

İki Parçalı Ağda Bağlantı Tahminine Dayalı İlgi Çekici Nokta Tavsiyesi

Point-of-Interest Recommendation Based on Link Prediction in Bipartite Network

Elifgöl ÇAKMAK¹ , Buket KAYA² , Mehmet KAYA³ 

¹Bilgisayar Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

²Elektrik ve Otomasyon Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

³Bilgisayar Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

(elifgulcakmak@gmail.com, bkaya@firat.edu.tr, kaya@firat.edu.tr)

Received: Sep.3, 2021

Accepted: Sep.16, 2021

Published: Oct.20, 2021

Özetçe— Konum tabanlı sosyal ağların kullanımı her geçen gün artmaktadır. Bu ağlarda kullanıcılar beğendikleri ilgi noktalarını (POI) check-in yapar ve bir anlamda gelecekteki kullanıcılara tavsiyelerde bulunurlar. Bu makalenin amacı, bağlantı tahmini yöntemini kullanarak aynı memleketteki kullanıcıların benzer POI'ler için check-in yapıp yapmadıklarını tespit etmek ve böylece yeni POI'ler önermektir. Yöntem önce kullanıcı-POI ikili ağını modeller ve ardından bağlantı tahmin yöntemi tarafından yeni öneriler oluşturulur. Foursquare'de gerçek veriler üzerinde yapılan testler, önerilen yöntemin yüksek doğruluk değerlerine ulaştığını göstermiştir.

Anahtar Kelimeler: Makine Öğrenmesi, Tavsiye Sistemler, Konum Tabanlı Sosyal Ağlar, İlgi Çekici Nokta

Abstract—The use of location-based social networks is increasing day by day. In these networks, users check-in Point of Interest (POI) that they like, and in a sense, they advise future users. The aim of this paper is to detect whether users from the same hometown check-in for similar POIs using the link prediction method, thus recommending new POIs. The method first models the user-POI bipartite network, and then new recommendations are generated by the link prediction method. Experiments conducted on real data in Foursquare have shown that the proposed method achieves high accuracy values.

Keywords: Machine Learning, Recommendation Systems, Location Based Social Networks, Point of Interest

1.Giriş

Teknolojinin gelişimiyle birlikte dünyadaki internet kullanımı da aynı oranda artmaktadır. Sosyal ağlar vasıtası ile konum bilgileri, GPS yardımıyla kullanıcıların buldukları mekânda ne zaman buldukları veya mekânın özelliklerinin sosyal medya üzerine yansıtılır. Çalışma sosyal medya kullanıcılarının (Foursquare, Swarm) önceki konumlarına bakılarak kullanıcının yaşadığı yeri veya turist olarak gittiği yerleri düzenlemeyi ve gezilecek yerlerin daha kolay bulunmasını amaçlamaktadır. Bir sosyal medya kullanıcısının önceden yapmış olduğu check-in'leri ve yer bildirimlerini göz önüne alır. Bunlara ek olarak kullanıcıların hometown (memleket) bilgileri de toplanıp kullanılmaktadır. Bu işlemler gerçekleştirilirken kullanıcıların önceden ziyaret etmiş olduğu yerlerin sınıflandırılması yapılır.

Bu sınıflandırma; alışveriş merkezlerini, havalimanlarını, restoranları, tarihi olan bir müze veya tarihi yapı mekânlarında yapılan check-in'leri içermektedir.

Sınıflandırılmış check-in'lere bakılarak konum tabanlı sosyal ağ kullanan kullanıcıların mekânlar için kişisel davranışları çözümlenmektedir. Uygulamalar üzerinden geçmişte yapılan check-in bildirimlerine bakılarak mekânların ve kişilerin özelliklerini, geçmiş yer bildirim hareketliliklerini ortaya çıkarmaktadır. Son olarak kullanıcının kendi memleket bilgisiyle beraber önceden orada bulunan aynı memleket bilgisine sahip kullanıcıların tercih ettiği noktalara bakarak yönlendirilme yapılması amaçlanmaktadır.

