



Opportunità offerte dai 'Big Data' per lo sviluppo di nuovi modelli e servizi di trasporto

'Big Data' opportunities for new transport models and services

Chiara COLOMBARONI^(*)

Gaetano FUSCO^(*)

Natalia ISAENKO^(*)

Sommario - La diffusione di dispositivi mobili di localizzazione e comunicazione produce con continuità un'immensa quantità di dati – i cosiddetti Big Data – che possono essere sfruttati per migliorare la conoscenza dello stato del sistema di trasporto e per mettere in atto opportune politiche di mobilità e appropriate azioni di regolazione. Peraltro, gli attuali sistemi di informazione presentano tuttora notevoli lacune e sono quindi suscettibili di significativi miglioramenti. La presente memoria esamina i principali problemi connessi all'uso dei Big Data e tratta dell'opportunità offerta da questi di realizzare modelli di mobilità individuale basati su un aggiornamento continuo dell'informazione. La prima parte, di carattere discorsivo, è completata da una sintetica rassegna delle ricerche eseguite dagli autori e finalizzate ad analizzare i Big Data sotto diversi aspetti: per ottenere una caratterizzazione quantitativa dei fenomeni di mobilità, per comprendere i comportamenti e le preferenze degli utenti, per migliorare i modelli di previsione e studiare nuovi servizi di mobilità.

1. Introduzione

L'attuale disponibilità di una quantità enorme di dati sulla mobilità individuale ha ispirato un gran numero di studi finalizzati alla previsione del traffico e offre inoltre nuove prospettive per l'offerta di servizi di mobilità personalizzati. In effetti, i dispositivi mobili dotati di sistemi di localizzazione forniscono una fonte d'informazione di tipo diffuso, con cui è possibile monitorare gli utenti nel corso delle loro attività e controllare tutti gli elementi della rete attraverso un campionamento periodico di veicoli tracciabili, o veicoli sonda. A differenza delle tecnologie tradizionali di monitoraggio del traffico, i veicoli sonda forniscono stime campionarie delle velocità e dei tem-

Summary - The vast diffusion of mobile location and communication devices continuously produce a huge amount of data ('Big Data') that can be exploited to improve the knowledge about the state of the transport system and perform appropriate regulatory actions and execute suitable policy actions. However, current information systems still have noteworthy drawbacks and are in the meantime open to significant improvements. The paper discusses the main problems related to the use of the Big Data and examines the opportunities offered by Big Data to introduce new transport models based on continuous updating of microscopic models. The first part of the paper, of conversational nature, is complemented by a concise overview of the research conducted by the authors with multiple objectives: derive a quantitative characterization of the mobility phenomena, understand users' behaviour and preferences, develop enhanced prediction models, and study new mobility services.

1. Introduction

The huge increase of individual mobile data is producing an overwhelming profusion of experimental studies and is offering prospects for new personalized mobility services. In fact, personal mobile devices embedding locating technology provide an additional source of ubiquitous information, which make possible both to track users during their activities and to monitor different elements on the network by periodic sampling of probe vehicles. Unlike traditional traffic monitoring technologies, probe vehicles supply sample estimates of both segment speeds and individual travel times. Such novel sources of information provide additional opportunities for development of new transport models based on continuous updating of individual driver's behaviour; that is, on differ-

^(*) Università degli Studi di Roma La Sapienza, Dipartimento di Ingegneria Civile, Edile e Ambientale.

^(*) La Sapienza University of Rome, Department of Civil, Construction and Environmental Engineering.

pi di percorrenza individuali. Queste nuove fonti di informazione offrono quindi l'opportunità di sviluppare modelli di trasporto basati su un aggiornamento continuo del comportamento dei singoli utenti, quindi su presupposti diversi da quelli utilizzati nella concezione e per l'applicazione dei modelli sviluppati fino a solo qualche decade fa.

