

Örüntü Tanıma ve Öznitelik Seçme Yöntemleri Kullanarak Kısa Zaman Sonraki Yol Trafik Hız Öngörüsü

Short Time Traffic Speed Prediction Using Pattern Recognition and Feature Selection Methods

Ülkem Yıldırım, Zehra Çataltepe

İstanbul Teknik Üniversitesi
Bilgisayar Mühendisliği Bölümü
Maslak, İstanbul, Türkiye

{ulkem.yildirim.cataltepe}@itu.edu.tr

Özetçe

Bu çalışmada İstanbul Büyükşehir Belediyesi'nin web sitesinden alınan RTMS (Remote Traffic Microwave Sensor) cihazlarının hız ölçüm değerleri kullanılarak ileriye yönelik trafik hızı tahmin edilmiştir. Örüntü tanıma yöntemi olarak *k-En Yakın Komşu (kNN)* ve Karar Destek Makinesi (SVM) kullanılmıştır. 5 dakikadan 60 dakikaya kadar ileriye yönelik hız öngörüsünde bulunabilmek için, tahmin edilecek andan belirli zaman önce ölçülen hız değerleri alınmıştır. Yapılan çalışmada hem uzun dönemli (1 gün veya 1 hafta) hız bilgilerinin hem de kısa dönemli (5 dakikadan 60 dakikaya kadar) hız bilgilerinin kısa dönemli trafik öngörüsü yapmakta önemli bir rol oynadığı bulunmuştur. Hız öngörüsü için en önemli nitelikleri bulmak için öz nitelik seçme yöntemi kullanılmıştır. Bir sensöre ait hız verilerinin değişik zamanlarda alınarak yapılan trafik hızı öngörüsüne ek olarak bu sensöre yakın sensörlerin hız bilgileri alınarak da hız öngörüsü yapılmıştır. Ek sensör verilerinin kullanılmasının daha iyi başarımlar sağladığı bulunmuştur. Ayrıca karar destek makinesi yönteminin KNN yöntemine göre, bu problem için, daha iyi sonuçlar bulduğu ortaya çıkmıştır.

Kelimeler: kısa zamanlı trafik hızı öngörüsü, *k-en yakın komşu*, karar destek makinesi

Abstract

In this study we predict traffic speed on Istanbul roads using RTMS (Remote Traffic Microwave Sensor) speed measurements obtained from the Istanbul Municipality web site. We use two different pattern recognition methods, *k-nearest neighbor (kNN)* and support vector regression machine (SVM). In order to predict the speed at a short time (5 minutes to 60 minutes) ahead, we use speed measurements taken at different time intervals before the prediction. We find out that both long term (1 day or 1 week) speed information and short term (5 minutes to 60 minutes) speed information play an important role for short time speed prediction. We use backward feature selection algorithm to find out the most important features for speed prediction. In addition to speed measurements for the same sensor at different times, we use speed measurements from different sensors to predict speed at a certain sensor point. We find out that using additional sensors results in better speed prediction. We also find out that

using SVM results in better prediction than KNN for this problem.

Keywords: short time traffic speed prediction, *k-nearest neighbor*, support vector machine..

1. Giriş

Şehirlerin büyümesi ve nüfusun kalabalıklaşmasıyla beraber insanların şehrin içinde bir noktadan bir noktaya araçlarıyla ulaşmaları giderek daha da zorlaşmaktadır. Günün belirli vakitlerinde oluşan olağan trafik sıkışıklığının yanı sıra olağan dışı durumlar sonucu oluşan beklenmeyen trafikte bekleme süreleri insanların hayatlarını olumsuz şekilde etkilemektedir. Her ne kadar belediyeler bu durumu çözmek için çeşitli önlemler alsada özellikle şehirlerin eski yerleşim birimlerinde yeni yollar açmak mümkün olamaması gibi çeşitli etkenler sonucu bu çabalar çoğu zaman sonuçsuz kalmaktadır. Akıllı trafik sistemleri (ITS) bu noktada yardımımıza koşmakta ve trafik işaretleri kontrol sistemi, elektronik bilet toplama sistemi, transit yollar yönetim sistemleri gibi bir çok uygulamayı yolcuların ve trafik kontrol servislerinin daha akıcı ve güvenli bir trafik hizmeti sunmasını sağlamaktadır.

