion)

Bir sınıfın örnek sayısının diğer sınıftan fazla olduğu durumlarda örnek sayısı fazla olan sınıf tahmin doğruluğunu negatif etkilemektedir. Bu çalışmada hava ve yer istasyonlarından toplanılan 5 bine yakın örnek bulunmaktadır. Bu örneklerin çoğu buzlanmanın gerçekleşmediği tahmin değişkenlerinin verileridir. Bu yüzden bunların içerisinde eksik değışkene sahip 600'e yakın örnek göz ardı edilmektedir. Eksik veriye sahip olup silinen örneklerden birkaçı Şekil 2'de gösterilmektedir.

```

8 @attribute 'Temperature'          numeric
9 @attribute 'Dew_Point'           numeric
10 @attribute 'Feel_Temperature'    numeric
11 @attribute 'Wind_Gust_C'         numeric
12 @attribute 'Relative_Humidity_Yude' numeric
13 @attribute 'Wind_Spee_km_h'     numeric
14 @attribute 'Wind_Direction'     numeric
15 @attribute 'Icing_forecast' { 'Buzlanma_yok', 'Buzlanma_var'}
16
17
18 % Temperature,Dew_Point, Feel_Temperature,Wind_Gust_C,Relati
19
20
21 @data
22 4.253,-2.909,5.838,9.521,59.670,1.918,295.284,'Buzlanma_yok'
23 4.327,-2.830,6.030,9.615,59.713,1.157,61.758,'Buzlanma_yok'
24 4.327,-2.830,6.076,9.615,59.713,1.456,346.692,'Buzlanma_yok'
25 4.673,-2.507,5.871,9.615,59.700,1.684,255.653,'Buzlanma_yok'
26 4.816,-2.491,5.669,9.615,59.175,2.498,282.309,'Buzlanma_yok'
27 4.816,-2.491,5.669,9.628,59.175,2.105,335.233,'Buzlanma_yok'
28 4.926,-2.743,5.823,9.708,57.639,2.141,281.556,'Buzlanma_yok'
29 5.064,-2.381,5.951,9.748,58.641,1.765,267.212,'Buzlanma_yok'
30 5.064,-2.381,5.951,9.800,58.641,3.002,280.104,'Buzlanma_yok'
31 4.933,-2.561,5.773,9.800,58.392,3.119,85.460,'Buzlanma_yok'
32 4.770,-2.696,5.694,9.800,58.471,1.600,151.235,'Buzlanma_yok'
33 4.770,-2.696,5.535,9.800,58.471,1.316,44.736,'Buzlanma_yok'
34 4.856,-2.522,5.769,9.800,58.877,2.025,228.138,'Buzlanma_yok'
35 4.927,-2.478,5.849,9.800,58.780,0.000,0.000,'Buzlanma_yok'
36 4.927,-2.478,5.969,9.800,58.780,1.901,261.429,'Buzlanma_yok'
37 4.938,-2.537,5.905,9.800,58.477,4.269,26.337,'Buzlanma_yok'
38 4.781,-2.666,5.583,9.708,58.556,0.000,0.000,'Buzlanma_yok'

```

Şekil 2. İşlenen veriler (Processed data)

#### 3.2.2. Doğrusal regresyon yöntemi (Linear regression method)

Yer ve hava istasyonlarından toplanılan 5 bine yakın örnekten çok azında buzlanma durumu oluşmaktadır. Bu yüzden buzlanmanın olduğu örneklerin veri kümesinde korunması önemlidir. Bu örneklerdeki eksik değışkenler doğrusal regresyon yöntemi ile tamamlanmaktadır. Doğrusal Regresyon kullanılarak, örneklere en yakın doğrunun çizilerek sistemin matematiksel olarak modellenmesi ve eksik verilerin tamamlanması sağlanmaktadır. Elde edilen matematiksel modelleme 1 ve 2'de verilmektedir.

$$Rüzgar Yönü = ((-17,5828 \times Sıcaklık) - (24,393 \times Hissedilen Sıcaklık) + (34,8641 \times Rüzgar Şiddeti) + (1,6018 \times) + 3,4677) \quad (1)$$

$$Rüzgar Hızı = ((-0.5543 \times Sıcaklık) + (-0.5134 \times Hissedilen Sıcaklık) + (0.2713 \times Rüzgar Şiddeti) + (-0.1374 \times Bağıl Nem) + (0.82 \times Çiğ Noktası) + 15.6895) \quad (2)$$

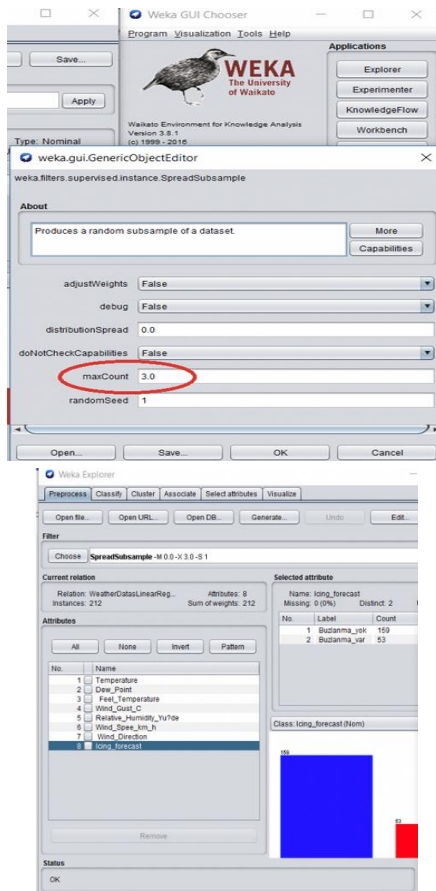
1 ve 2'de gösterilen matematiksel modellemelerde nitelikler ile çarpılan sayısal değerler, o niteliklerin ağırlıklarıdır. Bir niteliğin ağırlığı, sistemi ne kadar etkilediğini gösterir. Örneğin, Rüzgâr Yönü niteliği matematiksel modellemesinde Sıcaklık, Hissedilen Sıcaklık, Rüzgâr Şiddeti ve Bağıl Nem hesaplamada kullanılırken, Çiğ noktası niteliği etkisi (ağırlık) çok az olduğu için hesaba katılmamıştır. Çizelge 1'de hesaplanan veriler yer almaktadır.