D'altra parte, emergono anche nuovi problemi riguardanti le esigenze di trattare, immagazzinare ed elaborare tali enormi quantità di dati: i 'Big Data', arrivati a costituire una vera e propria nuova materia di studio [1], cui sono dedicate specifiche riviste scientifiche quali *Big Data*, *Journal of Big Data*, *Big Data Research*. Peraltro, scienziati e tecnici stanno tuttora affrontando il problema di individuare le forme più appropriate per sfruttare queste informazioni e migliorare le prestazioni del sistema di trasporto mediante l'applicazione di nuovi metodi di controllo distribuito e lo sviluppo di sistemi di informazione e servizi innovativi per la mobilità, concepita come servizio e svincolata dal possesso del veicolo. Non esiste neppure una definizione univoca e condivisa di Big Data. La prima e tuttora più diffusa è basata sul concetto espresso dal modello '3V'; vale a dire dati contraddistinti da un grande 'Volume', che richiedono elevata 'Velocità' di trattamento e caratterizzati da notevole 'Varietà' tipologica di dati [2]. Più recentemente, è stata proposta una definizione che intende caratterizzare i Big Data mediante una metrica nello spazio '3C' al fine di consentirne una specificazione quantitativa con metodi statistici: i Big Data sono così definiti da elevata 'Cardinalità' (numero di record nella base di dati), 'Continuità' di raccolta (dimensione continuamente crescente) ed elevata 'Complessità' (ampia varietà tipologica, alta dimensione del dataset, alta velocità di elaborazione) [3]. Una definizione più generale, che riteniamo preferibile perché più strettamente legata al significato originario dei termini, indica con Big Data un termine che descrive l'archiviazione e l'analisi di un grande o complesso insieme di dati che richiede l'uso di tecniche di analisi non tradizionali (quali: NoSQL, MapReduce e machine learning) [4]. L'ambito delle applicazioni dei Big Data nei trasporti è vasto e variegato. Queste possono riguardare lo stato del veicolo, le prestazioni del sistema di trasporto e la distribuzione delle posizioni degli utenti in un dato istante, nonché le loro preferenze. In tal modo, i Big Data sono una fonte estremamente preziosa di dati di input per potenziare le applicazioni delle tecnologie dell'informazione e delle comunicazioni (Information and Communication Technology, in breve ICT) ai sistemi di trasporto e realizzare sistemi di trasporto effettivamente 'intelligenti'. La presente memoria intende fornire un inquadramento delle opportunità fornite dai Big Data per lo sviluppo di nuovi modelli di trasporto e delle relative problematiche. Il successivo paragrafo illustra in forma discorsiva le opportunità offerte dai Big Data per sviluppare nuovi paradigmi dei modelli di trasporto, secondo un approccio centrato sull'osservazione dei dati individuali, rilevati direttamente durante gli spostamenti e aggiornati con continuità. Nel para-

ent premises from those of the models developed even since one decade ago. However, new problems arise about the needs for handling, storing and processing such huge amount of data: 'Big Data' became a new science discipline [1] and are the main object of scientific journals (*Big Data*, *Journal of Big Data*, *Big Data Research*). Furthermore, scholars and practitioners are still facing the problem to understand appropriate ways to exploit such information in order to improve transport system performances, apply new control methods, and support users with advanced information and new mobility services, that conceive the mobility as a service, uncoupled from a vehicle ownership. A unique and agreed definition of Big Data note even exists. The earliest and up to now the prevailing definition is based on the so-called '3V' paradigm; that is data characterized by large 'Volume', which require high treatment 'Velocity' and featured by a wide type 'Variety' of data [2]. More recently, a definition that characterizes Big Data through a metric in '3C' space metric has been introduced to enable a quantitative specification with statistical methods: Big Data so defined have high 'Cardinality' (number of records in the database), 'Continuity' of collection (continuously increasing size), and high 'Complexity' (wide typological variety, high dataset size, high processing speed) [3]. A more general definition, which is preferable because more strictly related to the original meaning of the words, denotes as Big Data a term that describes the storage and analysis of a big or complex set of data that require using non-traditional techniques of analysis (e.g.: NoSQL, MapReduce e machine learning) [4].

The extent of Big Data applications in transport is vast and multifaceted. They concern the vehicle state, the transport system performances, and the distribution of users' positions and preferences at a given time instant. In such a way, Big Data are a powerful source of input to enhance Information and Communication Technology (ICT) applications to transport systems and then realize actual 'Intelligent' Transportation Systems.

