

# Ein instanzbasiertes Lernverfahren zur Schätzung und Prognose von Verkehrskenngrößen unter Nutzung räumlich-zeitlicher Verkehrsmuster

Axel Leonhardt

Der Artikel beschreibt ein instanzbasiertes Lernverfahren zur Schätzung und Prognose von Verkehrskenngrößen auf Basis räumlich-zeitlicher Verkehrsmuster. Instanzbasierte Lernverfahren sind Mustererkennungsverfahren und können zur Lösung von Regressionsproblemen verwendet werden. Wesentliches Merkmal dieser Verfahrensgruppe ist, dass der Schätzwert zur Laufzeit nur auf Basis der jeweils relevantesten historischen Beobachtungen gebildet wird. Das Verfahren kann eingesetzt werden, wenn historische Beobachtungen zusammen mit relevanten unabhängigen Variablen vorliegen und diese unabhängigen Variablen zum Zeitpunkt der Schätzung verfügbar sind. Dadurch wird das Verfahren insbesondere zur Schätzung von „zufällig“ im Netz beobachtbaren Verkehrskenngrößen (z.B. Reisezeiten aus Fahrzeugpositionsmeldungen) auf Basis kontinuierlich erhobener Verkehrsdaten (typischerweise aus lokalen Detektoren) interessant.

The paper describes an instance based learning method for the estimation and short term prediction of traffic parameters, based on spatio-temporal traffic patterns. Instance based learning is a data mining method to solve regression problems. One important characteristic of such models is that the functional relationship between input and output variables is not estimated globally but only based on the most relevant observations. The proposed method can generally be used to estimate any traffic parameter if there are historical observations of the respective parameter and if there are relevant features available at the time the estimation is made. This makes the method particularly useful for the estimation and prediction of occasionally observed variables (e.g. travel times from probe vehicles) based on continuously observed parameters (e.g. data from local detector stations).

Verfasseranschrift:  
Dr.-Ing. A. Leonhardt,  
Technische Universität  
München,  
Lehrstuhl für Verkehrs-  
technik,  
Arcisstraße 21,  
80333 München,  
axel.leonhardt@vt.bv.tum.de

## 1 Einleitung

Ziel des modernen Straßenverkehrsmanagements ist eine angepasste und umfassende Unterstützung des Verkehrsteilnehmers durch individuelle Dienste sowie die netzoptimale Beeinflussung der Verkehrsteilnehmer über kollektiv wirkende Systeme. Dabei bildet das Wissen über aktuelle und zukünftige Verkehrszustände bzw. entsprechende Verkehrskenngrößen ein zentrales Element.

### 1.1 Erfassung, Schätzung und Prognose von Verkehrskenngrößen

Lokale Kenngrößen werden in der Regel kontinuierlich erfasst, sind jedoch in ihrer Aussagekraft zunächst auf einen lokalen Querschnitt beschränkt. Aus Nutzer- und Betreibersicht relevante streckenbezogene Größen wie Reisezeiten und Staulängen lassen sich daraus nicht direkt herauslesen. Die direkte Erhebung streckenbezogener Kenngrößen ist heutzutage nicht

der Regelfall. Genutzt werden beispielsweise fahrzeuggenerierte Daten oder – teilweise temporär installierte – Systeme zur Fahrzeugwiedererkennung. Häufig ist eine kontinuierliche Erfassung nicht möglich und es entsteht ein „löchriges“ Bild. Um diese Löcher zu schließen, aber auch um die kurzfristige Entwicklung prognostizieren zu können, müssen Modelle oder Berechnungsverfahren eingesetzt werden. Verfahren der Mustererkennung können eingesetzt werden, wenn die gesuchten Verkehrskenngrößen zumindest zufällig erfasst und archiviert wurden und wenn zum Zeitpunkt der Modellierung beschreibende Variablen („Muster“) vorliegen, die mit den historischen Mustern verglichen werden können.

### 1.2 Mustererkennung zur Lösung von Regressionsproblemen

Der Forschungsgegenstand der Mustererkennung sind große, strukturierte Datenbestände und beinhaltet Verfahren zum

automatisierten Erkennen und Auswerten von Mustern in ein- oder mehrdimensionalen Signalen. Detaillierte Erläuterungen zum Thema finden sich beispielsweise in Hagedorn et al. [1997]. Die Regression als Teilgebiet der Mustererkennung beschäftigt sich mit der Schätzung und Prognose von numerischen Daten. Dazu werden auf Basis von Beobachtungen (Beispiel- oder Trainingsdatensätzen) Zusammenhänge zwischen den zu prognostizierenden Größen (den abhängigen Variablen)  $y$  und gemessenen Größen (unabhängigen Variablen)  $X$  hergestellt:

$$y = f(X), X = x_1, \dots, x_n.$$

Es existieren verschiedene Verfahren zur Lösung von Regressionsproblemen. Bei regressionsanalytischen Verfahren werden Zusammenhänge zwischen einer (einfachen Regression) bzw. mehreren (multiple Regression) unabhängigen Variablen und einer abhängigen Variablen angenommen und geschlossen funktional formuliert.




Bild 1: Darstellung von globaler und lokaler Funktionsnäherung

Künstliche Neuronale Netze sind flexible, aus einfachen Verarbeitungseinheiten (Neuronen) bestehende Funktionsapproximatoren. Aufgrund ihrer Struktur existieren effiziente Lernalgorithmen zur optimalen Verknüpfung der Neuronen mit dem Ziel, den Zusammenhang zwischen unabhängigen und abhängigen Variablen herzustellen. Selbstlernende Expertensysteme sind hybride Verfahren, die Expertenwissen über Zusammenhänge in Form prototypischer Regeln, Fallbeispielen oder Entscheidungsbäumen abbilden und diese auf Basis von Trainingsdaten optimieren. Instanzbasierte Lernverfahren (auch: Parameterfreie Regression) berechnen die Ähnlichkeit des aktuellen Musters  $X$  zu den historischen Instanzen entsprechend eines vorgegebenen Ähnlichkeitsmaßes zur Laufzeit und approximieren  $y$  aus den zugehörigen historischen abhängigen Variablen direkt auf Basis der Trainingsdaten. Im folgenden Abschnitt wird diese Verfahrensklasse detailliert beschrieben.

### 1.3 Instanzbasierte Lernverfahren

#### Verfahrensprinzip

Instanzbasiertes Lernen kann mit einem Zitat von Moore (2001) treffend beschrieben werden:

*"To make a prediction, search database for similar datapoints, and fit with the local points."*

Beim instanzbasierten Lernen wird also keine globale Funktion zur Abbildung des gesamten Wertebereichs gebildet (Bild 1, links), sondern die vermutete Funktion durch lokale Teillösungen direkt aus den Beobachtungen angenähert (Bild 1, rechts).