#### 3.2.3. Rastgele altküme üretilmesi yöntemi (Random subset generation method)

Eksik verilerin giderilmesi işlemi tamamlandıktan sonra veri setindeki örneklerden 4 bine yakını buzlanmanın oluşmadığı örnekler iken buzlanmanın olduğu temiz örnek sayısı yalnızca 53 tanedir. Bu örnekler ile oluşturulacak bir veri seti dengesiz veri setidir. Çünkü fazla örnek sayısına sahip olan sınıf, doğruluk oranının yanlış değerlendirilmesine neden olmaktadır. Bu gibi durumlarda sınıflandırma süresi uzamaktadır ve yüzde tahmini sapmaktadır. Bu nedenle çalışmada dengesiz veri setinden dengeli veri seti üretmek amacıyla, WEKA filtreleme yöntemlerinden "SpreadSubsample" kullanılarak rastgele alt küme üretilmiştir. Maksimum yayılım miktarı üç kat olarak Şekil 3'te belirlenmiştir.

**Çizelge 1.** Tamamlanan rüzgâr hızı ve rüzgâr yönü verileri (Completed wind speed and wind direction data)

Rüzgâr Hızı (km/sa)	Rüzgâr yönü ( )
2.609	205.351
2.176	167.072
2.701	211.19
1.623	122.361
1.625	123.37
1.480	128.96
1.665	126.428
1.654	127.192
1.647	129.241
1.655	132.691
1.612	134.677
1.6	148.549
1.622	149.679
1.618	149.403
1.617	139.77
1.639	145.668
1.629	147.217
1.666	145.025
1.656	145.778
1.638	144.069
1.675	145.966
1.635	232.506
1.948	250.278
2.518	-



**Şekil 3.** Rastgele alt küme üretimi yönteminde maksimum yayılım oranı seçimi (Maximum propagation rate selection in random subset generation method)

Eksik veriler tamamlanarak veri seti dengeli bir hale getirdikten sonra, sınıflandırma ve tahmin için eğitim veri setinde kullanılmak üzere 53 “Buzlanma Var” sınıfına ait örnek ve 159 “Buzlanma Yok” sınıfına ait örnek bulunmaktadır.

### 3.3. Tahmin Yöntemleri (Prediction Methods)

Yapılan çalışmada oluşturulan dengeli veri seti DVM ve ÇKA yöntemleri kullanılarak anlamlandırılmakta ve gelecek ile ilgili tahminde bulunmaktadır. Bu yöntemlerin seçilme nedeni literatüre göre probleme en uygun olan yöntemler olmalarıdır. Çalışmada önce DVM ve ÇKA kullanılarak veri sınıflandırılmaktadır. Elde edilen sonuçlar kendi algoritmamızı oluştururken - doğrusal denklemlerin doğrusal olmayan denklemlere göre buzlanma tahminlerinde daha iyi sonuçlar vermesi-bize yol göstermiştir. Çalışmada kullanılan veri madenciliği yöntemleri için WEKA yazılım aracı kullanılmaktadır. Elde edilen sonuçlar karşılaştırılmakta ve geliştirilen yeni algoritmanın adımlarını tanımlamada yol göstermektedir.


#### 3.3.1. Destek vektör makineleri (Support vector machines)

Makine öğrenmesi yöntemi olan DVM, sınıflandırma ve regresyon için verileri analiz etmede kullanılan bir denetimli öğrenme modelidir. DVM, yüksek boyutlu fakat az sayıda veri içeren uygulamalarda da başarılıdır [38]. Her biri, iki kategoriden birine ya da diğerine ait olacak şekilde belirtilmiş bir dizi eğitim örneği ele alındığında, DVM eğitim algoritması, verilen iki kategoriden birine ya da diğerine olacak şekilde örnekler atayan bir model oluşturur ve bu onu olasılıksal olmayan ikili doğrusal sınıflandırıcı yapar. Bu model ile örnekler uzaya haritalandırılabilir. İki özellik vektörü ve negatif olmayan katsayılar arasındaki benzerliği hesaplayan bir çekirdek fonksiyonu, karar kuralını  $K(x, x')$  oluşturur. Karar sınırına olan mesafe hesaplanarak yeni örnekler sınıflandırılmaktadır. Eşitlik 3'te sabit bir değere kadar bu mesafe hesabı formülü verilmiştir.

$$h(x) = \sum_{i=1}^n a_i(2y_i - 1)K(x_i, x) \quad (3)$$

Şekil 4'te görüldüğü gibi, DVM sınıflar arası en fazla aralığa sahip (marja) ayırıcı düzlemi bularak sınıflandırma yapar. Bulduğu düzlemin denklemi Eşitlik 4'te ifade edilmektedir.

$$f(x) = w\vec{x} - b \quad (4)$$



Şekil 4. DVM sınıflandırıcı yapısı (SVM structure)

Burada  $w$  ağırlık vektörü,  $b$  ise kayma noktasıdır. İki grup arasındaki mesafe farkı  $b/\|w\|$  ile ifade edilmektedir. Eğitim verileri  $n$  boyutlu  $x$  vektörleriyle ifade edilir. Eğitim verileri doğrusal olarak ayrılabilirse, iki veri sınıfını birbirinden ayıran iki paralel hiperdüzlem seçilebilir, böylece aralarındaki mesafe ayrımı olabildiğince geniş olur. Bu iki hiperdüzlem ile sınırlanan bölge “kenar” olarak adlandırılır ve maksimum paylı hiperdüzlem ikisinin ortasında olan hiperdüzlemdir. Farklı örnekleri ayırmak için kullanılan denklemlere bakıldığında ( $w \cdot \vec{x} - b = 1$  ve  $w \cdot \vec{x} - b = -1$ ), doğrular arası mesafe  $b=2$  olarak bulunmaktadır.

Üstte yer verilen DVM sınıflandırıcısı doğrusal yapıdaki uygulamalarda kullanılmaktadır. Ancak, doğrusal olmayan uygulamalarda sınıflandırma yapabilmek için kernel fonksiyonlarını kullanmak gerekmektedir. Lineer olmayan giriş uzayındaki veriler çekirdek fonksiyonu ile lineer yüksek boyutlu nitelik uzayına dönüştürülür [39].

$$K(u, v) = \phi(u)\phi(v) = (uv + 1)^2 \quad (5)$$

Eşitlik 5’te çekirdek fonksiyonun genel ifade denklemi verilmektedir. Çekirdek denklemleri, bir alandaki doğrusal olmayan ayrılabilir veriyi, örneklerin lineer olarak ayrılabilir hale geldiği başka bir alandan dönüştüren herhangi bir işlev olabilir. Çekirdek denklemleri doğrusal, kuadratik, Gauss veya bu özel amaca ulaşan başka herhangi bir şey olabilmektedir.