The paper aims at providing a general overview of issues and prospects provided by the exploitation of individual Big Data for new transport models, applications and services. The next section illustrates in a discursive form the opportunities provided by Big Data to develop new paradigms of transport models that follow an approach based on individual data, directly detected during users' journeys and updated with continuity. In the third Section, the discussion is complemented by the presentation of several experimental analyses, conducted by the authors and provided as examples, concerning the characterization of mobility phenomena, the study of choice behaviour, the development of short-term prediction models. Finally, some future applications of information systems and innovative mobility services, enabled by mobility Big Data and active users' crowdsourcing, are described.

grafo successivo la discussione è integrata dalla presentazione di alcune analisi sperimentali compiute dagli autori e fornite a titolo esemplificativo, riguardanti la caratterizzazione della mobilità, i comportamenti di scelta degli utenti, lo sviluppo di modelli di previsione di breve termine. Infine, vengono descritte alcune future applicazioni di sistemi di informazione e servizi di mobilità innovativi, resi possibili dalla partecipazione attiva degli utenti alla creazione e all'uso dei Big Data in mobilità, utilizzando i metodi del cosiddetto 'crowdsourcing'.

2. Nuovi paradigmi dei modelli di trasporto

Il monitoraggio continuo dello stato del veicolo, degli spostamenti degli utenti e delle prestazioni della infrastruttura fornisce straordinarie opportunità per sviluppare paradigmi teorici completamente nuovi che applicano modelli di previsione, strategie di controllo proattive e servizi di mobilità personalizzati in grado di innovare profondamente il sistema di trasporto attuale.

Gli utenti contribuiscono ai Sistemi di Trasporto Intelligenti ('Intelligent Transport Systems', ITS) fornendo i dati posizionali utili per descrivere i loro spostamenti e stimare le condizioni di traffico attuali; questo contributo avviene sia in forma passiva, quando gli utenti acconsentono ad essere tracciati dai dispositivi di localizzazione, sia in forma attiva, attraverso reti sociali specializzate nelle informazioni sulla mobilità basate sulle dirette esperienze che gli utenti condividono in tempo reale tra di loro durante i propri spostamenti.

I dati individuali forniscono un numero di osservazioni sull'attuale meccanismo di scelta di percorso degli utenti; queste possono essere utilizzate per calibrare e validare i numerosi modelli comportamentali che sono stati costruiti negli ultimi anni. In particolare, i percorsi effettivamente effettuati dagli utenti della rete stradale non sono mai stati direttamente osservati su larga scala, ma sono stati raccolti solo su piccole flotte di veicoli, come i taxi [5], o su piccoli campioni di utenti consapevolmente coinvolti in esperimenti ([6], [7], [8]). Così, i modelli di scelta del percorso sono stati finora calibrati su piccoli campioni di dati, in genere validati su misure aggregate, come flussi d'arco, invece che sulle frequenze di scelta dei percorsi effettivamente scelti dagli utenti. I dati rilevati da veicoli sonda ('Floating Car Data', FCD) possono essere utilizzati nelle diverse fasi di calibrazione dei modelli di scelta di percorso: la identificazione di opportuni insiemi di scelta di percorso, la specificazione della struttura matematica, la stima dei coefficienti del modello di scelta. La possibilità di raccogliere in maniera continua informazioni sul comportamento individuale e lo straordinario potenziamento delle capacità di memorizzazione ed elaborazione consentite dal calcolo parallelo e distribuito aprono nuove prospettive per la realizzazione di un approccio microscopico alla modellazione delle reti. In questo contesto, appare appropriata l'applicazione delle tecniche di intelligenza artificiale per sviluppare modelli

2. New Paradigms of Transport Models

Continuous monitoring of vehicles' states, travellers' journeys, and road performances provides extraordinary opportunities to develop completely new theoretical paradigms that apply predicting models, proactive control strategies, and just-in-time personalized mobility services and finally can revolutionize the current transport system.

Users provide the system with data useful to describe their trips and current traffic states both passively, by allowing their navigation device being tracked, and actively, by crowdsourcing social networks specialized in traffic and mobility information based on travellers' experiences shared in real-time by the users during their trip.