2. İlgili Çalışmalar


Konum tabanlı sosyal ağlar (LBSN'ler) son yıllarda artan sayıda kullanıcıyı cezbetmiş ve bu da büyük miktarda coğrafi ve sosyal veri ile sonuçlanmıştır. Bu tür LBSN verileri, konum tavsiyesi gibi konum tabanlı uygulamaları geliştirmek için insan hareketini sosyo-mekansal davranışları incelemek için benzeri görülmemiş bir fırsat sağlar [1]. Sosyal ağ, arkadaşlık, ortak çıkarlar ve paylaşılan bilgi gibi bir veya daha fazla belirli karşılıklı bağımlılık türüyle birbirine bağlanan bireylerden oluşan bir sosyal yapıdır. Genel olarak, bir sosyal ağ hizmeti, bir web sitesi gibi çevrimiçi platformlar aracılığıyla insanlar arasındaki gerçek hayattaki sosyal ağları oluşturur ve yansıtır; kullanıcılara İnternet üzerinden fikirlerini, etkinliklerini ve ilgi alanlarını paylaşmaları için yollar sağlar [2]. LBSN'lerdeki çeşitli uygulamalar arasında, konum tavsiyesi, kullanıcıların ilginç olmayan öğeleri filtrelemesine ve sanal pazarlamaya da fayda sağlayabilecek ve ayrıca karar verme süresini kısaltmasına yardımcı olmasından dolayı, son yıllarda çok kullanışlı bir hale gelmiştir. Check-in davranışının en önemli özelliklerinden biri kullanıcı tarafından yönlendirilen özelliktir [3].

Noulas ve diğ. [4], bir konumun popüleritesini, yani bir konumdaki toplam check-in sayısını, bir özellik olarak değerlendiren ve kullanıcının yerini tahmin etmek için denetimli öğrenme tekniğini kullanmıştır. Deveaud ve diğ. [5], bir yerin popüleritesinin, İlgi Çekici Nokta (İÇN) önerisi için sıralamayı öğrenme tekniğindeki etkin bir özellik olduğunu göstermiştir. Yuan ve diğ. [6], bir kullanıcının uzak bir İÇN'yi ziyaret etme isteğini modellemek için bir güç kanunu dağılımı kullandı. Araştırmacılar, konum tabanlı sosyal ağlarda sosyal ağ ve check-in özelliklerini araştırmışlardır [7]. Chang ve Sun'da [8], LBSN'lerde konum tahmini için çeşitli özellikleri araştırmış ve arkadaşlar tarafından yapılan check-in sayısının önemli bir tahmin edici olduğunu bildirmiştir. Long ve Joshi'de [9] yazarlar, sosyal ilişkileri dikkate alarak LBSN kullanıcılarına POI önermek için HITS tabanlı bir POI öneri algoritması önerdiler.

Ye ve diğerleri (2010), yakındaki arkadaşlardan gelen check-in bilgileri konum önerisi için kullanılırken diğer kullanıcılar göz ardı edilmiştir. Sonuçlar, sosyal ağın yalnızca küçük iyileştirmeler getirdiğini göstermektedir. Gao ve diğerleri [10], özellikle bir kullanıcının bir sonraki check-in'inde konum tavsiyesi sorununa benzer olabilen "cold start" konum tahmini problemini çözmek için LBSN'ler üzerindeki coğrafi sosyal korelasyonları araştırdı. Ye ve diğerleri [11], konum önerisi için hem kullanıcı tabanlı hem de arkadaş tabanlı ortak filtrelemeyi kullandılar.

3. Bağlantı Tahmini

Bağlantı tahmini bir ağdaki iki taraf arasında, bir bağlantının varlığını tahmin etme sorunudur. Bağlantı tahminine örnek olarak bir sosyal ağdaki kullanıcılar arasındaki arkadaşlık bağlarını tahmin etmek, bir alıntı ağındaki ortak yazarlık bağlantılarını tahmin etmek ve bir biyolojik ağdaki genler ve proteinler arasındaki etkileşimleri tahmin etmek dâhil edilebilir [12-14] Bağlantı tahmininin zamansal bir yönü de olabilir, burada bağlantı kümesinin anlık görüntüsü verilir. Amaç bağlantıları zamanında tahmin etmektir. Bağlantı tahmini geniş çapta uygulanabilir. E-ticarette, bağlantı tahmini genellikle kullanıcılara öğe önermek için kullanılan bir alt görevdir. Bağlantı tahmini, graflar ve ağlar alanındaki en önemli araştırma konularından biridir. Bağlantı tahmininin amacı şekil 1'de görüldüğü gibi, gelecekte bir bağlantı oluşturacak veya oluşturmayacak düğüm çiftlerini belirlemektir.