Verileri iki ayrı kategoriye böldükten sonra, amacımız iki küme örneklerini ayırmak için en iyi hiperdüzlem elde etmektir [40]. Çalışmamızda Polinomial, Sigmoid ve Gaussian radyal tabanlı çekirdek fonksiyonu kullanılmıştır. Bu fonksiyonların denklemleri sırasıyla Eşitlik 6,7 ve 8’de ifade edilmektedir.

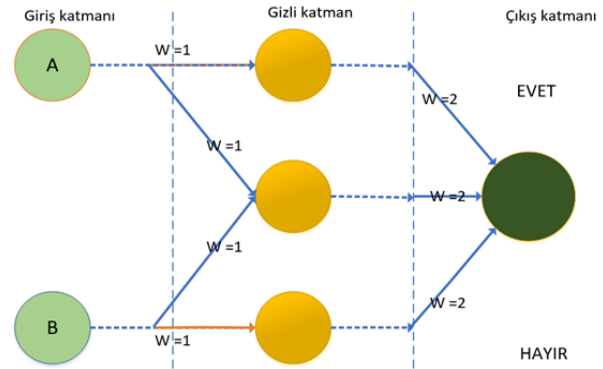
$$K(x_i, x_j) = (p + x_i, x_j)^q \quad (6)$$

$$K(x_i, x_j) = \tanh(kx_i, x_j - \delta) \quad (7)$$

$$K(x_i, x_j) = \exp \exp(-\gamma \|x_i - x_j\|^2) \quad (8)$$

### 3.3.2. Çok katmanlı algılayıcı yapay sinir ağları (A multilayer perceptron Artificial Neural Network)

YSA insan beyninin yapısı ve davranışları örnek alınarak hazırlanmış ve insan beynine benzer yapıda bir modeldir. Bilgileri işlemek için birbirine bağlı basit işlem birimlerinden oluşur. Bu modelin bilgisi, yapay nöronlar arasındaki bağlantıların her birinde bulunan ağırlıkta saklanmaktadır. YSA ile regresyon, sınıflandırma, optimizasyon, karar verme, doğrusal olmayan sistemlerin modellenmesi ve tahmin yürütme gibi işlemler yapılabilmektedir. Bu çalışmada yaygın olarak kullanılan yapay sinir ağı modellerinden ÇKA ağı kullanılmıştır. Burada bulunan ara katmanlar, sürekli bir fonksiyona yaklaşma veya herhangi bir matematik fonksiyonuna uygunluk göstermesini garanti eder [41]. Aynı zamanda etkili öğrenme algoritması, hata toleransı, genelleme kapasitesi ve paralel uygulamaları destekleme kabiliyetleri nedeniyle yaygın şekilde kullanılmaktadır [42]. Şekil 5’te bir ÇKA model yapısı verilmektedir.



Şekil 5. İleri beslemeli ÇKA yapısı (Feedforward MLP neural networks structure)

Şekil 5’te görüldüğü gibi ÇKA birden fazla düğüm katmanından (giriş, gizli ve çıkış katmanı) oluşmaktadır. Her bir katman diğerine bağlıdır. Giriş düğümleri dışındaki tüm düğümler aktivasyon fonksiyonuna sahip bir (nöron) düğümdür. Bu yöntemde, geri yayılım denetimli öğrenme tekniği ağı eğitimi için kullanılmaktadır. Bugüne kadarki en popüler kural, Paul Werbos tarafından geliştirilen, David Parker tarafından yeniden keşfedilen ve David Rumelhart tarafından yaygınlaştırılan geri yayılımdır [43]. Burada giriş katmanı özelliklerin sayısı kadardır. Her düğüme karşılık gelen bağlantının giriş değeri ile belirlenen ağırlık değerinin çarpımının toplamı sigmoidal fonksiyonu belirlemektedir. Ağırlıkların belirlenmesinde en uygun olanı almak için ağ eğitilir. Ağ eğitilirken en uygun ağırlık bulunana kadar ağırlıklar belirli bir şekilde dinamik olarak değiştirilmektedir. Böylece sinaptik bağlantıların güçlü yönleri ayarlanabilmekte ve eğitim setinden alınan her giriş uygun bir şekilde düzenlenmektedir. Bu nedenle düğüm sayısı ve gizli katmanların sayısı eğitim süresince belirlenmelidir [44]. Aynı zamanda problemin kendisine bağlı olarak



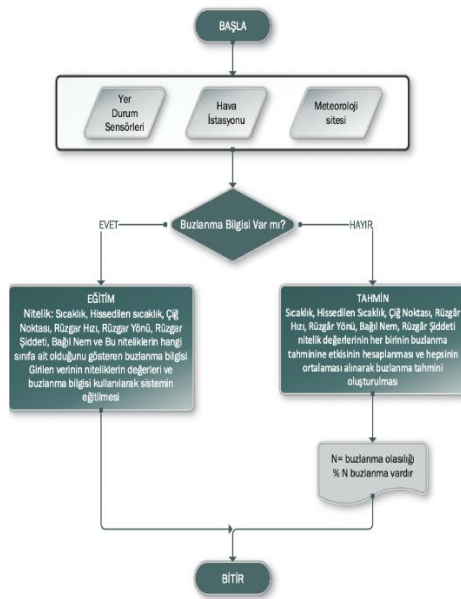
katmanlarda düğüm sayısı değiştiği gibi kullanılan katman sayısı da değişebilmektedir. Buradan anlaşılacağı üzere bir yapay sinir ağı modelinde gizli katmanlarda kaç düğüm kullanılacağı ya da katman sayısını belirlemede çalışma performansı en iyi olanın göz önünde bulundurulması gereklidir. Makalede, geri yayılım denetimli ÇKA yöntemi sınıflandırma ve buzlanma tahmini için diğer bulgular ile analiz için kullanılmaktadır.

### 3.3.3. Önerilen Model (Proposed Model)

Bu çalışmada en doğru tahmini bulabilmek için öncelikle makine öğrenmesi yöntemleri kullanılarak analizler yapılmış ve bunun sonucunda doğrusal olan matematiksel yöntemlerin buzlanma tahmini doğruluk oranını arttırdığı gözlemlenmiştir. Bu gözlemin doğruluğunun ispatı için karmaşık olmayan doğrusal yeni bir algoritma geliştirilmiştir. Geliştirilen algoritma ve diğer yöntemler, yol güzergahı boyunca en doğru buzlanma tahminini bulmak için kullanılmıştır.