Individual data provide unprecedented observations on the actual route choice mechanisms of the users, which can be used to calibrate and validate the numerous behavioural models that were built in the last years. Specifically, the actual routes followed by the road users were never directly observed before at a large scale on the road network but were collected only for small fleets of vehicles, such as taxis [5] or small samples of drivers involved in experiments [6]; [7]; [8]. Then, route choice models are so far often calibrated on small samples of data and have been usually validated on aggregated measures such as link flows instead of on the actual route choice frequencies. Floating Car Data (FCD) can be exploited in the several different phases of calibration of multilevel path-based random utility models: identifying suitable path choice sets, specifying a mathematical structure that captures the correlation among different paths, and determine the most likely values of the coefficients of the choice model.

Continuous information about individual behaviour and improved processing capabilities available by parallel and distributed computations open new perspectives for a microscopic approach to network modelling. Artificial intelligence can be applied to develop self-training models that learn from high-resolution trajectory data of vehicles detected continuously and reproduce car following drivers' behaviour by using position and speed data continuously detected with high resolution [9]. Individual behavioural models can be applied to simulate the road network and updated in real time by using online floating car data. In such a way, it is possible to get information about users' needs, predict drivers' behaviour, and adapt control actions to expected vehicle positions and traffic performances.

To reduce the problems related to their cumbersomeness, individual data are usually aggregated: speed is defined for link segments over given time interval; data on individual mobility such as the number of trips and travel times are aggregated by origin and destination zones and referred to given time intervals [10]. If larger space and time intervals reduce the process effort and ease the interpretation of data, they also reduce the granularity of the

che auto-apprendono a riprodurre il comportamento dei conducenti nella guida utilizzando dati di posizione e velocità rilevati con continuità ed elevata risoluzione [9].

Per ridurre i problemi di trattabilità conseguenti alla dimensione dei dati, è pratica abituale procedere all'aggregazione dei dati individuali: la velocità è così definita per segmenti d'arco; i dati di mobilità individuale, quali il numero di viaggi e i tempi di spostamento sono aggregati per zone di origine e destinazione [10]. Ovviamente, tutte le grandezze sono aggregate su definiti intervalli temporali. Se aumentare la dimensione degli intervalli spaziali e temporali riduce lo sforzo di elaborazione e facilita l'interpretazione dei dati, al tempo stesso riduce la granularità della informazione. D'altra parte, un'elevata precisione richiede altrettanto elevate risorse informatiche, in termini di capacità di memorizzazione e di elaborazione. Oltre a richiedere elevate risorse informatiche, un'elevata granularità spaziale e temporale dei dati implica ridotti intervalli di rilevazione delle misure; ciò comporta un minor numero di osservazioni per ciascuna variabile e quindi una minore significatività statistica della misura. Ne discende che, necessariamente, i due requisiti per garantire un'elevata qualità dei dati sono conflittuali tra loro: per accrescere la significatività delle misure, occorre accrescere l'ampiezza degli intervalli di tempo o dei segmenti spaziali, o di entrambi, e quindi ridurne l'accuratezza. Negli ultimi anni sono stati prodotti numerosi studi per determinare la frazione di veicoli tracciati necessaria per ottenere il livello di confidenza desiderato del valore medio della variabile [11]. Per valutare l'affidabilità della misura è necessario abbinare al valore medio della variabile la sua deviazione standard. In tal modo, è possibile realizzare previsioni di traffico per intervalli piuttosto che stime puntuali ed è possibile così stimarne l'accuratezza [12].

L'esistenza di mappe digitali di estremo dettaglio, sviluppate per i navigatori ed ora utilizzate per la pianificazione, e di quelle ancor più dettagliate concepite per la guida autonoma, pone la questione di quale sia il più appropriato livello di aggregazione delle variabili di traffico. E' logico definire gli intervalli spaziali e temporali in base al livello di confidenza desiderato per le variabili da stimare; poiché questo dipende dalla componente casuale delle singole misure, la questione metodologica fondamentale consiste nel determinare il miglior compromesso tra accuratezza ed efficacia dell'informazione.

La profusione di dati di mobilità, se da una parte fornisce grandi opportunità per acquisire una più ampia comprensione dei fenomeni di traffico, implica necessariamente anche la difficoltà di certificare l'affidabilità e di garantirne la riservatezza.