#### Anwendungsvoraussetzungen für instanzbasierte Lernverfahren

Bei der Verwendung instanzbasierter Lernverfahren sind einige Voraussetzungen zu beachten:

- Wie bei jedem Regressionsverfahren muss ein Zusammenhang zwischen den

unabhängigen Variablen  $X$  und der zur prognostizierenden abhängigen Variable  $y$  bestehen.

- Die aktuellen Daten und die historischen Instanzen müssen der gleichen Verteilung entstammen, es müssen also die gleichen Randbedingungen gegeben sein.
- Der Merkmalsraum sollte möglichst vollständig von den Instanzen belegt sein, es sollte also eine möglichst große Basis an historischen Beobachtungen vorliegen.

#### Eigenschaften instanzbasierter Lernverfahren

Instanzbasierte Lernverfahren bieten den Vorteil, dass sie intuitiv verständlich sind (keine „Black Box“) und dass durch die kontinuierliche Ergänzung des Datenarchivs eine selbstgegebene Adaptivität erreicht wird. Aufgrund der lokalen Approximation muss keine globale Funktion formuliert und gelernt werden, was bei zu erwartenden stark nicht-linearen Zusammenhängen günstig ist. Hauptnachteil der instanzbasierten Lernverfahren ist die benötigte Rechenzeit und der benötigte Speicherbedarf, da das Modell nicht in einer vorgeschalteten offline-Trainingsphase generiert wird, sondern bei jeder Prognoseanforderung neu gebildet werden muss.

#### Anwendungsbeispiele für instanzbasierte Lernverfahren

Es finden sich zahlreiche Anwendungen von instanzbasierten Lernverfahren zur Schätzung und Kurzfristprognose von Verkehrskenngrößen.

Wild (1996) stellt ein Verfahren zur Kurzfristprognose von Verkehrsstärken auf Basis historischer Verkehrsstärkeganglinien vor. Zur Prognose wird jeweils der zur bisherigen Tagesganglinie ähnlichste Repräsentant der entsprechenden Tagesklasse verwendet. Der Eingangsvektor ist also ein lokales, zeitlich ausgedehntes Muster.

Maier et al. (2008) beschreibt ein Verfahren zur Kurzfrist-Prognose von Störungsausbreitungen auf Basis räumlicher Mustererkennung. Grundlage bilden Verkehrszustände aus einem dynamischen Routenwahl- und Umlegungsmodell. Aus einer historischen Datenbasis werden die zur aktuellen Situation am besten passenden Muster ausgewählt und zur Prognose herangezogen. Der Eingangsvektor beschreibt ein räumlich ausgedehntes Muster zu einem Zeitintervall.

Förster (2008) stellt ein Verfahren vor, in dem die Verkehrsstärken für mehrere Messstellen in einem Netz durch einen Abgleich der aktuellen Messungen mit einer historischen Datenbasis für einen Horizont von 20 Minuten prognostiziert werden. Dabei wird die aktuelle Situation in ihrer Gesamtheit (alle Messstellen über mehrere Zeitintervalle) mit der Datenbasis verglichen, die ähnlichste ausgewählt und auf deren Basis die Prognose für alle Messstellen abgeleitet. Der Eingangsvektor beschreibt ein räumlich-zeitlich ausgedehntes Muster, das für alle betrachteten Messstellen gilt.

Robinson (2005) stellt ein Verfahren zur Schätzung von Reisezeiten vor. Dabei werden Reisezeiten der Kennzeichenerfassung aus dem Londoner City-Maut System als abhängige Variable und lokale Verkehrsstärken sowie Belegungsgraden mehrerer Messstellen auf der jeweiligen Strecke als unabhängige Variable betrachtet.

## 2 Entwicklung eines instanzbasierten Lernverfahrens zur räumlich-zeitlichen Mustererkennung

Im Folgenden wird das Verfahren, ohne andere Fälle auszuschließen, anhand der Reisezeit als abhängige Variable und anhand von Belegungsgraden lokaler Detektoren als unabhängige Variable erklärt. Grundlage ist eine strukturierte Datenbasis, in der alle Daten auf ein einheitliches Zeitraster (hier: 15 Minuten) referenziert sind.

### 2.1 Gesamtübersicht über das Verfahren

Das Bild 2 zeigt einen Gesamtüberblick über die einzelnen Verfahrensschritte. Für den zu schätzenden Wert  $y_r(t + \Delta t)$  (im Beispiel ist das die Reisezeit auf der Route  $r=3$  für einen Prognosehorizont von  $\Delta t=1$ ) werden die zur Schätzung relevanten Messstellen ausgewählt. Von diesen Messstellen werden die Daten bis zu einem

vorzuziehenden maximalen Alter als beschreibendes Verkehrsmuster verwendet. Die Verkehrskenngrößen werden für den späteren Zugriff fortlaufend archiviert. Für jedes historische Muster  $X_i(t+\Delta\varnothing t)_{hist,i}$ , für das die gewünschte Größe vorliegt (im Beispiel liegen 2 Instanzen vor), wird die Distanz (also die „Unähnlichkeit“)  $D_i$  zu dem aktuellen Muster berechnet. Die  $k$  ähnlichsten Instanzen werden zur Prognose herangezogen.

## 2.2 Berechnung der Ähnlichkeit zweier Situationen

Die Relevanz des jeweiligen Musters ist proportional zu seiner Ähnlichkeit zur aktuellen Situation. Zur Bestimmung der Ähnlichkeit wird die Distanz  $D$  zwischen jeweils zwei Situationen berechnet.  $D$  wird zur Summe aus der mit  $G_V$  gewichteten Distanz zwischen den berücksichtigten Verkehrsdaten (den Verkehrsmustern)  $D_V$ , der Distanz der Kalendermerkmale (Wochentag und Tageszeit)  $D_K$  und einem Strafterm für unvollständige Verkehrsmuster  $S_F$  definiert:

$$D = G_V \cdot D_V + D_K + S_F.$$

Auswahl und Gewichtung der Verkehrsmerkmale

Wird zu einem Zeitpunkt  $t$  eine Reisezeitprognose  $y'$  auf der Route  $r$  für den Zeitpunkt  $t + \Delta t$  berechnet, dann werden zunächst alle historischen Instanzen  $X_i$  identifiziert, für die eine entsprechende Beobachtung  $y$  vorliegt. Die Merkmale  $x_{i,j}$  ( $ds, dt$ )  $\in X_i$  sind lokale, auf das gewählte Zeitraster aggregierte Belegungsgrade relevanter Detektoren. Bei der Ähnlichkeitsberechnung werden die Merkmale entsprechend dem Abstand  $ds$  des Detek-

tors von der Route  $r$  und entsprechend ihrem Alter  $dt$  mit dem Gewichtungsfaktor  $g_j$  gewichtet:

$$g_j(ds, dt) = \max \left\{ 0, 1 - \frac{ds}{ds_{max}} - \frac{dt}{dt_{max}} \right\}.$$