Önerilen yöntemin eğitimi için kullanılan giriş değerleri sıcaklık, hissedilen sıcaklık, çiğ noktası, rüzgâr hızı, rüzgâr yönü, bağıl nem, rüzgâr şiddeti ve buzlanma bilgisidir. Her ne kadar yukarıdaki nitelikler algoritmanın girişi olarak kullanılsa da buzlanma bilgisi değeri ilk 7 özneliğin çıktısıdır. Bu nitelikler hava istasyonu, yer durum sensörleri ve meteoroloji web sitesinden alınmıştır. Eğitim tamamlandıktan sonra meteorolojiden alınan hava durumu nitelikleri kullanarak buzlanma tahmini yapılmıştır.

Kullanıcılara sunulan mobil uygulamada öntümüzdeki 12 saatin birer saatlik periyotlarla buzlanma tahmini yapılmaktadır. Bu tahmin yüzde olarak 0 ile 100 değerleri arasında bir çıkış üretmektedir. Tahmin çıkış değeri %50 den büyük ise “Buzlanma var” değilse “Buzlanma yok” şeklinde sınıflandırılmaktadır. Şekil 6’ da uygulamanın akış diyagramı verilmiştir.



Şekil 6. Önerilen modelin akış diyagramı (Flow chart of the proposed model)

Eğitimde kullanılan girişler Eşitlik 9’da verilmiştir.

$$N_{samples}^{attribute} = \{N_s^1 \dots N_s^7\} = \begin{cases} Sıcaklık \\ \dots \\ Basınç \end{cases} \quad (9)$$

Eşitlik 9’da verilen denklem sıcaklık, basınç, çiğ noktası, rüzgâr hızı ve yönü gibi niteliklerin örneklerini ifade etmektedir. Örneğin  $\{N_{34}^{sıcaklık}\}$  ifadesi sıcaklık niteliğinin 34. verisini ifade etmektedir. Bu durumda bu örneğin ağırlıkları  $\{w_{34}^{sıcaklık}\}$  şeklinde ifade edilmektedir. Aynı örneğin buzlanma bilgisi de  $P_{34}$  ile gösterilmektedir.  $P_s$  ifadesi buzlanma bilgisini göstermektedir.

$$P_s = \begin{cases} buzlanma var \\ buzlanma yok \end{cases} \quad (10)$$

Eşitlik 10’da verilen denklemde nominal olarak (buzlanma var – buzlanma yok) elde edilen değerler numerik ifadelerle dönüştürülerek kullanılmaktadır.

$$w_s^a = \left| \frac{P_{s+1}^a - p_s^a}{N_{s+1}^a - N_s^a} \right| \quad (11)$$

Eşitlik 11’de verilerin ağırlık hesaplaması denklemi verilmektedir. Denklemde  $P_s$  ifadesi buzlanma bilgisini ve  $N_s^a$  özneliklerin bilgisini ifade etmektedir. Verilerin ağırlıklarının eğitim için kullanılması YSA gibi birçok sınıflandırma algoritmasında kullanılmaktadır.

Önerilen modelde öznelikler için ortalama ağırlıklar hesaplanmaktadır. Ortalama ağırlık hesaplanırken tüm verilerin  $[1, w_1^a, w_2^a \dots w_n^a]$  ağırlıklarını içeren listeden faydalanılmaktadır. Bu listenin ilk değeri 1 olarak atanmaktadır.

$$W^a = \frac{1 + \sum_{k=1}^s w_k^a}{samples(s)} \quad (12)$$

Eşitlik 12’ de tüm öznelikler için ortalama ağırlık hesabı ifade edilmektedir.

Eğitim ile hava durumu özneliklerinin buzlanmayı nasıl etkilediği hesaplanmaktadır. Hesaplanan etki yeni buzlanma tahmini oluşturulması için kullanılmaktadır.

$$E = [\sum_{a=1}^7 (\Delta N^a \cdot W^a)] \quad (13)$$

Eşitlik 13’te etki -özneliklerin buzlanmayı nasıl etkilediği- verilmektedir.

$$Q_s = P_{s-1} + E \quad (14)$$

Son olarak buzlanma tahmini denklemi Eşitlik 14’te  $Q_s$  ile gösterilmektedir.

### 3.4. Geliştirilen Mobil Uygulama (Proposed mobile application)

Bu çalışmada yollardaki buzlanmadan kaynaklı kazaların önlenmesine yönelik bir tahmin algoritmasının yanı sıra mobil uygulama geliştirilmiştir. Geliştirilen mobil uygulama Android platform üzerinde tasarlanmıştır. Mobil uygulamada Şekil 7’de verildiği gibi AccuWeather.com sitesinden alınan hava veri değişkenleri geliştirilen tahmin algoritmasında giriş

değerleri olarak kullanılmakta ve sonucunda buzlanma tahmini gösterilmektedir. Bu sayede karayollarında sürüş halinde kullanıcılar önceden uyarılmaktadır.

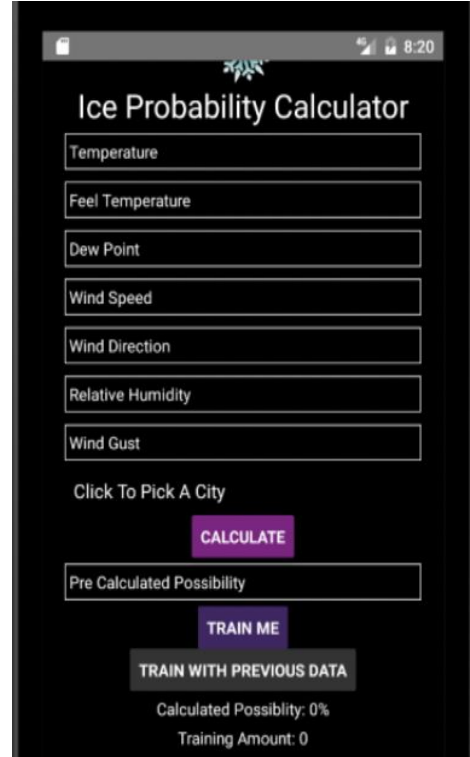
Şekil 8’de ve Şekil 9’da geliştirilen mobil uygulamanın arayüzü ve kod yapısının bir kısmı görülmektedir.