Şekil 1. Bağlantı Tahmini

4. Materyal ve Metot

4.1. Veri Seti

Konum tabanlı sosyal ağlarda uygulama yapabilmek için öncelikli olarak o sosyal ağları kullanan kullanıcıların konum, memleket gibi bilgilerinin toplanması ve kaydedilmesi gerekmektedir. Toplanan verilerden kullanıcı ve lokasyon arasında check-in yapmamış olan 500 bağlantı olmayan verimizden 250 tane pozitif örnek, 250 tane negatif örnek olarak belirlenen değerler Tablo 1’de gösterilmiştir. Toplam check-in sayısı, kullanıcı sayısı ve lokasyon sayısı Tablo 2’de verilmiştir. Bu çalışmada gerçek dünya veri kümesi kullanılmıştır. Veriler twitter aracılığıyla foursquare’ den toplanmıştır. Toplanan verilerden eğitim verileri Ocak 2011 ve Haziran 2011 arasında 6 aylık bir süreçte toplanmıştır. Test verileri ise; Temmuz 2011 ve Eylül 2011 arasındaki 3 aylık süreçte toplanmıştır. Mevcut verilerden elde edilen toplam check-in sayısı kullanıcıların ülkeleri ve check-in yaptığı şehirlere göre Tablo 3’te kategorize edilmiştir.

Tablo 1. Örnek Sayısı

Bağlantı olmayan örnek sayısı	Pozitif örnek sayısı	Negatif örnek sayısı
500	250	250

Tablo 2. Veri Sayıları

Kullanıcı sayısı	Check-in sayısı	Lokasyon sayısı
4589	722,580	71,816

Tablo 3. Kullanıcı ülkelerden belirlenen ilgi çekici nokta olarak belirlenen ülkelerinde yaptıkları check- in sayısı

Kullanıcı	NewYork	Bangkok
Almanya	71588	114246
Türkiye	14086	7613
Japonya	108819	162109
Amerika	174596	69523

4.2. Sınıflandırma Yöntemleri

4.2.1. Rastgele Orman (RF)

Rastgele Orman algoritması, regresyon, sınıflandırma ve diğer çeşitli işlemler için, eğitim aşamasında olan çok miktarda karar ağacı oluşturarak problemin türüne göre sınıf veya sayı tahmini yapan toplu öğrenme yöntemidir. Rastgele orman, birden daha fazla karar ağaçlarını oluşturur ve daha doğru ve kararlı bir tahmin elde etmek için onları birleştirir. Rastgele kara ormanlarının büyük bir avantajı, mevcut olan makine öğrenmesi sistemlerinin birçoğunu oluşturan sınıflandırma ve regresyon problemleri için kullanılabilmesidir [15].

4.2.2. K-NN

K En Yakın Komşu algoritması (K-NN), denetimli öğrenme algoritmalarında verileri analiz etmek için yaygın olarak kullanılmış olan bir makine öğrenmesi algoritmasıdır. Popülerliği, kullanımın kolaylığı ve kolaylıkla anlaşılabilir sonuçlarından kaynaklanmaktadır. K-NN de olan 'K', bir veri kümesindeki sonuçları sınıflandırmak ya da tahmin etmek için kullanılmış olan en yakın komşuların adetini ifade eder. Her bir yeni gözlemin sınıflandırması ya da tahmini, ağırlıklı ortalamalara göre belirlenmiş bir mesafeye (yani En Yakın Komşusuna) göre hesaplanmaktadır.

4.2.3. Destek Vektör Makineleri

Destek Vektör Makinesi, sınıflandırma veya regresyon gibi problemler için kullanılan denetimli bir makine öğrenmesi algoritmasıdır. Destek Vektörü Makineleri birbirine en yakın olan veri noktaları arasında bir hiper düzlem çizer. Bu, sınıfları ayırır ve bunların daha net şekilde ayırt edilmesi için aralarındaki mesafeyi en yükseğe çıkarır. Bununla beraber, çoğunluk olarak sınıflandırma problemlerinde kullanılmaktadır. Bu kullanılan algortmada, her bir veriyi belirli bir koordinatın değeri olan her niteliğin değeri ile beraber n-boyutlu boşluğa (n sahip olunan özelliklerin sayısı) bir nokta olarak çizilmektedir. Daha sonra, iki sınıftan daha iyi ayırım yapan hiper-düzlemi bularak sınıflandırma işlemi gerçekleştirilir [16].