I modelli comportamentali individuali possono essere inseriti in modelli di simulazione online, aggiornati in tempo reale mediante i dati provenienti dai veicoli tracciati on-line e dagli utenti che cooperano volontariamente al sistema di 'crowdsourcing'. In tal modo, è possibile ottenere informazioni aggiornate sulle esigenze degli

information. High precision needs high storage and processing performances.

However, computer costs are not the only drawback connected to a high space and time granularity of data. Small space and time intervals, in fact, imply smaller observation intervals and mean fewer observations for each variable and then lower statistical significance of the measure. It follows that, necessarily, the two requirements for high quality of data are conflicting: to increase the significance of the measures, the length of either space segments or time intervals, or both, has to be increased. Several studies have been produced in the last years to determine the fraction of tracked vehicles to have the desired confidence on the average value of the variable [11]. To assess the reliability of the measure it is necessary to complement the average value of the variable with the standard deviation [12]. In such a way, traffic predictions can be carried out through interval estimates instead of point estimates and complemented by accuracy estimates.

The existence of very detailed digital maps, developed for car navigators and now used also for planning, and of those even more detailed conceived for autonomous driving highlights the question on the proper level of aggregation for traffic variables. It is logical to define the time and space intervals according to the desired level of confidence for the variables to estimate, which depends on the random components that affect the individual measures. Thus, the fundamental methodological question is to find the best trade-off between accuracy and efficiency of the information.

The abundance of mobility data, while providing great opportunities to get an enhanced comprehension of traffic phenomena, necessarily implies also the difficulty to certify their reliability and ensure the privacy of the information collected.

We envision mobility management systems based on online simulation models that embed individual behavioural models, updated in real-time through data collected from floating cars and people voluntarily cooperating to crowdsourcing. In such a way, it is possible to get updated information on travellers' needs, predict drivers' behaviour, and adapt control actions to vehicle positions (at local, microscopic level) and to the predicted network performances (at global, macroscopic level).

The next section introduces some results achieved in several applications that exploit an available set of big data on urban mobility to face the following issues:

- characterize variability of mobility phenomena (day-to-day and inter-vehicular);
- understand users' behaviour and preferences;
- modelling mobility exploiting updated individual data;
- predict future states of the system to apply control measures and information strategies.

utenti del sistema, prevedere il comportamento dei conducenti e adattare le azioni di controllo alle posizioni veicolari (a livello locale, o microscopico) e alle prestazioni previste della rete di trasporto (a livello di sistema, o macroscopico).

Nel capitolo seguente sono presentati alcuni risultati ottenuti in diverse applicazioni che utilizzano una base di dati individuali di veicoli sonda per affrontare i seguenti aspetti:

- caratterizzare la variabilità dei fenomeni di mobilità (giornaliera e inter-veicolare);
- comprendere il comportamento e le preferenze degli utenti;
- modellizzare la mobilità sfruttando dati individuali aggiornati;
- prevedere gli stati futuri del sistema per applicare misure di controllo e strategie di informazione.

3. Analisi sperimentale

3.1. Descrizione della base di dati

La base di dati utilizzata per presentare le analisi sperimentali è stata fornita da una società di servizi telematici per il mercato assicurativo e automobilistico, nell'ambito di un progetto di ricerca congiunto. Essa è costituita da circa 100 milioni di posizioni individuali e velocità puntuali, rilevate per un mese nella città di Roma mediante il tracciamento di circa 100.000 veicoli privati, equipaggiati con dispositivi di localizzazione GPS, di memorizzazione dei dati e di trasmissione delle informazioni via GSM/GPRS, forniti agli abbonati ai servizi di tracciamento a fini assicurativi. Il campione dei veicoli tracciati rappresenta circa il 2,5% dell'intera flotta veicolare della città di Roma. Ciascun record di dati contiene l'orario, le coordinate del veicolo, la velocità istantanea, la direzione di marcia, la distanza percorsa dalla rilevazione precedente, lo stato del motore (acceso, in moto, spento) e la qualità del segnale GPS. Secondo le impostazioni della società fornitrice, i dati sono rilevati in modo continuo, ma sono memorizzati ogni 2 km. Per garantire la riservatezza degli utenti, la base di dati fornita per la ricerca è stata anonimizzata: ogni record contiene un codice identificativo del veicolo che consente di ricostruire i percorsi di ciascun utente e di studiarne il comportamento da un giorno all'altro, ma non di risalire alla sua identità. Per questo motivo, non è possibile qualificare la rappresentatività tipologica degli utenti rispetto alla popolazione di riferimento.