Die räumliche Relevanz des Merkmals  $j$  wird durch den stromabwärtigen Abstand  $ds$  des Detektors zur betrachteten Route  $r$  im Straßennetz berücksichtigt. Dem liegt die Annahme zugrunde, dass sich innerorts die Information in Form der Nachfrage primär in Flussrichtung ausbreitet und dass sich relevante Ereignisse wie Staus auch primär durch eine zu hohe Nachfrage an den Knotenpunkten einstellen. Alternativ können auch Korrelationsanalysen oder Routenspinnen zur Schätzung der Relevanz verwendet werden.  $ds_{max}$  ist der maximale Abstand, innerhalb dessen ein Detektor berücksichtigt wird. Die zeitliche Relevanz eines Merkmals geht über das Alter  $dt$  ein. Es werden Merkmale bis zu einem Alter  $dt_{max}$  berücksichtigt. Je älter ein Messwert im aktuellen Muster und je weiter die entsprechende Messstelle entfernt ist, desto geringer ist der Einfluss dieses Messwertes. Die lineare Form der Gewichtsfunktion kann prinzipiell durch andere Formen (z.B. Exponentialfunktion, Berücksichtigung der Informationsfortpflanzungsgeschwindigkeit) ersetzt werden.

Zur Berechnung der Ähnlichkeiten der aus den relevanten Merkmalen bestehenden Verkehrsmuster (dem aktuellen Verkehrsmuster  $X_i^{akt}$  und dem historischen Verkehrsmuster  $X_i^{hist}$ ) wird die Distanz  $D_{V,r,i}$  auf Basis einer gewichteten, auf den Mittelwert der Merkmale des aktuellen Musters  $\bar{x}_i^{akt}$  normierten  $L_k$ -Norm verwendet:



... sorgen wir für Sicherheit im Straßenverkehr mit Lichtsignalanlagen, Verkehrsbeeinflussungsanlagen und Anlagen für den ruhenden Verkehr.



SAG GmbH · Pitterstraße 44 · 63225 Langen  
T +49 6103 4858-0 · F +49 6103 4858-389  
E info@sag.de · I [www.sag.eu](http://www.sag.eu)

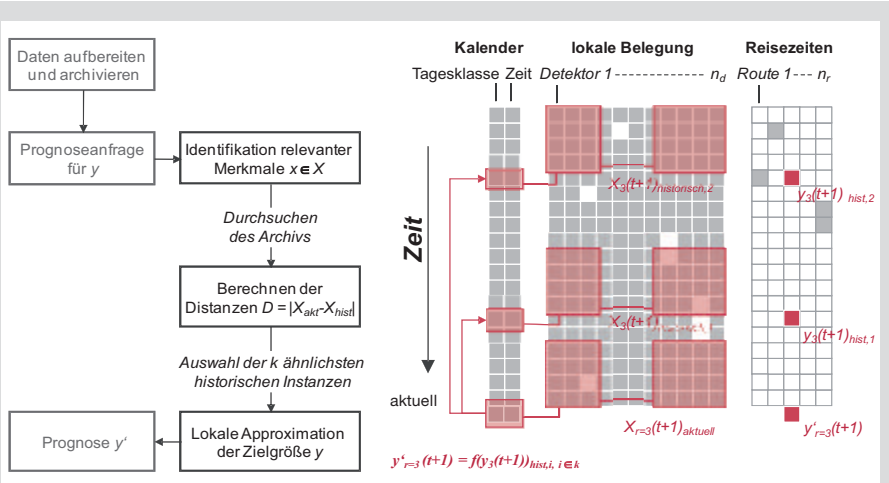


Bild 2: Schematische Darstellung des Mustererkennungsprozesses

$$D_{V,r,i} = \frac{\left[ \sum_j (g_j(ds,dt) \cdot |x_{ij}^{akt}(ds,dt) - x_{ij}^{hist}(ds,dt)|^{k_c}) \right]^{\frac{1}{k_c}}}{\sum_j (g_j(ds,dt) \cdot \bar{x}_i^{akt})}$$

mit  $0 \leq g \leq 1$ .

Mit einem großen Exponenten  $k_c$  wird dabei eine größere Gewichtung einzelner größerer Abstände erreicht. Die Normierung wird zur Berücksichtigung möglicherweise fehlender Messwerte benötigt.

### Kalenderbasierte Distanz

Tagesklasse und Tageszeit stellen aufgrund typischer Nachfragestrukturen wichtige Merkmale zur Schätzung und Prognose verkehrlicher Kenngrößen dar. Daher werden die Ähnlichkeit der aktuellen und der historischen Tagesklasse, sowie die Übereinstimmung der Tageszeiten als Merkmal bei der Bewertung der Ähnlichkeit zweier Situationen berücksichtigt.

Die Tagesklassen werden anhand der Wochentage und weiterer verkehrsrelevanter Merkmale wie „Feiertag“ und „Brückentag“ festgelegt. In einem Ereigniskalender können einzelne Tage zusätzlich entsprechend verkehrswirksamer Ereignisse definiert werden.

Zur Beschreibung der kalenderbasierten Distanz des aktuellen Musters zu einer historischen Instanz  $i$  wird das Distanzmaß  $D_{K,i}$  definiert. Dabei soll  $D_{K,i}$  klein sein, wenn sich der Erwartungswert der zu prognostizierenden Größe für das Merkmal (Tagesklasse, Tageszeit) für die Muster wenig unterscheidet.  $D_{K,i}$  wird definiert als:

$$D_{K,i}((T_i, Z_i), (T_{akt}, Z_{akt})) = \frac{E_y(T_i, Z_i) - E_y(T_{akt}, Z_{akt})}{\bar{y}}$$

$E_y$  ist dabei der Erwartungswert der abhängigen Variablen je Tagesklasse  $T$  und Zeitintervall  $Z$ . Durch Division durch den Mittelwert der abhängigen Variablen über die gesamte Stichprobe  $\bar{y}$  werden die Unterschiede in den Erwartungswerten relativiert.

Durch die Integration der Tagesklassen

und der Tageszeit als Distanzfunktion wird eine Berücksichtigung dieser insbesondere für größere Prognosehorizonte relevanten Merkmale möglich. Gleichzeitig ist durch eine entsprechende Gewichtung das Tagesklassen- und Tageszeit-übergreifende Erkennen signifikanter Verkehrssituationen möglich, da der Mustervergleich nicht ausschließlich auf identische Tagesklassen beschränkt ist.