Veriler_ID	TIME_Unique	Temperature
12	2016-11-12 06:00:00	275
13	2016-11-12 09:00:00	285
14	2016-11-12 12:00:00	287
15	2016-11-12 15:00:00	282
16	2016-11-12 18:00:00	275
17	2016-11-12 21:00:00	275
18	2016-11-13 00:00:00	277
19	2016-11-13 03:00:00	279
20	2016-11-13 06:00:00	282
21	2016-11-13 09:00:00	282
22	2016-11-13 12:00:00	283
23	2016-11-13 15:00:00	280
24	2016-11-13 18:00:00	276
25	2016-11-13 21:00:00	271
26	2016-11-14 00:00:00	269
27	2016-11-14 03:00:00	268
28	2016-11-14 06:00:00	273
29	2016-11-14 09:00:00	278
30	2016-11-14 12:00:00	278
31	2016-11-14 15:00:00	273
32	2016-11-14 18:00:00	268
33	2016-11-14 21:00:00	265
34	2016-11-15 00:00:00	263
35	2016-11-15 03:00:00	262
36	2016-11-15 06:00:00	267

Maximum_Temperature	Minimum_Temperature	Hun
275	275	80
285	285	63
287	287	55
282	282	65
275	275	81
275	275	77
277	277	79
279	279	88
282	282	80
282	282	95
283	283	63
280	280	61
276	276	79
271	271	82
269	269	77
268	268	75
273	273	82
278	278	57
278	278	53
273	273	59
268	268	86
265	265	77
263	263	74
262	262	72
267	267	75

Şekil 7. Meteorolojiden alınan veriler (Data from meteorology)



Şekil 8. Uygulama Arayüzü (Interface of the application)

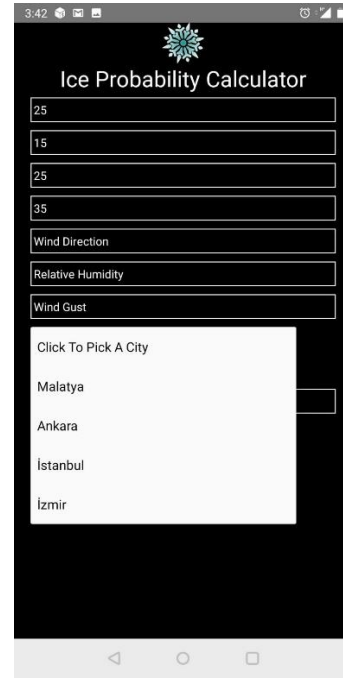
```

25 super(prop):
26
27
28
29
30 this.state = {
31   temp:null,
32   feeltemp:null,
33   dewpoint:null,
34   windspeed:null,
35   winddirection:null,
36   humidity:null,
37   windgust:null,
38   percent:null,
39   trainamount:0,
40   postPercent:0,
41   city:'empty'
42 }
43
44
45 render() {
46   return (
47     <ScrollView style={styles.outercontainer}>
48       <View style={styles.container}>
49         <Image source={require('./img/ice.png')} style={styles.logo} />
50         <Text style={styles.header}>Ice Probability Calculator</Text>
51
52         <TextInput placeholder="Temperature" placeholderTextColor="white"
53           onChangeText={temp => this.setState({temp})}
54           value={this.state.temp == null ? '' : this.state.temp.toString}
55           />
56
57         <TextInput placeholder="Feel Temperature" placeholderTextColor="white"
58           onChangeText={feeltemp => this.setState({feeltemp})}
59           value={this.state.feeltemp == null ? '' : this.state.feeltemp}
60           />

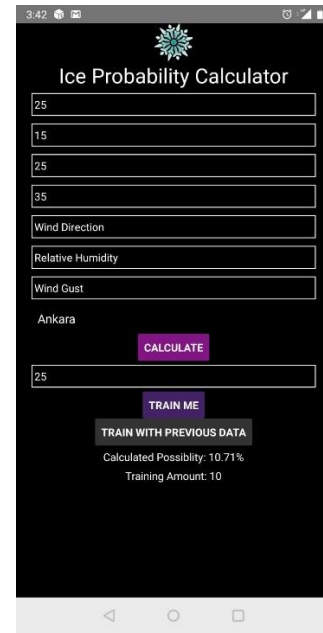
```

Şekil 9. Uygulama arayüz kod kısmı (Frontend code part of the application)

Geliştirilen mobil uygulama tek bir sayfa olarak tasarlanmıştır. Şekil 10'da görüldüğü gibi meteorolojiden alınacak hava tahmin değerleri için öncelikle şehir seçilmektedir. Uygulamada sıcaklık, basınç gibi hava özneliklerini ifade eden metin kutuları bulunmaktadır. Şekil 11'de görüldüğü gibi bu metin kutularının içerisine hava durumu verileri girilmektedir. Daha sonra hespla butonuna basılarak tahmin yapılmaktadır. Elde edilen buzlanma tahmin değerleri eğitim butonuna basıldığında eğitime eklenmekte ve tahmin iyileştirilmektedir.



Şekil 10. Mobil uygulama parametre seçim görüntüsü (Mobile application parameter selection screen view)



Şekil 11. Mobil uygulama sonuç görüntüsü (Mobile application result screen view)

#### 4. BULGULAR (RESULTS)

Bu çalışmada, buzlanma tespiti için literatür temel alınarak makine öğrenmesi yöntemlerinden DVM ve YSA kullanılmıştır. Yöntemlerin analizi açık kaynak kodlu veri madenciliği programlarından olan WEKA üzerinde gerçekleştirilmiştir. Çalışmalar sonucunda elde edilen buzlanma tahmin değerleri, gerçek buzlanma değerleri ile karşılaştırılmış ve son olarak, kullanılan yöntemlerin bulunan doğruluk oranları karşılaştırılarak yorumlanmıştır.

Çalışma kapsamında, DVM yönteminin farklı fonksiyonları incelenmiştir. Doğrusal yöntem ile beraber doğrusal olmayan yapıda Polinomiyal, Radyal tabanlı ve Sigmoid olmak üzere 3 Kernel fonksiyon kullanılmıştır. Analiz sonuçlarına ait sayısal değerler Çizelge 2'de verilmiştir.