Kısa zamanlı trafik hızı tahmini yolcuların seyahat sürelerini en doğru şekilde öngörmelerini sağlamaktadır. Yola çıktıktan hedefe varıncaya kadar gidilecek rota üzerinde oluşabilecek trafik sıkışıklığını önceden öngörülmesiyle kullanıcılar başka rotalara kaydırılması sağlanmakta ve trafiğin daha homojen yayılması sağlanabilmektedir.

Trafik öngörüsü için yapılan çalışmalarda temel olarak yapılan işlem geçmiş zamana ve şimdiki zamana ait hız verilerini giriş olarak vererek gelecekteki oluşabilecek değerleri çıktı olarak almaktır. Bu amaçla ilk denenen metodlar biri lineer metoddur [11,13,16,4]. Lineer modellerin hız değerleri arasındaki karmaşık ilişkiyi tam olarak verememesinden dolayı yapılan tahminler 15 dakikadan kısa periyotlarda iyi sonuç vermekte, daha uzun zamanda yapılan tahminlerde ilgili zaman diliminde geçmiş zamanın ortalaması alınarak yapılan ölçümler daha iyi sonuç vermektedir [5,6]. Yine trafik öngörüsünde kullanılan ve zamana bağlı parametreler kullanan Kalman filtresi metodu yine ileriki zaman dilimi tahminlerinde hatalı sonuçlar verebilmektedir [9].

Problemin karmaşıklığı göz önüne alınarak bir çok çalışmada SVM (Support Vector Machine, Karar Destek Makinesi) ve

ANN (Artificial Neural Network, Yapay Sinir Ağları) metodları, bu metodların belirli bir fonksiyon şeklinde olmaması ve başlangıçta belirli parametrelere ilk değer verme zorunluğu olmaması özellikleri nedeniyle kullanılmıştır. SVR ve ANN metodları giriş-çıkış arasındaki belirli bir matematik formülle ifade edilemeyecek karmaşıklığındaki ifadeler arasındaki ilişkiyi bulması yönünden birbirlerine benzer özellikler taşımaktadır. ANN'ler insan beyninin hesaplama yapısını modelleyerek çok katmanlı bir hesaplama birimi oluşturmaktadır ve trafik hızı öngörüsü bir çok çalışmada kullanılmıştır [8,7,13,10]. Fakat SVM'de kullanılan yapısal risk küçültme yöntemi (SRM), ANN'de kullanılan deneysel risk küçültme (ERM) yönetimine göre, lokal minima'lara takılmaması ve global değerleri daha iyi yakalaması nedeniyle daha iyi sonuçlar vermektedir [2,15]. Aynı zamanda SVM'nin kayıp verilerle ANN'ye göre daha iyi başa çıkabilmesi onu trafik öngörüsü yapmakta ANN'nin önüne geçirmektedir.


Bu çalışmada SVM ve kNN (k-En Yakın Komşu) yöntemleri ve üç değişik noktadan toplanan RTMS verileri kullanılarak kısa zamanlı hız tahmini yapılmaktadır. Hem aynı noktada yapılan ölçümler, hem de o noktaya bağlanan yollardan alınan ölçümler ve öznelik seçme yöntemleri kullanılarak hız tahmini yapılmıştır. Bildirinin geri kalanı şu şekilde düzenlenmiştir: 2. bölümde kullanılan veri kümesi hakkında bilgi verilmiştir. 3. bölümde kullanılan örüntü tanıma yöntemleri ve öznelik seçme yönteminden kısaca bahsedilmiştir. 4. bölüm deneysel sonuçları, 5. bölüm ise genel olarak varılan sonuçları içermektedir.