### Strafterm zur Berücksichtigung fehlender Messwerte

Aufgrund fehlender oder nicht verwendbarer Messwerte kann es zu „Löchern“ in der eigentlich kontinuierlichen lokalen Datenerfassung kommen. Muster sollten jedoch auch bei fehlenden Messwerten bezüglich ihrer Ähnlichkeit bewertet werden können. Die oben beschriebene Funktion zur Berechnung der Distanz  $D_V$  zweier Verkehrsmuster ist normiert auf die Anzahl der verwendbaren Muster. Ergebnis ist also eine durchschnittliche Distanz der einzelnen Merkmale. Die Distanz der Verkehrsmuster sollte jedoch stärker gewichtet werden, wenn das Muster vollständig ist. Ansonsten besteht die Gefahr, dass stark unvollständige Muster mit einzelnen zufällig ähnlichen Messwerten als nächste Nachbarn identifiziert werden.

Bei der Distanzberechnung wird daher der Strafterm  $S_F$  für fehlende Messwerte eingeführt.  $S_F$  berechnet sich zu:

$$S_{F,i} = \frac{n_{gesamt,i} - n_{gültig,i}}{n_{gesamt,i}} \cdot \left[ 1 - \frac{t_{prog}}{t_{prog,max}} \right]$$

mit  $0 \leq t_{prog} \leq t_{prog,max}$  und  $0 \leq n_{gültig} \leq n_{gesamt,i}$ .

Dabei ist  $n_{gesamt,i}$  die Anzahl der möglichen Verkehrsmerkmale des Musters  $X_i$ .  $n_{gültig,i}$  ist die Anzahl der Merkmale, die sowohl im aktuellen als auch im historischen Muster  $X_i$  vorhanden sind (Bild 3).

$S_{F,i}$  nimmt dabei, ebenso wie die Gewichtung der Ähnlichkeit der Verkehrsmuster, proportional mit steigendem Prognosehorizont  $t_{prog}$  ab.

### 2.3 Lokale Approximation der Daten

Sortiert man die Instanzen aufsteigend nach der berechneten Distanz, so erhält man mit den  $k$  ersten Listeneinträgen die so genannten „ $k$  nächsten Nachbarn“. Aus diesen wird die Funktion lokal als gewichteter Mittelwert approximiert.

$$y' = \frac{\sum_{i=1}^k w_i \times y_i^{hist}}{k}$$

Die lokale Approximation wird wiederum als Regressionsproblem aufgefasst (nur eben auf Basis der  $k$  relevantesten und nicht allen vorliegenden Beobachtungen) und kann entsprechend gelöst werden.

Die Anzahl  $k$  bestimmt Glättung und Spezifität. Je größer  $k$ , desto stärker geglättet und weniger spezifisch ist die Schätzung für  $y$ . Für den Extremfall  $k = n$  ist die Schätzung für  $y$  gleich dem Mittelwert über alle jemals gemachten Beobachtungen. Für den Extremfall  $k = 1$  entspricht der Schätzwert der zum ähnlichsten historischen Muster gehörenden Beobachtung.

Zur Berechnung des Gewichts der  $k$  ähnlichsten Muster wird ein Gauß-Kern verwendet. Gauß-Kerne haben einige günstige Eigenschaften: Das Gewicht konvergiert mit steigender Distanz exponentiell abnehmend gegen null. Somit werden Instanzen mit geringer Distanz deutlich bevorzugt. Gleichzeitig wird das Gewicht aber nie gleich null, so dass auch dann eine Lösung ermittelt werden kann, wenn alle Instanzen eine relativ große Distanz zum aktuellen Muster aufweisen. Des Weiteren besitzt der Gauß-Kern mit der Kernweite  $K_w$  nur einen einzustellenden Parameter. Das Gewicht  $w_i$  der Instanz  $i$  berechnet sich zu:

$$w_i = e^{-\frac{D_i/D_{i,min}}{K_w}}$$

$K_w$  ist dabei die so genannte Kernweite und bestimmt den Einfluss der berücksichtigten Instanzen als Funktion ihrer Distanz zum aktuellen Muster. Wird  $K_w$  groß gewählt, dann haben auch unähnliche Instanzen einen relativ großen Einfluss auf die Prognose und die Prognose wird konservativer. Die Distanz  $D_i$  wird auf das minimale  $D_{i, i=1..k}$  bezogen, so dass die Distanz der ähnlichsten Instanz auf den Wert 1 normiert ist.

### 2.4 Parameterkalibrierung

Das vorgestellte Verfahren zur Schätzung von Verkehrskenngrößen besitzt sechs Parameter. Während die optimale Anpassung




Bild 3: Ermittlung der Anzahl der gültigen Merkmale des Verkehrsmusters

an die Trainingsdaten ein Teil des Mustererkennungsprozesses und damit automatisiert ist, können die Modellparameter auf Basis von Trainingsmustern kalibriert werden. Da sich das Optimierungsproblem nicht als ableitbare Funktion formulieren lässt, eignen sich heuristische Optimierungsverfahren wie Genetische Algorithmen (siehe beispielsweise Bajwa et al. (2003)). Dabei werden zu Beginn des Optimierungsprozesses Initiallösungen generiert und anhand ihrer Güte (Schätz-/Prognosegenauigkeit) bewertet. Ist ein Abbruchkriterium erreicht, wird die Lösung verwendet und die Optimierung beendet. Wenn nicht, so werden auf Basis des Selektionsschemas Individuen aus der aktuellen Generation zur Fortpflanzung ausgewählt. Aus den ausgewählten Individuen wird über genetische Operatoren eine neue Generation gebildet und bewertet. Dieser Prozess wird solange wiederholt, bis ein Abbruchkriterium (Güte, Konvergenz und maximale Anzahl an Iterationen) erfüllt ist. Detailliertere Erläuterungen können in der einschlägigen Literatur gefunden werden (z.B. in Gerdes et al. (2004)).

Im Bild 4 ist die Performanz in Form des Zielfunktionswerts als Funktion der Generation dargestellt. Sowohl für den Belegungsgrad, als auch für die Reisezeit ist deutlich zu sehen, dass die Prognosegüte für die Initiallösungen ebenso wie im weiteren Verlauf für die kleineren Prognosehorizonte höher ist.