**Çizelge 2.** DVM Kernel fonksiyonlarının doğruluk yüzdeleri (Accuracy percentages of SVM Kernel functions)

Kernel fonksiyonları	Doğruluk Oranı(%)
Doğrusal Destek Vektör Makineleri	%86.3208
Polinomiyal Destek Vektör Makineleri	%58.0189
Radyal Tabanlı Destek Vektör Makineleri	%84.434
Sigmoid Destek Vektör Makineleri	%75.00

Çizelge 2'de verilen analiz sonuç değerleri incelendiğinde Sigmoid, Radyal tabanlı, polinomiyal ve doğrusal fonksiyonlar arasında en iyi başarımların Doğrusal DVM olduğu gözlenmiştir. Çalışmada kullanılan diğer yöntem ÇKA sinir ağı modelidir. ÇKA modelinde kullanılan parametreler;


- Öğrenme Oranı = 0.3
- Momentum Oranı = 0.2
- Eğitim Zamanı = 500 birim

ÇKA sinir ağı modelinde gizli katman sayısı genellikle giriş katmanı ile çıkış katmanı düğüm sayısı arasında bir değer veya ortalamaları alınarak bulunmaktadır. Ara katman düğüm sayıları 1 ile 6 arasında bakıldığında, 4 düğüm sayısı en iyi doğru sınıflandırılan örnek yüzdesini vermektedir (Çizelge 3).

**Çizelge 3.** Düğüm sayısına göre doğru sınıflandırılan örnek yüzdesi (Percentage of samples correctly classified by number of nodes)

Ara katman düğüm sayısı	Doğruluk Oranı(%)
1	%83.9623
2	%83.9623
3	%85.8491
4	%87.2642
5	%86.3208
6	%86.3208

Ara katmanda düğüm sayısının artması doğruluk oranında sapmalara neden olduğu için ara katman sayısı 4 olarak belirlenmiştir. Şekil 12'de 4 düğümlü sinir ağı grafiksel olarak gösterilmektedir.



**Şekil 12.** Çok Katmanlı Algılayıcı sinir ağı grafiksel kullanıcı arayüzü (Multi-layer perceptron neural network graphical user interface)

ÇKA sinir ağı modelinde en iyi başarımların performansının %87.2642 olduğu gözlenmiştir. Her iki yöntemden elde edilen sonuçlar karşılaştırıldığında 4 ara katman sayısı olan ÇKA sinir ağı modeli ile Doğrusal fonksiyonlu DVM yönteminin en başarılı yöntemler olduğu ve başarımlarının birbirine çok yakın olduğu görülmüştür. Her iki yöntem matematiksel denklemleri incelendiğinde kabaca her bir eğitim verisinin ağırlıklarına çarpımı ile bulunan bir yapı görülmektedir. Bu incelemeler sonucunda doğrusal matematiksel fonksiyonların buzlanma tespiti için en iyi yöntem olduğu görülmüştür. Bu tespitten yola çıkılarak geliştirilen mobil uygulamada kullanılmak üzere doğrusal fonksiyonlu bir algoritma önerilmiştir.

Çalışmada önerilen yöntemi beslemek için giriş değeri olarak geçmiş buzlanma tahmin verileri kullanılmıştır. Akıllı ulaşım sistemleri için tasarlanan yol durum sensörleri sayesinde yol yüzey sıcaklığını, hava sıcaklığını, hissedilen nemi, hava basıncını ve yol yüzeyindeki tuz miktarını anlık olarak işleme almaktadır [45]. Bu verilerle eğitilen yöntem artık kendi buzlanma tahminini üretmek için hazırdır. Yapılan buzlanma tahminleri, gerçek buzlanma değerleri ile karşılaştırılmıştır. Sonuçlar göstermiştir ki doğrusal matematiksel çözümler tahminin doğruluk oranını artırmaktadır. Ancak bu artış yöntemin gerçek verilerle beslenme sayısı ile doğru orantılıdır. Buzlanmayı etkileyen her bir nitelik için hesaplamalar yapılmış ve her niteliğin buzlanmaya etkisi dikkate alınmıştır.

Model eğitildikçe tahmin doğruluğunda iyileşme ve hata oranında azalma olduğu gözlemlenmiştir. Sistem ilk eğitildiğinde hata oranı %87 çıkmış, eğitim sayısı arttıkça hata oranı %40 a kadar gerilemiştir. Geliştirilen modelde hatanın nicel büyüklüğü her ne kadar büyük olsa da hatadaki yönelim sürekli olarak sifira doğrudur. Sistemi eğitmek için kullanılan örnek sayısı ile tahmin doğruluğunun doğru orantılı olduğu görülmektedir. Şekil



13'te eğitim sayısı arttıkça iyileşen tahmin değerleri gösterilmektedir.


```

C:\Windows\system32\cmd.exe
D:\Çalışmalar\Yüksek Lisans_TEZ_Calışması\Y.
0.00 87 Error Rate = 87.00%
0.00
54.13 0 Error Rate = 70.56%
54.13
79.50 0 Error Rate = 73.54%
79.50
71.62 0 Error Rate = 73.06%
71.62
71.71 0 Error Rate = 72.79%
71.71
81.94 0 Error Rate = 74.32%
81.94
83.19 0 Error Rate = 75.58%
83.19
83.84 0 Error Rate = 76.62%
83.84
79.53 0 Error Rate = 76.94%
79.53
76.05 0 Error Rate = 76.85%
76.05
77.40 0 Error Rate = 76.90%
77.40
70.79 0 Error Rate = 76.39%
70.79
78.19 0 Error Rate = 76.53%
78.19
72.00 0 Error Rate = 76.21%
72.00
85.71
77.76 100 Error Rate = 40.31%
77.76
28.57 100 Error Rate = 40.46%
28.57
71.92 100 Error Rate = 40.40%
71.92
85.71 100 Error Rate = 40.27%
85.71
96.97 100 Error Rate = 40.09%
96.97
100.00 100 Error Rate = 39.90%
100.00
14.29 100 Error Rate = 40.12%
14.29
71.43 100 Error Rate = 40.06%
71.43
58.50 100 Error Rate = 40.07%
58.50
93.02 100 Error Rate = 39.91%
93.02
14.29 100 Error Rate = 40.13%
14.29
85.71 100 Error Rate = 40.01%
85.71
14.29 100 Error Rate = 40.22%
14.29
14.88 100 Error Rate = 40.43%
14.88

```

Şekil 13. Tahmin değerleri (Prediction values)

Bu çalışmada eğitim veri kümesinden alınan buzlanma tahmin oranları % olarak ifade edilmektedir. “Buzlanma Var” sınıfı %100, “Buzlanma Yok” sınıfı %0 olarak atanmaktadır. %50 ve üzerindeki tahminler “Buzlanma var” olarak öngörülürken, %50 ve altı durumlarda buzlanma olma ihtimali düşük olduğu ifade edilmektedir ve “Buzlanma yok” olarak öngörülmektedir. Geliştirilen algoritmada tüm verilere bakıldığında yaklaşık %75 oranında başarı sağlandığı görülmüştür. YSA, DVM ve geliştirilen modele ait doğruluk değerleri Şekil 14'te gösterildiği gibidir.