2. Veri Kümesi

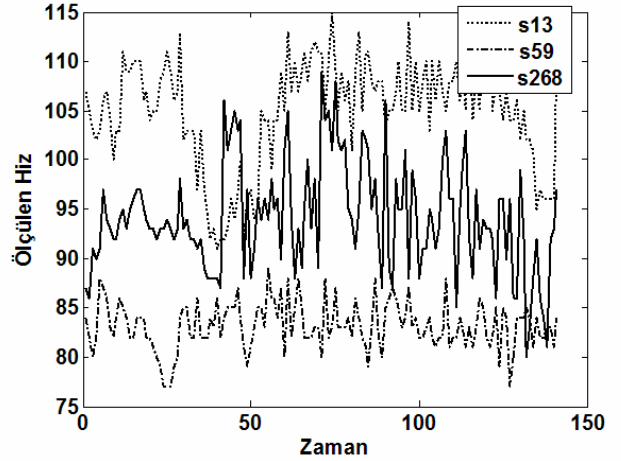
Veriler, İstanbul Büyükşehir Belediyesi Trafik Kontrol Merkezinin online sayfasından alınmaktadır. Trafik Kontrol Merkezi bütün İstanbul'a yayılmış 327 RTMS ile ilgili şeritlerden geçen araçların hız ortalamalarını aralık 1-2 dakika aralıklarla web sitesinden yayınlamaktadır. Trafik sensörlerinin sıkça doğru sonuç vermemesine neden olan sensör açığı değişimleri ve önüne sensörü engelleyici yabancı cisimlerin gelmesi (ağaç dalı vs.) gibi durumlar Trafik Kontrol Merkezi çalışanlarının 3 ayda bir yaptığı periyodik bakım çalışmaları sayesinde önlenmektedir.

Deneyler sırasında kullanılan 3 RTMS trafik sıkışıklığı yoğun olan FSM köprüsü yolu üzerinde seçilmiştir. Bu RTMS'lerden s13 Maslak FSM köprüsü yönünde, s59 Levent FSM köprüsü yolunda bulunmaktadır. s13 ve s59'dan gelen trafiğin birleşimi ile oluşan trafik, s268 FSM köprüsünde ölçülmektedir.

Bir noktada oluşabilecek hız değerini tahmin etmek için, öznelik vektörü olarak, o noktada daha önce ölçülmüş hız değerleri kullanılmıştır. 5 dakika sonraki hız değerini tahmin etmek için istenen andan 5, 10, 15, ..., 60 dakika, 1 gün ve 1 hafta önceki hızlar (gösterim olarak -5, -10, -15, ..., -60, -1440, -10080) öznelik vektörü olarak seçilmiştir. 1 saat sonrası hız tahmini için ise, 65, ..., 120 dakika, 1 gün ve 1 hafta önceki hız değerleri kullanılmıştır.



Şekil 1: Hız ölçümlerinin alındığı, FSM Köprüsü'ne bağlanan yollar üzerindeki üç nokta.



Şekil 2: s13, s59, s268 noktalarından 3/12/2007 Pazartesi günü alınan hız ölçümleri.

3. Örüntü Tanıma Yöntemleri

3.1. k-En Yakın Komşu (kNN) ve Karar Destek Makinesi (SVM)

kNN [1] yöntemi en basit örüntü tanıma yöntemlerinden birisidir. Belirli bir k değeri için (bu çalışmada k=25 kullanılmıştır) tahmin edilmesi istenen veri noktasının özneliklerine seçilen bir uzaklık metriğine göre en yakın k tane eğitim noktasının çıktı değerlerinin ortalaması, o veri noktası için yapılan öngörüü belirler. Böylece şu anki trafik hızı dağılımına en yakın geçmiş 25 hız dağılımı bulunarak geleceğe yönelik hız tahmini yapılır. kNN yöntemi, bütün eğitim veri kümesindeki noktalara uzaklık hesabını gerektirdiği için yavaştır. Öznelik vektörlerinin boyutlarının azaltılması, uzaklık metrik hesabının, dolayısı ile kNN'in hızının artırılması için kullanılabilir.

