

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

Ülkem Yıldırım, Zehra Çataltepe  
İstanbul Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü, İstanbul  
[ulkem.yildirim,cataltepe@itu.edu.tr](mailto: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. Bir sensöre ait hız verilerinin değişik zamanlarda alınarak yapılan trafik hızı öngörüsüne ek olarak bu sensöre yakın sensörlerin hız bilgileri alınarak ve yüksek bağıntıya sahip sensörlerin hız bilgileri alınarak hız öngörüsü yapılmıştır. Yapılan testler sonucunda genel olarak SVR metodunun KNN metodundan daha başarılı olduğu görülmüştür. Yakın konumlardaki veya yüksek bağıntılı sensör verisi kullanılarak yapılan tahminlerin ise bir sensör verisi kullanılarak yapılan tahminlerden daha iyi sonuç verdiği görülmüştür.*

## 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 from 327 different sensor locations. We do speed predictions 5 minutes to an hour ahead and use SVM (Support Vector Machine) and kNN (k Nearest Neighbor) methods for speed prediction. We find out which other sensors could be used to predict the speed at a certain sensor location and show that especially for nearby/correlated sensors, it is possible to get better results using related sensor measurements in addition to the sensor being predicted.*

## 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 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 yollara daha eşit 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 yöntemlerden biri doğrusal yöntemdir [11,13,16,4]. Doğrusal yöntemlerin 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 süzgeci yöntemi 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) yöntemleri, bu yöntemlerin giriş-çıkış arasındaki belirli bir matematik formülle ifade edilemeyecek karmaşıklıkta ifadeler arasındaki ilişkiyi bulması yönünden birbirlerine benzer özellikler taşımaktadır. ANN'ler insan beyninin hesaplama yapısını modelleyerek çok katmanlı bir hesaplama birimi oluşturmaktır ve trafik hızı öngörülü bir çok çalışmada kullanılmıştır [8,7,13,10]. Fakat SVM'de kullanılan yapısal risk küçültme yöntemi (SRM), ANN'de kullanılan deneysel risk küçültme (ERM) yöntemine göre, yerel sınırlara takılmaması ve genel 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 kullanılarak kısa zamanlı hız tahmini yapılmaktadır. Hem aynı noktada yapılan ölçümler, hem de o noktaya bağlanan yollardan alınan ölçümler ve öznitelik seçme yöntemleri kullanılarak hız tahmini yapılmıştır. Bir sensöre ait hız verilerinin değişik zamanlarda alınarak yapılan trafik hızı öngörüsüne ek olarak bu sensöre yakın sensörlerin hız bilgileri alınarak ve yüksek bağıntıya sahip sensörlerin hız bilgileri alınarak hız öngörü yapılmıştır. Ayrıca ilgili sensörden veri alınmadığı düşünülerek yüksek korelasyona bağlı sensörlerin birbirlerinin verileri kullanılarak hız öngörüsü yapılmaya çalışılmıştır. Yapılan testler sonucunda genel olarak SVR metodunun KNN metodundan daha başarılı olduğu görülmüştür. Yakın konumlardaki veya yüksek korelasyonlu sensör verisi kullanılarak yapılan tahminlerin ise bir sensör verisi kullanılarak yapılan tahminlerden daha iyi sonuç verdiği görülmüştür. İlgili sensörün bozulduğu varsayılarak onun yerine korelasyonu

yüksek diğer sensör verilerinin kullanıldığında sonuçların ilgili sensörün kullanıldığı duruma gayet yakın sonuçlar verdiği görülmüştür.

Bildirinin geri kalanı şu şekilde düzenlenmiştir: 2. bölümde kullanılan veri kümesi hakkında bilgi verilmiştir. 3. bölümde kullanılan örüntü tanıma yöntemleri ve öznitelik 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 web sayfasından alınmaktadır ([www.tkm.ibb.gov.tr](http://www.tkm.ibb.gov.tr)). Trafik Kontrol Merkezi bütün İstanbul'a yayılmış 327 RTMS ile ilgili şeritlerden geçen araçların hız ortalamalarını alarak 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 yaptığı periyodik bakım çalışmaları sayesinde önlenmektedir.

Bir noktada oluşabilecek hız değerini tahmin etmek için, öznitelik 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) öznitelik vektörü olarak seçilmiştir. 1 saat sonrası hız tahmini için ise, 65, ..., 120 dakika, 1 gün ve 1 hafta önceki hız değerleri kullanılmıştır.