Şekil 14. Önerilen model ile DVM ve YSA algoritmalarının doğruluk değerlerinin karşılaştırılması (Comparison of the proposed model with the accuracy rates of DVM and ANN algorithms)

## 6. SONUÇ (CONCLUSION)

Bu çalışmada, ülkemizde yerel bölgelerde kullanılmak üzere sürücülerini buzlanma olup olmadığına dair uyarabilecek bir erken uyarı sistemi geliştirilmiştir. Araç kullanırken kolaylıkla erişilebilir olması amacıyla bu sistem mobil telefon üzerinde geliştirilmiştir. Sistemin kullanım kolaylığı düşünülerek prototip olarak basit bir arayüz tasarlanmıştır.

Çalışmada veri madenciliği yöntemlerinden geleceğe dair analiz ve yorumlama hususunda sıklıkla tercih edilen çok katmanlı algılayıcı sinir ağı yöntemi ve destek vektör makineleri kullanılmıştır. DVM, ÇKA ve yeni geliştirilen modeller ile buzlanma tahminleri yapılmış ve bu tahminler gerçek değerler ile karşılaştırılarak ne kadar doğru tahmin yapıldığı yüzdelik olarak ortaya konulmuştur.

Toplam doğru sınıflandırılan örnek yüzdesine bakıldığında 4 ara katmanlı ÇKA sinir ağı modelinin %87,26 doğruluk oranı ile en iyi performansı gösterdiği ardından %86,32 doğruluk oranı ile Doğrusal fonksiyonlu DVM modeli ve %75,47 doğruluk oranı ile geliştirdiğimiz modelin geldiği görülmüştür. Bu çalışmada ÇKA ve DDVM baz alınarak geliştirilen model istenilen performansı yakalamamaktadır, ancak modelin eğitim sayısı arttıkça buzlanma tespiti doğruluğunun artması, doğrusal matematiksel çözümlerle buzlanma tahmini yapmada doğrusal olmayan yöntemlerden daha başarılı olduğunu ortaya koymuştur. Çalışmada buzlanmanın olduğu durumlara ait örneklem sayısı arttıkça modelin başarı oranı da artmaktadır.

## ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.



**YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)**

**Hatice KABAOĞLU:** Deneyleri yapmış, sonuçlarını analiz etmiş ve makalenin yazım işlemini gerçekleştirmiştir.

**Emine UÇAR:** Sonuçları analiz etmiş ve makalenin yazım işlemini gerçekleştirmede yardım etmiştir.

**Fecir DURAN:** Deneyleri yapmış, sonuçlarını analiz etmiş ve makalenin yazım işlemini gerçekleştirmede yardım etmiştir.

**ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)**

Bu çalışmada herhangi bir çıkar çatışması yoktur.

**KAYNAKLAR (REFERENCES)**

- [1] Balbay, A., Esen, M., "Yollardaki kar ve buzu önleyici sistemler", *Fırat Üniversitesi Doğu Araştırmaları Dergisi*, 6(1): 169–174, (2007).
- [2] Joshi, A., Kamble, B., Joshi, V., Kajale, K. and Dhange, N., "Weather Forecasting and Climate Changing Using Data Mining Application", *International Journal of Advanced Research in Computer and Communication Engineering*, 4(3): 19–21, (2015).
- [3] Drezga, I. and Rahman, S., "Short-term load forecasting with local ANN predictors", *IEEE Transactions on Power Systems*, 14(3): 844–850, (1999).
- [4] Chen, S. M. and Hwang, J. R., "Temperature prediction using fuzzy time series", *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 30(2): 263–275, (2000).
- [5] De Giorgi, M. G., Ficarella, A. and Tarantino, M., "Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods", *Department of Engineering for Innovation*, 36(7): 3968–3978, (2011).
- [6] Lee, M., & Kim, M., "Development of Real-Time Road Surface Condition Determination Algorithm Using an Automatic Weather System", *In 2016 6th International Conference on IT Convergence and Security (ICITCS)*, Prague, Czech Republic, 1–2, (2016).
- [7] Yang C. H., Park M. S., Yun D. G., "A Road Surface Temperature Prediction Modeling for Road Weather Information System", *Journal of Korean Society of Transportation*, 29(2): 123–131, (2011).
- [8] Krsmanc R., Sajnslak A., Carman S., Korosec M., "Metro Model Testing at Slovenian Road Weather Stations and Suggestions for Further Improvements", *16th International Road Weather Conference in Helsinki*, (2012).
- [9] Bogren, J., Gustavsson, T., Nordin, L., Ekström, P., & Sjölander, P. O., "SRIS—Slippery Road Information System", *In Proc., of the 14th Standing International Road Weather Commission—SIRWEC Conf*, Stockholm, Sweden, (2008).
- [10] Yang C. H., Yun D. G., Sung J. G., "Validation of a Road Surface Temperature Prediction Model Using Real-time Weather Forecasts", *KSCE Journal of Civil Engineering*, 16: 1289–1294, (2012).
- [11] Jokela, M., Kutila, M., & Le, L., "Road condition monitoring system based on a stereo camera", *In 2009 IEEE 5th International conference on intelligent computer communication and processing*, Romania, 423–428, (2009).
- [12] Yamada, M., Oshima, T., Ueda, K., Horiba, I., & Yamamoto, S., "A study of the road surface condition detection technique for deployment on a vehicle", *JSAE review*, 24(2): 183–188, (2003).
- [13] Dregza, I. and Rahman, S., "Short-term load forecasting with local ANN predictors", *IEEE Transactions on Power Systems*, 14(3): 844–850, (1999).
- [14] Taylor, J.W. and Buizza, R., "Neural network load forecasting with weather ensemble predictions", *IEEE Transactions on Power Systems*, 17(3):626–632, (2002).
- [15] Sapankevych, N., I. and Sankar, R., "Time series prediction, using support vector machines: a survey", *IEEE Computational Intelligence Magazine*, 4(2): 24–38, (2009).
- [16] Lu, W., Wang, W., Leung, Y. T. A., Lo, S.-M., Yuen, R. K. K., Xu, Z. and Fan, H., "Air pollutant parameter forecasting using support vector machines", *Conference on Proceedings of the 2002 International Joint Neural Networks*, USA, 630–635, (2002).
- [17] Rao, T., Rajasekhar, N. and Rajinikanth, T. V., "An efficient approach for Weather forecasting using Support Vector Machines", *International Conference on Computer Technology and Science*, 208–212, (2012).
- [18] Perrone, M. P., "General Averaging Results for Convex Optimization", *Proceeding of the 1993 Connectionist Models Summer School*, *Psychology Press*, New York, USA, 364–371, (1994).
- [19] Pal, N. R., Pal, S., Das, J. and Majumdar, K., "SOFM-MLP: A hybrid neural network for atmospheric temperature prediction", *IEEE Transactions on Geoscience and Remote Sensing*, 41(12): 2783–2791, (2003).
- [20] Chen, N., Qian, Z., Nabney, I. T. and Meng, X., "Wind power forecasts using Gaussian processes and numerical weather prediction", *IEEE Transactions on Power Systems*, 29(2): 656–665, (2014).
- [21] Costa, M. and Pasero, E., "Artificial Neural Systems for Verglass Forecast", *International Joint Conference on Neural Networks*, Washington, USA, 258–262, (2001).
- [22] Li, J., "A Combination of DE and SVM with Feature Selection for Road Icing Forecast", *2nd International Asia Conference on Informatics in Control, Automation and Robotics*, 509–512, (2010).
- [23] Mandale, A. and Jadhawar, B. A., "Weather forecast prediction: a Data Mining application", *International Journal of Engineering Research and General Science*, 3(2), 1279–1284, (2015).
- [24] Lampton, A. and Valasek, J., "Prediction of icing effects on the lateral/directional stability and control of light airplanes", *Aerospace Science and Technology*, 23(1): 305–311, (2012).