SVM [3] yaklaşık son 10 yıldır kullanılan, değişik problemler için iyi sonuçlar vermiş, bir örüntü tanıma yöntemidir. Öznelik vektörleri arasında daha çok boyutlu bir uzayda hesaplanan bir çarpıma (dot product) ve bu çok boyutlu uzayda sınıfların birbirlerinden doğrusal bir sınıflandırıcı ile ayrılmasına dayanır. Birbirine ilişkisi karmaşık sayılabilecek ve direk lineer bir ilişki bulunamayan örnek problemimiz gibi konularda öznelik vektörleri arasındaki ilişkiyi çok

boyutlu uzayda bulan bir yöntemdir. Eğitim kümesinde verilen trafik hız vektörleri kullanılarak hız değerlerinin değişim eğrisi bulunmakta ve geleceğe yönelik hız tahmini yapılmaktadır. Eğitim kümesindeki SVM'ler regresyon problemleri için de kullanılabilir. Bu çalışmada, Stefan Rüping tarafından C++ dilinde yazılmış, açık kaynak kodlu mySVM programı kullanılmıştır [12].

3.2. Öznitelik Seçimi

Öznitelik seçme yöntemleri (feature selection), veri boyutu azaltma (dimensionality reduction) yöntemlerinin bir alt grubudur. PCA, ICA gibi öznitelik projeksiyon yöntemleri, bütün ölçülen özniteliklerin doğrusal birleşimi olan ama daha az sayıda boyut kullanırken, ileri ya da geriye doğru öznitelik seçimi (forward/backward feature selection) sadece belirli özellikleri seçip kullanmaktadır. Özellikle ölçümlerin alınmasının ya da saklanması zaman ya da para açısından masraflı olduğu durumlarda öznitelik seçme yöntemleri, öznitelik projeksiyon yöntemlerine tercih edilir.

3.3. Örüntü Tanıma Algoritmalarının Performanslarının Ölçümü

$i = 1..n$ öngörülmesi istenen zamanları, Y_i gerçek hız değerini, Y_i^* ise öngörülen hızı gösterebilir. Performans ölçütü olarak gerçek ve öngörülen hızların farklarının mutlak değerinin, gerçek hıza oranının ortalaması alınmıştır:

$$RME = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - Y_i^*}{Y_i} \right| \quad (1)$$

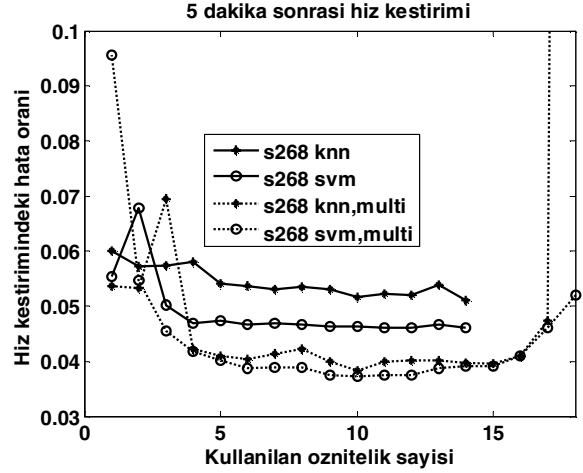
4. Deneysel Sonuçlar

4.1. Sadece Bir Yere Ait Geçmiş Hız Değerlerini Kullanarak Hız Tahmini

5 dakika sonraki ve 1 saat sonraki hız tahmini ayrı ayrı incelenmiştir. Şekil 3'de, 5 dakika sonraki hız tahmini için (s268knn ve s268svm ile gösterilmiştir), s268 noktasında, geriye doğru öznitelik seçimi ile svm ve kNN'nin ulaştığı yüzde hata değerleri görülmektedir. Hem s268, hem de diğer noktalar için, SVM'nin ulaştığı hatalar, genel olarak, kNN'den daha azdır. Yaklaşık 6 sensör değerinden fazlasının kullanılması ile SVM'nin de kNN'nin de hata oranlarında büyük bir düşme görülmemektedir. Bu 6 sensörün hangileri olduğu ve önem sırasına göre seçilen diğer sensörler, hem s268, hem de s13 ve s59 noktaları için Tablo 1'de gösterilmiştir. Her nokta için hem uzun dönemle yapılmış (-1440=1 gün, -10080=1hafta) hem de en son 1

saat içinde yapılmış ölçümler her üç nokta için de önemli bulunmuştur.