## 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 özniteliklerine 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. Öznitelik 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. Öznitelik 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. Birbiriyle ilişkisi karmaşık sayılabilecek ve direk doğrusal bir ilişki bulunamayan örnek problemimiz gibi konularda öznitelik 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. SVM hem sınıflandırma hem de 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 öznitelikleri seçip kullanmaktadır. Özellikle ölçümlerin alınmasının ya da saklanmasının 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 hız 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 veya Komşu Sensör Değerlerini Kullanarak Hız Tahmini

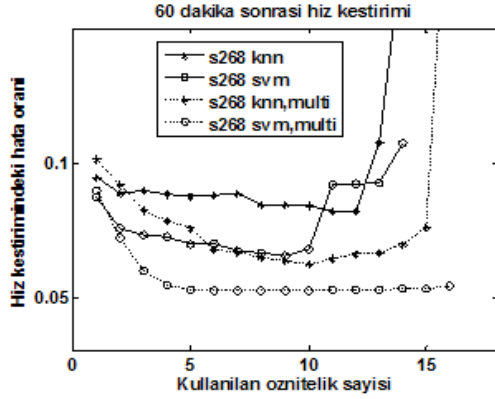
Bu bölüm deneyleri sırasında kullanılan 3 RTMS trafik sıklığı yoğun olan FSM köprüsü yolu üzerinde seçilmiştir. Bu RTMS'lerden s13 Maslak FSM köprüsü yönünde, s59 Levent FSM köprüsü yolunda bulunmaktadır. s13 ve s59'dan gelen trafiğin birleşimi ile oluşan trafik, s268 FSM köprüsünde ölçülmektedir (Şekil 1).



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

Şekil 2'de, s268 noktasında 5 dakika sonraki hız tahmini için sadece s268 sensörü kullanılarak svm ve knn yöntemleriyle ölçülen hata oranları (s268knn ve s268svm ile gösterilmiştir), ve geriye doğru öznitelik seçimi ile 3 sensörün birlikte kullanıldığında ulaşıldığı yüzde hata değerleri görülmektedir (s268knn, multi ve s268svm, multi ile gösterilmiştir). Hem s268, hem de diğer

noktalar için, SVM'nin ulaştığı hatalar, genel olarak, kNN'den daha azdır.



Şekil 2: s268 noktasında 5 dakika sonraki hız tahmini için geriye doğru öznelik seçimi.

Yaklaşık 6 sensör değerinden fazlasının kullanılması ile SVM'nin de kNN'nin de hata oranlarında büyük bir düşme görülmektedir. 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 dönemde yapılmış (-1440=1 gün, -10080=1hafta) hem de en son 1 saat içinde yapılmış ölçümler her üç nokta için de önemli bulunmuştur.

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

| Öznelik | 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 Birbirine bağımlı sensörlerin bağıntı yöntemiyle bulunması

Önceki bölümde, yakın konumdaki sensörlerin kullanılmasının hız tahmininin başarımını arttırdığı gösterilmiştir. Sensörlerin belirli aralıklarla ayarlanmaya ihtiyaç duydukları veya öngörülmeven şekilde çeşitli nedenlerle hizmet dışı kaldıkları bilinmektedir. Bu durumda birbirlerinin yerlerine kullanılacak bağımlı sensörlerin bulunması yararlı olacaktır. 327 sensörün ölçülen hız değerlerinin birbirlerine göre bağıntısı (correlation) bulunarak bağımlı sensörler bulunabilir. Her sensör noktası için bağıntısı en yüksek diğer sensör noktaları bulunmuş ve ek sensörler hız öngörüsünde yardımcı olarak kullanılmıştır. Tablo 2'de birbirlerine yüksek bağıntı ile bağlı sensörler görülmektedir.

Tablo 2: Yüksek korelasyonlu sensörler


| Sensör 1 | Sensör 2 |
|----------|----------|
| s95      | s73      |
| s266     | ts266    |
| s156     | ts156    |
| s73      | s4       |
| s95      | s4       |
| s174     | s171     |

Bu sensörlerin fiziksel konumlarına bakıldığında bunların birbirleriyle aynı yol üzerinde veya birbirlerine bağlanan yollar üzerinde olduğu görülmektedir. Örnek olarak birbirlerine sırasıyla bağımlı s95,s73 ve s4 sensörlerinin aynı yol üzerinde peşpeşe geldikleri Şekil 3'te görülmektedir.



Şekil 3: FSM Köprüsü – TEM Anadolu yolu üzerinde bulunan s95, s73 ve s4'ün konumları

Benzer şekilde Şekil 4'de görüldüğü gibi s266 ve ts266'da harita üzerinde hemen hemen aynı noktadaki yolun farklı şeritlerindeki hızı ölçmektedir. s266 Sarıyer'den – Maslak'a giden yolun hızını ölçerken, ts266 Maslak'tan Sarıyer'e giden yol üzerindeki hızı ölçmektedir.