Preliminarmente all'uso della base di dati ai fini dell'analisi ne è stata effettuata una ripulitura, eliminando i dati con bassa qualità del segnale GPS (determinata in base al numero di satelliti di cui vengono ricevuti i segnali), quelli incongruenti con la sequenza dei codici di stato del motore e quelli con distanze percorse troppo brevi o nulle.

3. Examples of Applications

3.1. Data set description

The dataset used for the examples of an application was provided by an information technology that supplies services to insurance companies within a joint research program. It is composed by about 100 million single positions and speed points, detected by tracking about 100,000 private vehicles equipped with devices for positioning via GPS as well as storing and telecommunication via GSM/GPRS, supplied to the subscribers to tracking services for insurance purposes. The sample of vehicles tracked corresponds to about the 2.5% of the whole vehicular fleet of the town of Rome. Each record of data contains the timestamp, the coordinates of the vehicle, its instantaneous speed, the distance travelled from the previous detection and the engine state (switched on, moving, turned off) together with the quality of the GPS signal. According to the manufacturer settings, data are detected continuously but are saved every 2 km. To ensure users' privacy the dataset has been anonymized: each record contains a vehicle identification code that enables reconstructing the path followed by each user and studying his day-to-day behaviour but does not allow to identify the driver. This also prevents to match the users' typology with respect to the reference population.

Before using the dataset, a data cleaning operation was performed to eliminate data having poor GPS signal quality (determined by the number of visible satellites), inconsistent data with the sequence of engine codes, and those with too short travelled distances. A map matching algorithm was applied that assigns position data to the most likely element of the graph. After a specific sensitivity analysis, about 100,000 data, corresponding to about 1% of the total, has been discarded whose positions were 80 m farther from the nearest road link.

3.2. Characterize Mobility Phenomena

In order to improve the knowledge of the road traffic system, we want to characterize it by studying its variability in time and space, and to assess the approximation introduced by aggregating individual data to derive link variables. In the following, among the numerous analyses conducted on Floating Car Data, a selection concerning vehicular speed is reported. It focuses on the day-to-day variability, the inter-vehicle speed variance, and the time-space extent of congestion on the network.

3.2.1. Day-to-Day variability

Characterising the periodicity of road congestion is necessary to assess the accuracy of predictions based on statistical estimates based on the typical day.

Day-to-day variability on the whole road network is exemplified in figure 1. For every day of the week the average

È stato quindi eseguito un algoritmo di 'map matching' che ha associato i dati posizionali al più probabile elemento del grafo. A conclusione di una specifica analisi di sensibilità, sono stati scartati i record (circa 100.000, corrispondenti a circa l'1% del totale), la cui posizione GPS risultava distante oltre 80m dall'arco stradale più vicino.

3.2. Caratterizzazione dei fenomeni di mobilità

La disponibilità di una grande base di dati sulla mobilità consente di definirne le caratteristiche in termini di variabilità spaziale e temporale e di stimare l'approssimazione introdotta aggregando i dati individuali per derivare le variabili d'arco. Nel seguito, viene presentata una selezione delle numerose analisi condotte, in particolare sulle velocità veicolari, esaminando la variabilità tra un giorno e l'altro, la varianza tra un veicolo e l'altro, l'estensione spazio-temporale della congestione sulla rete stradale.

3.2.1. Variabilità giornaliera

Conoscere la periodicità della congestione sulla rete stradale è utile per comprendere l'accuratezza delle previsioni basate sulla conoscenza statistica del giorno medio.