Şekil 3: s268 noktasında 5 dakika sonraki hız tahmini için geriye doğru öznitelik seçimi.



Tablo 1: Azalan önem sırası ile, üç değişik noktada SVM kullanılarak seçilen öznitelikler.

Öznitelik	S13	S59	S268
1	-1440	-10080	-5
2	-10080	-1440	-1440
3	-30	-5	-10080
4	-10	-60	-10
5	-15	-35	-50
6	-40	-30	-35
7	-20	-20	-60
8	-45	-50	-25
9	-25	-15	-30
10	-50	-45	-45
11	-55	-55	-40
12	-35	-40	-55
13	-60	-25	-15
14	-5	-10	-20


4.2. Birden Fazla Yere Ait Geçmiş Hız Değerlerini Kullanarak Hız Tahmini

[5] çalışmasında, önceki noktadaki hız değerleri ve lineer modeller kullanarak hız tahmini yapılmıştır. Bu çalışmada KNN ve SVM ile önceki ve tahmin istenen noktadaki hız değerleri kullanılmıştır. Her nokta için Tablo 1'de en önemli olduğu bulunan 6 öznitelik kullanılarak, s268 noktasındaki hızın tahmini yapılmıştır. Yine geriye doğru öznitelik seçme algoritması kullanılarak, en az hata veren öznitelikler saptanmıştır. Şekil 3'de görüldüğü gibi (s268knnmulti ve s268svmmulti ile gösterilmiştir), sadece s268 yerine, ek olarak s13 ve s59'daki hız ölçümlerinin kullanılması daha iyi sonuçlar vermiştir. 10 tane öznitelik ile en iyi sonuçların alındığı gözlemlenmiştir. Bu öznitelikler şunlardır: (s268:-10), (s59:-1440), (s13: -10080), (s13:-5), (s13:-10), (s13:-15), (s268:10080), (s268:-30), (s59:

-10080), (s13:-30). 10'dan fazla öznelik kullanılmamasının her iki algoritmanın da hata oranında artmaya neden olduğu görülmektedir.

Sadece bir noktadaki değerler kullanılarak yapılan tahminlerde olduğu gibi, bütün noktalar kullanılarak yapılan tahminlerde de SVM, kNN'den daha az hataya yol açmaktadır.

4.3. Birden Fazla Yere Ait Geçmiş Hız Değerlerini Kullanarak 1 Saat Sonrası için Hız Tahmini



Şekil 4: s268 noktasında 60 dakika sonraki hız tahmini için geriye doğru öznelik seçimi.

Özellikle seyahat planlama algoritmalarında, 5 dakikadan daha uzun süreli hız tahminine gerek vardır. Bu çalışmada 1 saat sonrası hız tahmini de yapılmış ve 5 dakikada sonrası hız tahminine benzer yöntemler kullanılmıştır. Yalnızca öznelik olarak -5...-60 dakika yerine, -65...-120 dakikadaki ölçümler kullanılmıştır. S268 noktası için sadece orada alınan ölçümler ve s13 ve s59 da katılarak ve SVM kullanılarak yapılan öznelik seçimi sonuçları Şekil 4'de verilmiştir. Beklendiği gibi hata oranları 5 dakikaya göre daha fazladır.