4.3. Performans Ölçütleri

4.3.1. Konfüzyon Matrisi

Makine öğrenmesinde kullanılan sınıflandırma modellerinin performansını değerlendirmek için hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı hata matrisi sıklıkla kullanılmaktadır. Her ne olursa olsun sınıflandırma tahminleri şu dört değerlendirmeden birine sahip olacaktır:

Doğruya doğru demek (True Positive – TP) DOĞRU

Yanlış yanlı demek (True Negative – TN) DOĞRU

Doğruya yanlış demek (False Positive – FP) YANLIŞ

Yanlış doğru demek(False Negative – FN) YANLIŞ

4.3.2. Doğruluk

Algoritma başarımının ölçülmesinde kullanılan en popüler ve aynı zamanda en basit yöntemdir. Doğru sınıflandırılmış olan örnek sayısının, toplam örnek sayısına oranı sonucu elde edilir [17]. Denklem 1'de formülize edilmiş hali verilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

4.3.3. F-Ölçüm

İkili sınıflandırmanın istatistiksel analizinde, F skoru veya F ölçümü, bir testin doğruluğunun ölçüsüdür. Doğruluk değeri yerine F-Ölçüm değerinin kullanılmasının en temel nedeni eşit dağılmayan veri kümelerinde hatalı bir model seçimi yapmamaktır. Ayrıca sadece Yanlış Negatif ya da Yanlış

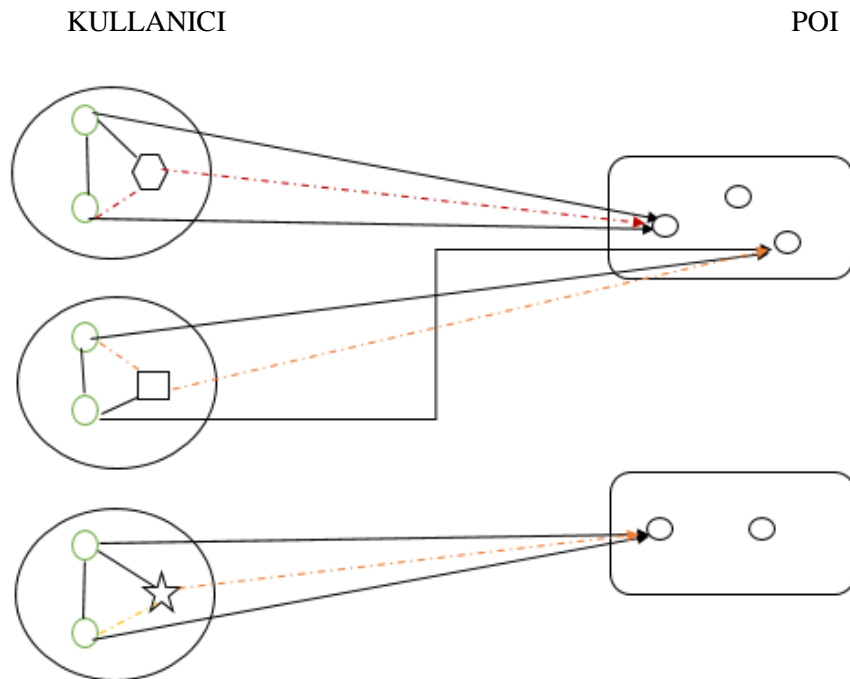
Pozitif değil tüm hata maliyetlerini de içeren bir ölçme metriğine ihtiyaç duyulduğundan F-Ölçüm kullanımı önemlidir. F-Ölçüm değerini hesaplayabilmek için gerekli denklem 2’de ifade edilmiştir.

$$F - \text{Ölçüm} = \frac{2 \cdot \text{Duyarlılık} \cdot \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (2)$$

4.4. Kullanılan Yöntem

Sosyal ağlarda, bağlantı tahmini, mevcut ağlardaki eksik bağlantıları ve gelecekteki ağlardaki yeni veya çözülen bağlantıları tahmin eder, bu sosyal ağların evrimini araştırmak ve analiz etmek için önemlidir. Son on yılda sosyal ağlarda bağlantı tahmini ile ilgili birçok çalışma yapılmıştır. Bu makalenin amacı, sosyal ağlardaki bağlantı tahmininin son durumunu kapsamlı bir şekilde gözden geçirmek, analiz etmek ve tartışmaktır. Bağlantı tahmin teknikleri ve sorunları için sistematik bir kategori sunulmaktadır. Daha sonra bağlantı tahmin teknikleri ve problemler analiz edilir ve tartışılır. Tipik bağlantı tahmini uygulamaları da ele alınmaktadır.