- [25] McCann, D. W., "NNICE – A Neural Network Aircraft Icing Algorithm", *Environmental Modelling & Software*, 20(10): 1335–1342, (2005).
- [26] Wang, Z., & Li, C., "River ice forecasting based on genetic neural network", *In 2009 International Conference on Information Engineering and Computer Science*, China, 1–4, (2009).
- [27] Savadjiev, K. and Farzaneh, M., "Modeling of icing and ice shedding on overhead power lines based on statistical analysis of meteorological data", *IEEE Transactions on Power Delivery*, 19(2): 715–721, (2004).
- [28] Luo, Y., Li, Y., Yao, Y., & Zhan, X., "Research on power transmission line ice prediction system based on BP neural network", *In Proceedings of 2012 International Conference on Measurement, Information and Control*, 2: 817–820, (2012).
- [29] Chen, S. Q. and Guo, S. Z., "Fuzzy Prediction", *Guiyang: Guizhou Science & Technology Press*, 332–342, (1994).
- [30] Liu, C., Liu, H. W., Wang, Y. S., Lu, J. Z., Xu, X. J. and Tan, Y. J., "Research of icing thickness on transmission lines based on fuzzy Markov chain prediction", *IEEE International Conference on Applied Superconductivity and Electromagnetic Devices*, Beijing, China, 327–330, (2014).
- [31] Huang, J., Yang, H., Hunan, Y. W., "Forecast of Line Ice-Coating Degree Using Circumfluence Index & Support Vector Machine Method", *International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, China, 327–330, (2016).
- [32] Li, Q., Li, P., Zhang, Q., Ren, W., Cao, M. and Gao, S., "Icing Load Prediction for Overhead Power Lines Based on SVM", *Proceedings of 2011 International Conference on Modelling, Identification and Control*, China, 104–108, (2011).
- [33] Patel, B. G., Dabhi, V. K., Tyagi, U. and Shah, P. B., "A Survey on Location Based Application Development for Android Platform", *International Conference on Advances in Computer Engineering and Applications*, Ghaziabad, India, 731–739, (2015).
- [34] López, V. F., Medina, S. L. and de Paz, J. F., "Taranis: Neural networks and intelligent agents in the early warning against floods", *Expert Systems with Applications*, 39(11): 10031–10037, (2012).
- [35] Lee, M., Bak, C. and Lee, J. W., "A prediction and auto-execution system of smartphone application services based on user context-awareness", *Journal of Systems Architecture*, 60(8): 702–710, (2014).
- [36] Mantas, V.M., Liu, Z., Pereira, A.J.S.C., "A web service and android application for the distribution of rainfall estimates and earth observation data", *Computers & Geosciences*, 77: 66–76, (2015).
- [37] Sezgin, E., & Çelik, Y., "Veri madenciliğinde kayıp veriler için kullanılan yöntemlerin karşılaştırılması", *Akademik Bilişim Konferansı*, Akdeniz Üniversitesi, Türkiye, 23–25, (2013).
- [38] Shen, J., Pei, Z. J., & Lee, E. S., "Support vector regression in the analysis of soft-pad grinding of wire-sawn silicon wafers", *Cybernetics and Information Technologies Systems and Applications (CITSA)*, 21–25, (2004).
- [39] Güner, N., & Çomak, E., "Mühendislik öğrencilerinin matematik I derslerindeki başarısının destek vektör makineleri kullanılarak tahmin edilmesi", *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 17(2): 87–96, (2011).
- [40] Dan, L., Lihua, L. and Zhaoxin, Z., "Research of Text Categorization on WEKA", *Third International Conference on Intelligent System Design and Engineering Applications (ISDEA)*, Hong Kong, China, 1129–1131, (2013).
- [41] Dantas, L. and Valença, M., "Using Neural Networks In The Identification Of Signatures For Prediction Of Alzheimer's Disease", *IEEE 26th International Conference on Tools with Artificial Intelligence (ICTAI)*, Limassol, Cyprus, 238–242, (2014).
- [42] Maysanjaya, D., Nugroho, H. A and Setiawan, N. O., "A Comparison of Classification Methods on Diagnosis of Thyroid Diseases", *2015 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, Surabaya, Indonesia, 89–93, (2015).
- [43] Rumelhart, D. E., Hinton, G. E. and Williams, R. J., "Learning Internal Representations by Error Propagation", *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, (1): 318–362, (1986).
- [44] Halder, C., Paul, J. and Roy, K., "Comparison of The Classifiers In Bangla Handwritten Numeral Recognition", *2012 International Conference on Communication and Computing (ICRCC)*, Tiruvannamalai, India, 272–276, (2012).
- [45] Duran, F., & Teke, M., "Akıllı yol durum sensörü tasarımı", *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 11(1): 396–401, (2019).