5. Sonuçlar

Bu çalışmada hem SVM, hem de kNN yöntemleri kullanılarak kısa zamanlı hız tahmini yapılmıştır. Sadece bir noktadan alınan hız ölçümleri ve SVM kullanıldığında, geriye doğru öznelik seçimi algoritması kullanılarak daha az sayıda öznelik ile %4.7 oranında hata ile doğru hız tahmini yapılabildiği görülmüştür. Yine SVM ve sadece bir nokta yerine, o noktaya bağlanan diğer noktalarındaki hız ölçümlerinin kullanılması ile bu hata oranı %3.7'ye inmiştir. Bu problem için, genel olarak SVM yönteminin kNN'den daha iyi sonuçlar verdiği de varılan başka bir sonuçtur.

6. Kaynakça

- [1] Alpaydin, E., "Introduction to Machine Learning", MIT Press, 2004.
- [2] Bin, Y., Zhongzhen, Y. Baozhen, Y., "Bus Arrival Time Prediction Using Support Vector Machines", *Journal of Intelligent Transportation Systems*, Volume 10, Issue 4 October 2006, pages 151 – 158.
- [3] Burges, C.J.C., "A Tutorial on Support Vector Machines for Pattern Recognition", *Data Mining and Knowledge Discovery*, Vol. 2, Number 2, p. 121-167, 1998.
- [4] Chrobok, R., Kaumann, O., Wahle, J., Schreckenber, M., "Three Categories of Traffic Data: Historical, Current, and Predictive", the *9th IFAC Symposium Control in Transportation Systems*, 250-25, 2000.
- [5] Hobeika, A.G. and Kim, C.K., "Traffic-flow-prediction systems based on upstream traffic", *Proceedings of Vehicle Navigation and Information Systems Conference*, 31 Aug-2 Sep 1994, 345 – 350.
- [6] Kwon, J., Coifman, B., Bickel, P., "Day-to-day travel time trends and travel time prediction from loop detector data", *Transportation Research Record*, (1554), 2000.
- [7] Lingras, P., and Mountford, P., "Time Delay Neural Networks Designed Using Genetic Algorithms for Short Term Inter-City Traffic Forecasting Engineering of Intelligent Systems", *14th International Conference on Industrial and Engineering Applications of Artificial Intelligence and Expert Systems, IEA/AIE 2001*, Budapest, Hungary, June 4-7, 2001, Proceedings, page 390, 2001.
- [8] Mark, C.D., Sadek, A.W., Rizzo, D., "Predicting experienced travel time with neural networks: a PARAMICS simulation study", *Intelligent Transportation Systems*, 2004. Proceedings. The 7th International IEEE Conference on Volume, Issue, 3-6 Oct. 2004 Page(s): 906 - 911
- [9] Park, D., and Rittett, L. R., "Forecasting Multiple-Period Freeway Link Travel Times Using Modular Neural Networks," *77th Annual Meeting of the Transportation Research Board*, Washington, D.C., January 1998.
- [10] Park, D. and Rilett, L. R., "Forecasting freeway link travel times with a multilayer feedforward neural network", *Computer-Aided Civil and Infrastructure Engineering*, 14(5), 357–367, 1999.
- [11] Rice, J., van Zwet, E., "A simple and effective method for predicting travel times on freeways", *Intelligent Transp. Systems, IEEE Proceedings*, 227 -232, 2001.
- [12] Ruping, S., "mySVM software", Available: <http://www-ai.cs.uni-dortmund.de/SOFTWARE/MYSVM>
- [13] Sun, H., Liu, H., and Ran, B., "Short Term Traffic Forecasting Using the Local Linear Regression Model", *Transportation Research Record*, 2003.
- [14] W.C.Van Lint, W.C., Hoogendoorn, S.P., and van Zuylen, H.J., "Robust and adaptive travel time prediction with neural networks," *Proceedings of the 6th annual TRAIL Congress* (part 2), December 2000.
- [15] Wu, C.H., Ho, J.M., D.T., Lee, "Travel-time prediction with support vector regression", *Intelligent Transportation Systems*, 5(4), 276 – 28, Dec. 2004.
- [16] Zhang, Z., Rice, J., and Bickel, P., "Empirical Comparison of Travel Time Estimation Methods", Report for MOU 353, UCB-ITS-PRR-99-43, ISSN1055-1425, December 1999