Bu çalışmada, konu önerisi için ve verileri modellemek için yarı-iki parçalı bir ağ [18] önerilmiştir. Yarı-iki parçalı bir grafik, $G = (V1, V2, E1, E2)$ olarak tanımlanabilir; burada V1 ve V2, iki düğüm kümesidir, E1, V1 ve V2 arasındaki kenarları belirtirken, E2, düğümler arasındaki kenarları (etkileşimleri) gösterir. Önerilen ağda, iki düğüm grubu, kullanıcı (V1) ve konu (V2) düğümleridir. Daha önce açıklandığı gibi, kullanıcının ilgi alanlarını anlamının iki yolu, ilk olarak memleketlerine göre önceki bağlantıları önemsemesi ve ikinci olarak da ilgi çekici noktalarda önceden yapılan check-inlerdir. Kullanıcı ile POI düğümü arasındaki bir kenar (E1), kullanıcının ilgili POI'ye check-in yaptığını belirtir. Ağdaki diğer kenarlar (E2) kullanıcılar arasındadır. Aynı ülkeden geliyorsa iki kullanıcı bağlanır. Bu, aynı ülkeden konum bildiren kullanıcıların takım olmasıyla sonuçlanır. Şekil-2’de gösterildiği gibi ağın sol tarafı kullanıcı, sağ tarafı ise POI kısmını göstermektedir. Kullanıcı kısmındaki her bir grup aynı ülkeden gelen kişileri, POI kısmındaki her bir grup ise kullanıcıların ziyaret ettiği bir şehirdeki POI’leri temsil eder. Kullanıcı kısmında da görüldüğü gibi aynı ülkeden kişiler ağda birbirine bağlanmıştır. Burada çözülmesi gereken problem, altıgen, kare veya yıldız ile gösterilen ve daha önce ilgili şehre gitmemiş kişiye uygun POI’leri tavsiye etmektir.



Şekil 2. Ülkeler ve kullanıcılar arasındaki oluşan bağlantı tahmini

5. Deneysel Sonular

Makalenin bu b3l3m3nde 3nerilen y3ntemi deęerlendirmek iin bazı testler gerekleřtirilmiřtir. Performans kriteri olarak doęruluk ile birlikte F-3l3m deęeri kullanılmıřtır. Eęitici baęlantı tahmini y3ntemi iin 3zellik olarak, baęlantılı olmayan d3ę3mlerin CN (Ortak Komřular), JC (Jaccard Katsayısı), AA (Adamic Adar) ve PA (Tercihli Baęlanma) deęerleri kullanılmıřtır.

İlk uygulamada New York řehrini ziyaret eden d3rt farklı 3lkedeki (Almanya, T3rkiye, Japonya ve Amerika Birleřik Devletleri) kiřilerin performans 3l3tleri verilmiřtir. Bu testin sonuları Tablo 4’de rapor edilmiřtir.

Tablo 4. New York řehrini ziyaret eden d3rt farklı 3lkedeki (Almanya, T3rkiye, Japonya ve Amerika Birleřik Devletleri) kiřilerin performans 3l3tleri

Kullanıcı	Performans	RF	K-NN	SVM
Almanya	Doęruluk	0,803	0,756	0,776
	F-3l3m	0,796	0,714	0,777
T3rkiye	Doęruluk	0,776	0,670	0,718
	F-3l3m	0,772	0,654	0,722
Japonya	Doęruluk	0,820	0,784	0,803
	F-3l3m	0,816	0,776	0,795
ABD	Doęruluk	0,685	0,647	0,667
	F-3l3m	0,693	0,640	0,670