Der Parameter  $k$  ist ein wesentlicher Parameter des Verfahrens, er bestimmt die Glättung der Schätzung. Der Literatur ist zu entnehmen, dass es keine allgemeine Regel zur Wahl von  $k$  gibt,  $k$  jedoch  $\leq \sqrt{n}$  ( $n$  = Anzahl aller Instanzen des Archivs) gewählt werden sollte (siehe Jönsson

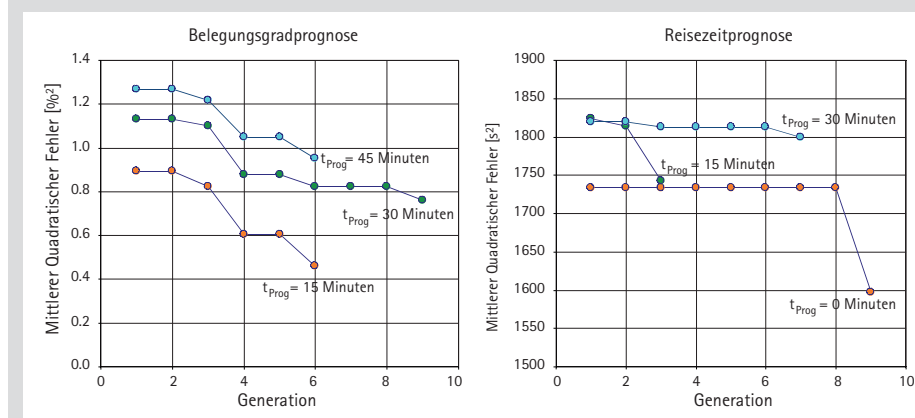


Bild 4: Visualisierung des Zielfunktionswertes MQF für verschiedene Prognosehorizonte bei der Optimierung der Belegungsgradprognose (links) und der Reisezeitprognose (rechts) mit Genetischen Algorithmen

und Wohlin (2004)). Der Parameter  $K_w$  bestimmt die Glättung innerhalb der ausgewählten  $k$  Beobachtungen. Mit  $K_w$  gegen unendlich geht der negative Exponent des Gauß-Kerns gegen null und jede der  $k$  Beobachtung wird unabhängig von der Ähnlichkeit des zugehörigen Musters bei der Schätzung berücksichtigt (arithmetischer Mittelwert). Wird  $K_w$  klein gewählt, wird die Distanz „verstärkt“; größere Distanzen führen zur überproportionalen Abnahme des Gewichts  $w$ . In der Anwendung kann das praktisch zu einer Reduzierung der berücksichtigten Nachbarn  $k$  führen, da Gewichte der unähnlicheren Muster viel kleiner als die der ähnlichen Muster sind. Für die Belegungsgradprognose zeigt sich die Wahl eines hohen  $K_w$  für große Prognosehorizonte als günstig, d.h. für größere Horizonte werden die Instanzen tendenziell gleich gewichtet, was zu einer stärkeren Glättung führt. Für die Reisezeitprognose ist diese Tendenz nicht klar erkennbar.

In den meisten Szenarien zeigt sich ein

hoher Wert von  $G_v$ , also eine hohe Gewichtung des Verkehrsmusters relativ zu den Kalendermerkmalen, als günstig.  $k_c$  ist eher niedrig zu wählen. D.h., eine überproportionale Gewichtung einzelner starker Abweichungen im Verkehrsmuster ist nicht sinnvoll. Für das optimale  $dt_{max}$  ist keine klare Tendenz zu erkennen, der Parameter ist stark lokationsabhängig. Insgesamt zeigen sich für alle Szenarien relativ kleine Werte für  $ds_{max}$  als günstig. Das bedeutet, dass die starke Gewichtung entfernter Messstellen tendenziell ungünstig ist. Wenn also Messstellen auf einer betrachteten Route zur Verfügung stehen, kann es besser sein, nur diese zur Prognose zu verwenden und nicht auch entfernte Messstellen.

### 3 Anwendung und Bewertung des Verfahrens

Das Verfahren ist ein allgemeiner Schätzer, der im Prinzip alle Größen schätzen



## Kompetenz in Verkehrsleittechnik

### Wir leiten den Verkehr auch auf Ihren Straßen ...

... mit innovativen, funkgesteuerten Stadtinformations- und Baustellenwarnsystemen oder mit unserer mobilen, radarbasierten Geschwindigkeitswarnanlage TRANS-100.

Besuchen Sie uns auf der Intertraffic 2010 - Stand Nr. 11.531

NIECHOJ TRAFFIC SYSTEMS GmbH  
Bildstock 5, 88085 Langenargen

Tel +49 (0)75 43 93 47 - 0  
www.niechoj.de, E-Mail info@niechoj.de

2010 Intertraffic  
AMSTERDAM  
Wir nehmen teil | We are participating

und prognostizieren kann, für die historische Beobachtungen und geeignete unabhängige Variable zur Beschreibung vorliegen. In diesem Kapitel wird das Verfahren auf folgende Eingabe-Ausgabedaten Konstellationen in städtischen Netzen angewendet:

- Reisezeitschätzung (Beobachtungen  $y$  aus Taxipositionsmeldungen, Muster  $X$  aus lokalen Belegungsgradmessungen), Testfeld Graz.
- Reisezeitschätzung ( $y$  aus Fahrzeugwiedererkennung,  $X$  aus Verkehrsstärkemessungen), Testfeld München.
- Belegungsgradschätzung ( $y$  und  $X$  aus lokalen Belegungsgradmessungen), Testfeld Graz.

### 3.1 Schätzung und Prognose von Reisezeiten

a)  $y$  aus Taxipositionsmeldungen,  $X$  aus Belegungsgraden

In Graz liegen Daten lokaler Messstellen (aus Siemens CONCERT, insgesamt ca. 320 Messquerschnitte und Taxipositionsmeldungen der Taxi878 Taxizentrale (i. d. R. ca. 160 Fahrzeuge online) vor. Die Ermittlung von Reisezeiten aus Taxipositionsmeldungen ist Gegenstand verschiedener Untersuchungen (z. B. Schäfer (2005), Linauer et al. (2006), Leonhardt (2008)) und wird hier nicht näher behandelt. Die hier verwendeten Reisezeiten stammen aus dem OnVLS (Online Verkehrsloge System) Graz.

Der Belegungsgrad wurde als unabhängige Variable ausgewählt, da er gegenüber der Verkehrsstärke den Vorteil besitzt, auch überlastete Zustände eindeutig abbilden zu können. Es werden die Belegungsgrade einzelner Detektoren verwendet, da eine Aggregation zu Querschnittswerten möglicherweise wertvolle Information wie Rückstau auf einzelnen Abbiegefahrstreifen unterschlagen würde. Stochastische Schwankungen werden durch eine Aggregation auf 15 Minuten und eine anschließende exponentielle Glättung herausgefiltert.

Im Bild 5 sind die Ergebnisse der Reisezeitschätzung auf einer Route über den Opernring in Graz über eine Woche (16. bis 22. November 2007) auf Basis der Belegungsgrade von Detektoren direkt auf der Route sowie stromaufwärts der Route dargestellt.