Şekil 4: Sarıyer-Maslak yolu üzerindeki s266 ve ts266 sensörlerinin konumları

#### 4.3 Yüksek bağıntılı sensörlerin hız tahmininde birlikte kullanılması


Birbirine bağımlı sensörlerle birden çok deney gerçekleştirilmiştir. Şekil 5, 6 ve 7'de sadece sensörün geçmiş hız değerleri kullanılarak hesaplanan hata oranı ile sensörün kendi verileriyle bağıntılı bulunduğu sensörün verileri birlikte kullanıldığında hesaplanan hata oranları karşılaştırılmıştır. Bütün şekillerde SVM yöntemi öznelilik seçme yöntemleriyle elde edilen özneliliklerle kullanılmıştır.

Şekil 5'de ise 5 dakikadan 60 dakikaya kadar artan zaman aralıklarında sadece s95'in, s95+s4'ün ve s95+s4+s73'ün karşılaştırmalı SVM başarımları verilmiştir. Şekil s73 ün s95 ile birlikte kullanıldığında hata oranını düşürdüğünü göstermektedir, ek olarak s4 sensörü verilerinin kullanılmasının sonuca ek bir katkısı olmamıştır.




Şekil 5: Tahmin edilen zamanın artırılmasıyla s95 SVM metodunun kullanılması

Şekil 6 ve şekil 7'de ts266 ve s171 sensörlerinin kendisine yüksek korelasyonla bağlı sensörler ile artan zaman aralıklarında başarımları görülmektedir. Yine birden fazla sensör kullanıldığında başarımlar artmaktadır.



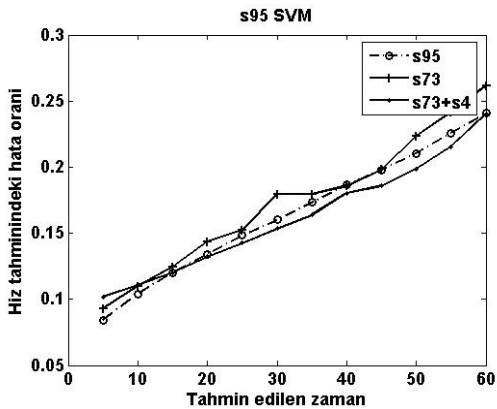
Şekil 6: Tahmin edilen zamanın artırılmasıyla s95 SVM metodunun kullanılması



Şekil 7: Tahmin edilen zamanın arttırılmasıyla s171 SVM metodunun kullanılması

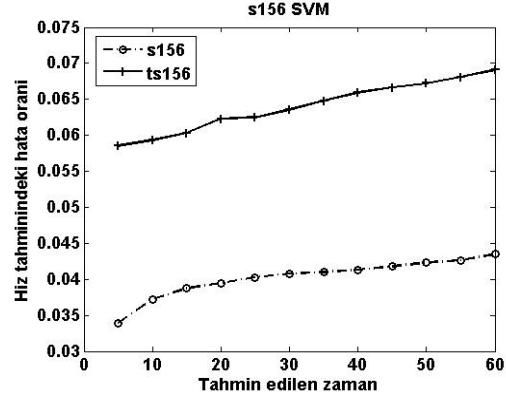
### 4.3 Yüksek bağıntılı sensörlerin birbirleri yerlerine kullanılması

Yüksek bağıntılı sensörlerin birbirlerinin hızlarına benzer hız eğrileri verdiği görülmüştür. Sensörlerin bozulma veya iletişim kopukluğu olduğu durumlarda yüksek bağıntılı sensörlerin birbirleri yerlerine kullanılabileceği düşünülebilir. Bu bölümde sensörlerin kendi verileri kullanılmadan sadece diğer sensörlerin verileri kullanılarak başarımların hesaplanacaktır. Şekil 8’de birbirlerini etkileyen 3 yüksek bağıntılı sensör kullanılmıştır. Bu sensörlerden s95 yerine s73 veya s73 ile s4’ün birlikte kullanıldığı durumda en az s95 verileri kullanıldığı kadar başarılı sonuçlar alındığı görülmektedir.




Şekil 8: Tahmin edilen zamanın arttırılmasıyla s95 için SVM metodu

Şekil 9’da yüksek bağıntılı s156 sensörünün yerine ts156 sensörü kullanıldığında yapılan hata oranları görülmektedir. %3 civarında bir hata payı ile s156 ile yapılan ölçümlere benzerlik göstermektedir.