Tablo 4 inceledięinde en y3ksek performans deęerlerinin Japonya kullanıcıları tarafından elde edildięi g3r3lmektedir. Bu durum Japon kullanıcıların bir yeri ziyaret ederken buraya daha 3nce gelen vatandaşlarının tercihlerini daha ok dikkat aldıęını g3stermektedir. Bu sonucun dięer bir g3stergesi de Japon kullanıcılarının genelde tur olarak grup halinde ziyaret ettięi ve gezilecek yerlerin daha 3nceden belirli olduęudur. Japonya’dan sonraki sıralama Almanya, T3rkiye ve ABD řekindedir. ABD’lilerin d3ř3k performans g3sterme nedeni New York řehri iin vatandaşlarının daha 3nce check-in yaptıęı POI’leri ok fazla dikkate almadıęı, New York kendi memleketleri olduęu iin řehri yakından tanıdıkları ve s3rekli aynı POI yerine alternatifleri tercih etmelerinden dolaydır.

Sınıflandırma y3ntemi olarak da en iyi sonuları RF algoritması bulmuřtur. RF’yi SVM ve K-NN izlemiřtir. Yani en k3t3 sonuları K-NN bulmuřtur. Bu aslında beklenen bir sonutur.

İkinci uygulamada ise Bangkok řehrini ziyaret eden d3rt farklı 3lkedeki (Almanya, T3rkiye, Japonya ve Amerika Birleřik Devletleri) kiřilerin performans 3l3tleri verilmiřtir. Bu testin sonuları Tablo 5’de paylařılmıřtır. Performans deęerlerine bakıldıęında bu defa Japonya kullanıcılarının deęil de Almanya kullanıcılarının doęruluęa en yakın olduęu g3r3lmektedir. Bunun sebebi olarak, Almanya kullanıcılarının uzak doęudan farklı bir k3lt3re sahip olduęu iin 3nceden Bangkok’u ziyaret eden ve oradaki POI’leri check-in yapan vatandaşlarınkine benzer řekilde gezilerini planladıkları d3ř3n3lmektedir. Japonya kullanıcılarının doęruluk oranının d3řmesinde ise o b3lgenin kendi k3lt3rlerine benzer yerler olduęundan 3nceden 3lkelerinden giden kullanıcıların check-in yaptıęı yerleri deęil de farklı yerlerde bulunmayı tercih ettięi d3ř3n3lmektedir. En d3ř3k performans deęerli sonular ilgin bir řekilde yine ABD’li kullanıcılardan ıkmıřtır. Her ne kadar New York řehri kadar olmasa da deęerler dięer 3 3lkedeki kullanıcılardan daha d3ř3kt3r.

3nceki teste benzer řekilde sınıflandırma y3ntemlerinden en iyi sonucu yine RF yaklařımı vermiřtir. RF ok kullanıřlı ve uygulanması kolay kabul edilen bir algoritmadır. Ayrıca hem basittir hem de sınıflandırma ve regresyon iinde kullanılabilir. Bundan sonraki bařarılı sonucu SVM, en d3ř3k sonuları ise genel olarak K-NN y3ntemi elde etmiřtir.

Tablo 5. Bangkok şehrini ziyaret eden dört farklı ülkedeki (Almanya, Türkiye, Japonya ve Amerika Birleşik Devletleri) kişilerin performans ölçütleri

Kullanıcı	Performans	RF	K-NN	SVM
Almanya	Doğruluk	0,876	0,810	0,843
	F-Ölçüm	0,869	0,812	0,850
Türkiye	Doğruluk	0,815	0,728	0,808
	F-Ölçüm	0,803	0,734	0,805
Japonya	Doğruluk	0,860	0,785	0,828
	F-Ölçüm	0,861	0,790	0,825
ABD	Doğruluk	0,798	0,706	0,783
	F-Ölçüm	0,797	0,695	0,769

6. Sonuç

Bu çalışma lokasyon bazlı sosyal ağlara katılan ve daha önceden bilgileri olan kullanıcılara yeni mekânlar önerme problemini incelemektedir. Çalışmada en çok yer bildirimini yapılan turistik mekânlardaki kullanıcı profilleri ve o mekânlardaki önceden check-in yapan aynı ülkeden olan kullanıcıların verileri kullanılmıştır. Bu bilgilerden faydalanılarak daha önceden ilgili POI'ye gitmemiş kullanıcılara mekânın önerimi yapılmaktadır. Sosyal medya, kullanıcıların günlük yaşamının bileşeni olmuştur. Foursquare/Swarm gibi uygulamalar coğrafi olarak konum verilerini bulunduran iletişimin veri kaynağını oluşturmaktadır.