Am Freitag sind einige sehr hohe Taxi-reisezeiten zu beobachten. Da diese von mehreren aufeinander folgenden Taxis „bestätigt“ werden, ist davon auszugehen, dass hier tatsächlich eine substantielle Störung im Verkehrsablauf vorgelegen hat. Es ist zu sehen, dass das instanzbasierte Lernverfahren den deutlichen Reisezeitanstieg abbildet, jedoch nicht in der Ausprägung wie durch die Taxis beobachtet. Im weiteren Verlauf zeigt sich – bis auf einen Ausreißer – ein plausibler Verlauf der Reisezeit. Insbesondere konnten die ausgeprägten Reisezeitanstiege am Montag und Dienstag im Vergleich zu Mittwoch und Donnerstag abgebildet werden.

b)  $y$  aus Fahrzeugwiedererkennung,  $X$  aus Verkehrsstärken

In München stehen auf ausgewählten Routen Reisezeiten aus Kennzeichenerkennungssystemen und lokale Verkehrsstärken zur Verfügung. Als Trainings- und Referenzdaten wurden Reisezeiten aus der Fahrzeugwiedererkennung verwendet. Als unabhängige Variable wurden Verkehrsstärken von auf der Route liegenden LSA nahen Detektoren verwendet, da der Belegungsgrad nicht vorlag. Die Verkehrsstärke eignet sich nicht optimal als Prädiktor für die Reisezeit, da niedrige Verkehrsstärken sowohl auf Stau, als auch auf geringe Nachfrage hindeuten können. Insgesamt sind trotzdem eine gute Übereinstimmung und ein plausibler Verlauf festzustellen. Insbesondere der deutlich überdurchschnittliche Anstieg der Reisezeit am Donnerstag (ganz rechts im Bild 6)

Bild 5: Geschätzte Reisezeiten und Reisezeiten aus Taxipositionsmeldungen

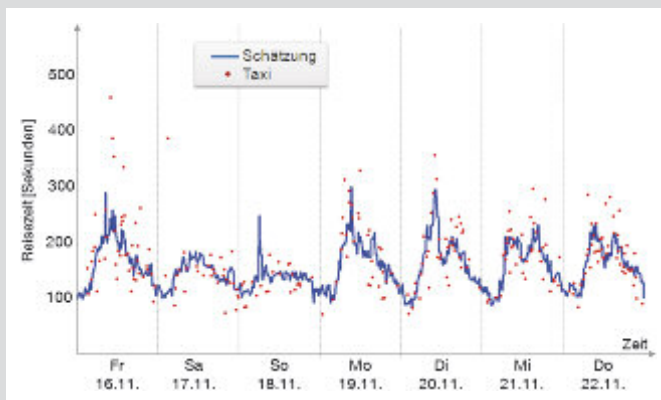


Bild 6: Geschätzte Reisezeiten und Reisezeiten aus Fahrzeugwiedererkennung

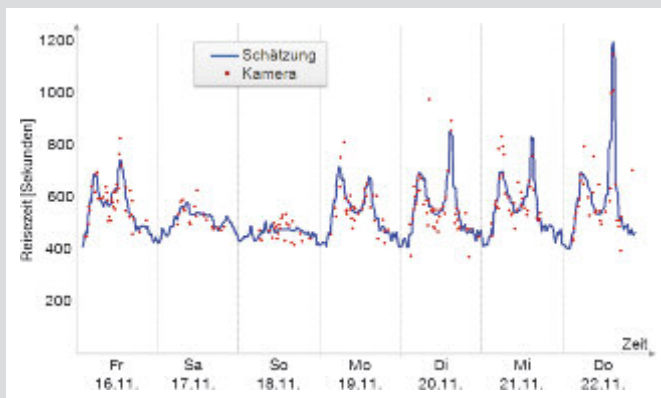
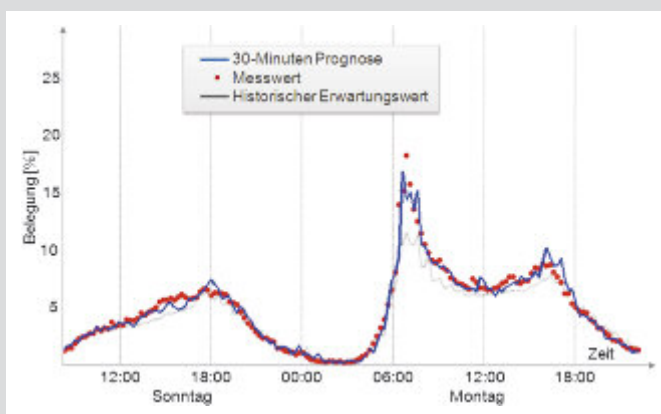


Bild 7: Prognostizierte und gemessene Belegungsgrade



wird vom instanzbasierten Lernverfahren gut abgebildet.

### 3.2 Prognose von Belegungsgraden

Der Einsatz des Verfahrens zur Belegungsgradprognose ist hier am Beispiel eines Detektors am Exerzierplatz in Graz für einen Prognosehorizont von 30 Minuten dargestellt (Bild 7, Daten von Sonntag dem 18.1.2007 bis Montag den 19.11.2007). Interessant ist vor allem die deutlich bessere Prognose gegenüber dem historischen Erwartungswert am Montag.

### 3.3 Zusammenfassung der Ergebnisse und Vergleich mit anderen Verfahren

Zur Beurteilung der Schätz- und Prognosegüte wird der Grad der linearen Abhängigkeit von Schätzung und Referenz mit dem Bestimmtheitsmaß  $r^2$  basierend auf dem empirischen Korrelationskoeffizienten verwendet. Daneben werden für den Belegungsgrad und die Reisezeit Fehlermaße definiert und ermittelt. Die Bewertung basiert auf einem zwei Wochen umfassenden Testdatensatzes. Die Trainingsdatenbasis umfasst sechs Monate.

#### Belegungsgrad

Für die Belegungsgrade liegen mit den gemessenen Belegungsgraden „sichere“ Referenzdaten vor. Die Abweichung der Schätzung von der Referenz wird mit dem mittleren quadratischen Fehler MQF aller Beobachtungen beschrieben.

In den Tabellen 1 und 2 sind die Ergebnisse für die Belegungsgradprognose dargestellt.