Şekil 9: Tahmin edilen zamanın arttırılmasıyla s156 için SVM metodu

Şekil 10’da yüksek bağıntılı ts266 sensörünün yerine s266 sensörü kullanıldığında yapılan hata oranları görülmektedir. Yine %3 civarında bir hata payı ile ts266 ile yapılan ölçümlere benzerlik göstermektedir.



Şekil 10: Tahmin edilen zamanın arttırılmasıyla ts266 için SVM metodu

## 5. Sonuçlar

Bu çalışmada hem SVM, hem de kNN yöntemleri kullanılarak kısa zamanlı hız tahmini yapılmıştır.

Yapılan testlerde genel olarak bu problem için SVM yönteminin KNN yöntemine göre daha iyi sonuçlar ürettiği görülmüştür. Öznitelik seçme vektörleriyle en iyi öznitelikler karşılaştırıldığında SVM'in öznitelik sayısının 6 ve üzeri olduğu durumlarda başarımının değişmediği görülmüştür. KNN'de ise öznitelik sayısı arttıkça başarım oranı düşmektedir. Ayrıca trafik öngörüsünde 1 gün ve 1 hafta önceki hızların öznitelik olarak kullanıldığında başarımın arttığı görülmüştür. Öngörü süresi uzadıkça başarım oranları hem SVM hem de KNN için beklenildiği gibi düşmektedir, fakat SVM ve KNN'nin başarımları uzun süreli öngürülerde birbirlerine yaklaşmaktadır. Bir noktadaki hızı bulurken tek bir sensör verisi kullanmak yerine yakın konumlardaki ve ilgili noktaya bağlantı yollarındaki sensör bilgilerinin kullanılmasının hız tahmini başarımını arttırdığı tespit edilmiştir. Ayrıca birbirlerine yüksek bağımlılıkla bağlı sensörler bulunduğu bunların fiziksel olarak birbiriyle yakın konumda bulunan sensörlere karşılık geldiği ve birlikte hız tahmininde kullanılmasının başarımını arttırdığı gözlenmiştir. Sensör verilerinin alınmadığı durumlarda yakın veya yüksek bağımlılığa sahip sensör verilerinin kullanılmasının da yüksek başarım sağladığı görülmüştür.

## Kaynakça

- [1] **Alpaydin, E.**, 2004, "Introduction to Machine Learning", MIT Press.
- [2] **Bin, Y., Zhongzhen, Y. Baozhen, Y.**, 2006, "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.**, 1998, "A Tutorial on Support Vector Machines for Pattern Recognition", Data Mining and Knowledge Discovery, Vol. 2, Number 2, p. 121-167.
- [4] **Chrobok, R., Kaumann, O., Wahle, J., Schreckenberg, M.**, 2000, "Three Categories of Traffic Data: Historical, Current, and Predictive", the 9th IFAC Symposium Control in Transportation Systems, 250-25.
- [5] **Hobeika, A.G. and Kim, C.K.**, 1994, "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.**, 2000, "Day-to-day travel time trends and travel time prediction from loop detector data", Transportation Research Record, (1554).
- [7] **Lingras, P., and Mountford, P.**, 2001, "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, Proceedings, page 390, 2001.
- [8] **Mark, C.D., Sadek, A.W., Rizzo, D.**, 2004, "Predicting experienced travel time with neural networks: a PARAMICS simulation study", Intelligent Transportation Systems. Proceedings. The 7th International IEEE Conference on Volume , Issue , 3-6 Oct. 2004 Page(s): 906 - 911
- [9] **Park, D., and Ritett, L. R.**, 1998, "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.**, 1999, "Forecasting freeway link travel times with a multilayer feedforward neural network", Computer-Aided Civil and Infrastructure Engineering, 14(5), 357–367.
- [11] **Rice, J., van Zwet, E.**, 2001, "A simple and effective method for predicting travel times on freeways", Intelligent Transp. Systems, IEEE Proceedings, 227 -232.
- [12] **Ruping, S.**, 2004, "mySVM software", Available: <http://www-ai.cs.uni-dortmund.de/SOFTWARE/MYSVM>
- [13] **Sun, H., Liu, H., and Ran, B.**, 2003, "Short Term Traffic Forecasting Using the Local Linear Regression Model", Transportation Research Record.
- [14] **W.C.Van Lint, W.C., Hoogendoorn, S.P., and van Zuylen, H.J.**, 2000, "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**, 2004, "Travel-time prediction with support vector regression", Intelligent Transportation Systems, 5(4), 276 – 28, Dec. 2004.

[16] **Zhang, Z., Rice, J., and Bickel, P.**, 1999, "Empirical Comparison of Travel Time Estimation Methods", Report for MOU 353, UCB-ITS-PRR-99-43, ISSN1055-1425, December 1999