Konum tabanlı sosyal ağlardaki geçmiş check-in verilerinin kullanılabilirliği, kullanıcının mobil davranışını anlamak için kullanılabilir. Bu çalışmada, yeni bir şehre giden kullanıcıya POI tavsiyesi için yarı iki parçalı bir ağda bağlantı tahmini öneriyoruz. Konum tabanlı sosyal ağlardaki gerçek check-in verilerine ilişkin deney sonuçları, önerdiğimiz yaklaşımın hem etkinlik açısından hem de cold start problemini hafifletme konusunda son teknoloji yaklaşımları geride bıraktığını göstermektedir.

Kaynaklar

- [1] Gao, H. , Tang, J. Liu, H. (2015). Addressing the cold-start problem in location recommendation using geo-social correlations, *Data Mining and Knowledge Discovery* March 2015, ss. 299-323.
- [2] Zheng, Y. (2011). *Location-Based Social Networks: Users*, Chapter 8.
- [3] Noulas, A., Scellato, S., Mascolo, C., & Pontil, M. (2011). An Empirical Study of Geographic User Activity Patterns in Foursquare., *Proceedings of the International AAAI Conference on Web and Social Media*, cilt 5(1).
- [4] Noulas, A. , Scellato, S. , Lambiotte, R. , Pontil, M. , Mascolo, C. (2012). A Tale of Many Cities: Universal Patterns in Human Urban Mobility, *PLoS ONE*, cilt 7(5) , Article e37027. DOI:10.1371/journal.pone.0037027
- [5] Albakour, M..D., Deveaud, R. , Macdonald, C. and Ounis, I. (2014). Diversifying contextual suggestions from location-based social networks, *Proceedings of the 5th Information Interaction in Context Symposium*, ss. 125-134.
- [6] Fulk, J. , Yuan ,Y. (2013). Location, Motivation, and Social Capitalization via Enterprise Social Networking, *Journal of Computer-Mediated Communication*, cilt 19(1), ss. 20-37.

- [7] Gao , H. , Liu, H. (2013). Data Analysis on Location-Based Social Networks, *Mobile Social Networking*, ss. 165-194.
- [8] Chang, J., Sun, E. (2011). Location 3: how users share and respond to location-based data on social networking sites, *The International AAAI Conference on Web and Social Media*.
- [9] Long, X. , Joshi, J. (2013). A hits-based poi recommendation algorithm for location-based social networks, *Proceedings of the 2013 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*, ss. 642-647.
- [10] Gao, H. , Tang, J. , Liu, H. (2012c). gSCorr: modeling geo-social correlations for new check-ins on locationbased social networks , *Proceedings of the 21st ACM international conference on Information and knowledge management* , ss. 1582–1586.
- [11] Ye, M. , Yin, P. , Lee, W. , Lee, D. (2011). Exploiting geographical influence for collaborative point-of-interest recommendation , *Annual International ACM SIGIR Conference on Research and Development in, Information Retrieval*, ss. 325-334.
- [12] Bütün, E., Kaya, M. (2020). Predicting citation count of scientists as a link prediction problem. *IEEE Transactions on Cybernetics*, 50(10), 4518-4529.
- [13] Bütün, E., Kaya, M. (2019). A pattern based supervised link prediction in directed complex networks. *Physica A: Statistical Mechanics and its Applications*, 525, 1136-1145.
- [14] Aslan, S., Kaya, M. (2018). Topic recommendation for authors as a link prediction problem. *Future Generation Computer Systems*, 89, 249-264.
- [15] Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197-227.
- [16] Destek Vektör Makineleri. <https://veribilimcisi.com/2017/07/19/destek-vektor-makineleri-support-vector-machine/>
- [17] Performans Ölçütleri. <https://veribilimcisi.com/2017/07/14/dogruluk-olcumu-nasil-yapilir-accuracy-measure/>
- [18] Gao H, Barbier G, Goolsby R (2011). Harnessing the crowdsourcing power of social media for disaster relief, *Intelligent Systems*, IEEE, cilt 26(3), ss. 10-14.