#### Reisezeiten

Für die Reisezeiten liegen mit den Taxireisezeiten in Graz Vergleichswerte vor, die Informationen über die Größenordnung der Reisezeiten liefern, nicht jedoch als 100 %ig korrekte Referenz betrachtet werden können. Grund ist vor allem, dass der Reisezeit mit einer Einzelmessung nur ein kleiner Teil des gesamten Fahrzeugkollektivs zugrunde liegt. Aufgrund der größeren Stichprobe nicht ganz so gravierend, aber dennoch gegeben, ist die Problematik bei den Reisezeiten aus der Fahrzeugwiedererkennung. Trotzdem stellen die Einzelfahrzeugreisezeiten wichtige und verwertbare Informationen über den Verkehrszustand auf der jeweiligen Route dar, die eine Beurteilung der Plausibilität der geschätzten und prognostizierten Reise-

$t_{\text{Prog}}$ [Minuten]	0	15	30	45	60
Belegungsgradprognose Exerzierplatz	-	0.994	0.990	0.985	0.985
Belegungsgradprognose Erzherzogstraße	-	0.995	0.990	0.978	0.970

Tabelle 1: Bestimmtheitsmaß  $r^2$  zwischen Prognosewert und Referenzwert (Belegungsgrad)

$t_{\text{Prog}}$ [Minuten]	0	15	30	45	60
Belegungsgradprognose Exerzierplatz	-	0.26	0.38	0.51	0.66
Belegungsgradprognose Erzherzogstraße	-	0.21	0.30	0.48	0.61

Tabelle 2: Mittlerer quadratischer Fehler zwischen Prognosewert und Referenzwert (Belegungsgrad) Reisezeiten

$t_{\text{Prog}}$ [Minuten]	0	15	30	45	60
Reisezeitprognose Opernring (y: Taxi)	0.68	0.64	0.63	0.63	0.59
Reisezeitprognose Ingolstädter Straße (y: Fahrzeugwiedererkennung)	0.81	0.78	0.77	0.75	0.72

Tabelle 3: Bestimmtheitsmaß  $r^2$  zwischen Prognosewert und Vergleichswert (Reisezeit)

$t_{\text{Prog}}$ [Minuten]	0	15	30	45	60
Reisezeitprognose Opernring (y: Taxi)	4	5	5	5	6
Reisezeitprognose Ingolstädter Straße (y: Fahrzeugwiedererkennung)	11	13	15	16	19

Tabelle 4: Mittlere absolute Abweichung (tolerierter Abweichung: 60 Sekunden) zwischen Prognosewert und Vergleichswert (Reisezeit)

zeiten erlauben. Eine Möglichkeit zur Verwendung der Beobachtungen als Vergleichswerte ist das unbestrafte Zulassen von Abweichungen beim Vergleich mit der Prognose, wobei die tolerierten Abweichungen dabei den maximal erwarteten Abweichungen der Einzelmessungen vom eigentlichen Erwartungswert entsprechen. Der Fehler  $e_T$  mit tolerierter Abweichung  $\Delta y_T$  berechnet sich zu:

$$e_T(y_p, y'_p) = \max\{0, |y_p - y'_p| - \Delta y_T\}$$

Als Fehlermaß wird der mittlere absolute Fehler zur „mittleren absoluten Abweichung mit Toleranz“  $MAA_T$  erweitert. Toleriert wird dabei ein Unterschied, der einem zusätzlichen Halt an einer LSA auf der Route entspricht (Annahme: 60 Sekunden):

$$MAA_T = \frac{1}{n} \sum_{p=1}^n e_{T,p}$$

In den Tabellen 3 und 4 sind die Ergebnisse für die Reisezeitprognose dargestellt.

#### Vergleich mit anderen Verfahren

Das instanzbasierte Lernverfahren „IL“ wurde anhand des Bestimmtheitsmaßes mit den folgenden Verfahren verglichen:

– kalenderbasierte Prognose „Kalender“ (Modell: Erwartungswert entspricht dem

gemäß Wochentag und der Tageszeit typischen Durchschnittswert)

- Trivialprognose „Trivial“ (Modell: aktueller Messwert bleibt konstant, nur bei kontinuierlich erhobenen Messwerten möglich)
- künstliches Neuronales Netz „NN“ (Multi Layer Feed Forward MLF, mit den selben Eingangswerten wie das instanzbasierte Lernverfahren).

Für die Belegungsgradprognose liefert das instanzbasierte Lernverfahren bis zu einem Prognosehorizont von 45 Minuten bessere Ergebnisse als die kalenderbasierte Prognose und stets bessere Ergebnisse als die Trivialprognose. Im Vergleich mit dem MLF schneidet das instanzbasierte Lernverfahren am Detektor Exerzierplatz (Bild 8 links) etwas besser und am Detektor Erzherzogstraße (Bild 8 rechts) etwas schlechter ab.

Für die Reisezeit wird angenommen, dass für den aktuellen Zeitpunkt keine Messung vorliegt, so dass keine Trivialprognose möglich ist. Auch hier liefert das instanzbasierte Lernverfahren stets bessere Ergebnisse als die kalenderbasierte Prognose. Das MLF liefert im Testfall Graz bis zu einem Prognosehorizont von 15 Minuten bessere Ergebnisse (Bild 9 links), ansonsten sind die Ergebnisse des instanzbasierten Lernverfahrens etwas besser.




Bild 8: Belegungsgradprognose (Detektor Exerzierplatz links, Detektor Erzherzogstraße rechts)




Bild 9: Reisezeitprognose (Taxipositionsmeldungen auf dem Opernring links, Fahrzeugwiedererkennung auf der Ingolstädter Straße rechts)

#### 4 Fazit und Ausblick

##### Ergebnisse und Einordnung des Verfahrens

Es konnten in allen untersuchten Szenarien plausible Reisezeiten und Belegungsgrade prognostiziert werden. Situationen mit untypisch hohen Werten treten per Definition selten auf, so dass sie auch in den zur Mustererkennung und zum Training verwendeten Datenbasen im Vergleich zu anderen Situationen relativ selten sind. Somit kommt es vor, dass die niedrigen Reisezeiten die  $k$  Nächsten Nachbarn dominieren und somit der wahre Wert teilweise unterschätzt wird. Diese Problematik könnte durch eine entsprechende Datenvorverarbeitung (etwa

einer Segmentierung der Datenbasis) möglicherweise gelöst werden.

Bei der Reisezeitschätzung ist eine Schwierigkeit, dass der Zusammenhang zwischen lokalen unabhängigen Verkehrsvariablen und der Reisezeit im Bereich hoher Reisezeiten nicht eindeutig ist. Die (mögliche) Streubreite der Reisezeit ist deutlich höher als die der lokalen Verkehrskenngrößen, da diese bei – nur theoretisch erreichbaren – 100% (Belegungsgrad) bzw. bei der Kapazität (Verkehrsstärke) begrenzt sind. Die Reisezeit hingegen kann theoretisch unendlich groß werden und erreicht in der Praxis nicht selten das fünf- oder sechsfache der idealen Reisezeit. Diese Problematik betrifft naturgemäß alle Mustererkennungsansätze.



Bild 10: Verkehrsqualitätskarten für Graz

Es hat sich gezeigt, dass in der Regel weder die kalenderbasierte noch die Trivialprognose eine Alternative zu komplexeren Verfahren unter Berücksichtigung von Verkehrsmustern darstellen. Bezüglich der Wahl des Mustererkennungsverfahrens (instanzbasiert oder Künstliches Neuronales Netz) zur Prognose von Erwartungswerten können keine eindeutigen Empfehlungen gegeben werden. Letztendlich hängt die Wahl nicht zuletzt von der Präferenz des Nutzers ab.

##### Mögliche Anwendung im Verkehrsmanagement

Eine interessante Anwendung des Verfahrens stellt die flächendeckende Schätzung und Prognose von Reisezeiten auf Basis von Fahrzeugpositionsmeldungen dar. Dabei werden die Vorteile der Fahrzeugpositionsdaten (die Reisezeit kann abgeleitet werden, jede Kante/Route wird zumindest von Zeit zu Zeit überfahren) und lokalen Verkehrsdaten (liegen kontinuierlich vor) genutzt. Die geschätzten Reisezeiten können dann beispielsweise farbkodiert auf dem Netz dargestellt und dem Verkehrsteilnehmer oder einem Operator zur Verfügung gestellt werden. Im Bild 10 sind beispielhaft Verkehrslagekarten für zwei Zeitintervalle in Graz dargestellt.

##### Möglichkeiten zur weiteren Entwicklung

Neben Reisezeiten aus Taxipositionsmeldungen und Fahrzeugwiedererkennung existieren weitere interessante Datenquellen zur Beobachtung streckenbezogener Verkehrskenngrößen. Innerorts von großer praktischer Relevanz wäre aufgrund der Planbarkeit der Erfassung die Nutzung des straßengebundenen ÖPNV zur Reisezeiterhebung, wobei natürlich die systemspezifischen Reisezeitverluste berücksichtigt werden müssen. Steuerungsdaten, beispielsweise die LSA-Signalisierungszustände, könnten als beschreibende Variable die Schätzung weiter verbessern. Insbesondere könnten dann Verkehrsstärkemessungen zusammen mit den Grünzeitanteilen zur Beschreibung der Verkehrssituation eingeführt werden. Dem Verfahren liegen große Datenbestände zugrunde. Die inhärenten Verteilungen statistisch zu erfassen und zur Schätzung und Prognose von Verteilungen zu den Erwartungswerten wäre ein sinnvoller nächster Schritt. Die Ergebnisse könnten beispielsweise als Eingangswerte für die so genannte zuverlässige dynamische Navigation verwendet werden (siehe beispiels-



weise Kaparias et al. (2009)). Diese zeichnet sich im Gegensatz zur „normalen“ dynamischen Navigation durch die explizite Berücksichtigung der zu erwartenden Zuverlässigkeit einer Route aus.

#### Literaturverzeichnis

Bajwa, S.; Chung, E.; Kuwahara, M. (2003): Sensitivity Analysis of Short-Term Travel Time Prediction Model's Parameters.

Förster, G. (2008): Kurzfristprognose auf Basis von Raum-Zeit-Mustern. Forschungsgesellschaft für Straßen- und Verkehrswesen (Hrsg.), HEU-REKA '08, Optimierung in Verkehr und Transport – Tagungsband, FGSV Verlag, Köln, ISBN 978-3-939715-48-1.

Gerdes, I.; Klawonn, F.; Kruse, R. (2004): Evolutionäre Algorithmen, Vieweg Verlag. ISBN 3-528-05570-7.

Hagedorn, J.; Bissantz, N.; Mertens, P. (1997): Data Mining (Datenmustererkennung): Stand der Forschung und Entwicklung. Wirtschaftsinformatik 39 (1997), S. 601-612.

Jönsson, P.; Wohlin, C. (2004): An Evaluation of k-Nearest Neighbour Imputation Using Likert Data. Proceedings of the 10<sup>th</sup> International Symposium on Software Metrics (METRICS'04).

Kaparias, I.; Bell, M.G.H.; Belzner, H.; Leonhardt, A.; Bogenberger, K. (2009): Zuverlässige Dynamische Zielführung. Straßenverkehrstechnik 9/2009.

Leonhardt, A. (2008): Ein instanzbasiertes Lernverfahren zur Prognose von Verkehrskenngrößen unter Nutzung räumlich-zeitlicher Verkehrsmuster. Dissertation am Lehrstuhl für Verkehrstechnik, Technische Universität München, 2008.

Linauer, M.; Din, K.; Asamer, J.; Nowotny, B.; Norman, N.; Heininger, M.; Heininger, D.; Paukerl, A.; Turek, T.; Steiner, P. (2006): FUSION – Floating Car Daten und Sensordaten intelligent fusionieren. Endbericht im Rahmen von I2 – Intelligente Infrastruktur. bmvit.

Maier, F.; Braun, R.; Busch, F.; Mathias, P. (2008): Pattern-based short-term prediction of urban congestion propagation and automatic response. Traffic Engineering & Control, TEC Magazine 06/2008.

Moore, A. (2001): Instance-based learning (a.k.a. memory-based) (a.k.a. nonparametric re-

gression) (a.k.a. casebased) (a.k.a. kernel-based). Tutorium, School of Computer Science Carnegie Mellon University.

Robinson, S.; Polak, J.W. (2005): Modelling Urban Link Travel Time with Inductive Loop Detector data using the k-NN method, 84<sup>th</sup> Transportation Research Board Annual Meeting, Jan. 9 – 13, 2005, Washington, D.C. and publication in the Transportation Research Record.

Schäfer, R. (2005): Real-time Floating Car Data – A data source generating TMC messages. TMC Workshop, Beijing, 5. April 2005.

Wild, D. (1996): Die Prognose von Verkehrsstärken anhand klassifizierter Ganglinien; Dissertation an der Universität Karlsruhe, 1996; Shaker-Verlag, Aachen, ISBN 3-8265-1478-5

# Handbuch Straßenwinterdienst

Das Handbuch Straßenwinterdienst behandelt aus Sicht der Wissenschaft und der Praxis die Organisation und Durchführung des Winterdienstes auf Verkehrsflächen außerorts wie innerorts. Das in 15 Kapitel gegliederte Werk, inklusive Rechtsgrundlagen, ist mit vielen farbigen Abbildungen ausgestattet.

#### Inhalt

- **Grundlagen und Forschung**  
Physik und Chemie, Meteorologie, Ökologie, Messtechnik, Informationstechnik
- **Planung und Vorbereitung**  
Schnee und Eisglätte in Straßenplanung und -entwurf, Linienführung und Topografie, Lawinenschutz, Schneezäunplanung, eishemmende Straßenbeläge
- **Praxis und Material**  
Geräte und Maschinen, Geräteträger und Zubehör, Ausstattung, rechnergestützte Wettervorhersagen, Optimierung von Touren- und Routenplanung, Daten-Management, Datenerhebung vor Ort



**Handbuch Straßenwinterdienst**  
Prof. Dr.-Ing. Walter Durth  
Dr.-Ing. Horst Hanke  
Hardcover, 380 Seiten  
mit vielen Fotos und Grafiken  
Format 17 x 24 cm, 64,- Euro  
ISBN 3-7812-1616-7