La figura 1 illustra la variabilità giornaliera sull'intera rete nei diversi giorni della settimana: per ogni giorno della settimana è riportato l'andamento medio delle velocità osservate aggregate con intervalli temporali di 15 minuti. Com'è da attendersi, l'andamento delle velocità nei giorni di sabato e domenica differisce significativamente da quello dei giorni feriali, mentre questi ultimi hanno un andamento molto simile tra loro. E' utile quantificare queste differenze. La deviazione standard della velocità nei giorni feriali, calcolata rispetto alla media nello stesso intervallo temporale di 15 minuti, varia da 1,7 km/h il giovedì a 2,5 km/h il lunedì. Il coefficiente di variazione è compreso tra 3,5% e 5%, così che il *giorno tipo* – definito come giorno avente un profilo di velocità corrispondente ai valori medi dei giorni feriali, da lunedì a venerdì – può essere considerato rappresentativo di ciascun singolo giorno feriale con un'approssimazione di pochi punti percentuali. Più elevata è la deviazione standard delle differenze tra le velocità rilevate il sabato e i corrispondenti valori medi dei giorni feriali, pari a 6,3 km/h, mentre la deviazione standard rispetto al profilo del giorno medio dell'intera settimana è 4,3 km/h; infine, la deviazione standard delle differenze di velocità tra la domenica e i giorni feriali è 9,1 km/h, ed è 7,0 km/h rispetto al *giorno medio*, definito come media della intera settimana.

3.2.2. Varianza inter-veicolare

L'acquisizione di dati individuali consente di valutare non solo il valore medio della velocità sui diversi elementi della rete, ma anche la varianza delle velocità veicolari. Avendo a disposizione il numero di osservazioni individuali n insieme alla loro deviazione standard σ è possibi-

trend of aggregate speeds is reported with 15-minute time intervals. As expected, Saturday and Sunday patterns differ from those of the workdays significantly, while workdays exhibit very similar trends. In fact, the standard deviation of the average speed on the work days with respect to their average on the same 15-minute time interval ranges from 1.7 km/h (Thursday) to 2.5 km/h (Monday), corresponding to a coefficient of variation from about 3.5% and 5%. The typical day, defined as the day that has a speed profile corresponding to the values of the average values of workdays from Monday to Friday, can be considered a fair representative of the single work days. However, the standard deviation of the speed detected on Saturday and the corresponding values collected during the working days is 6.3 km/h, while the standard deviation with respect to the average day of the whole week is 4.3 km/h. The standard deviation of the speed differences of Sunday values with respect to the workdays and the average day, defined as the average day of the whole week, are 9.1 km/h and 7.0 km/h, respectively.

3.2.2. Inter-vehicle speed variance

Individual position and speed data enable to assess not only the average value of speed on different links of the road network, but also the variance of vehicle speeds. As the number of individual observations n and the standard deviation σ , it is possible to take into account the approximation introduced by using the average link speed and compute the corresponding confidence interval $1-\alpha$ as $z_{\alpha/2} \sigma / \sqrt{n}$, where $z_{\alpha/2}$ is the $1-\alpha/2$ quantile of the normal distribution.

Fig. 2 exemplifies inter-vehicle variance that affects the degree of belief of the average value of individual speed detected as the estimator of the average of the population on two different links, with low and high variance, respectively. It is evident that the confidence interval with 0.90 confidence level reduces as the flow increases. On high-volume

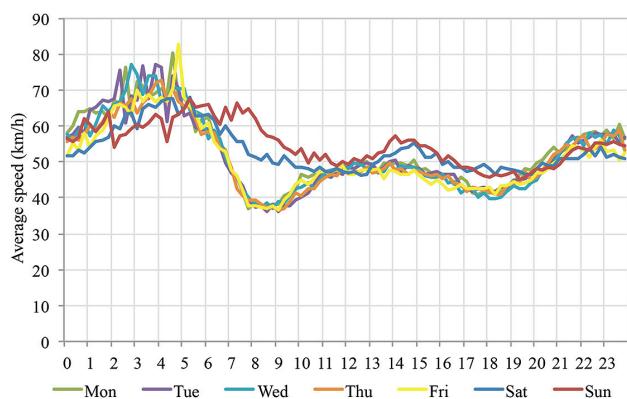


Fig. 1 - Andamento temporale della velocità media sull'intera rete metropolitana di Roma in differenti giorni della settimana.

Fig. 1 - Time variation of the average speed on the whole road network of Rome in different days.

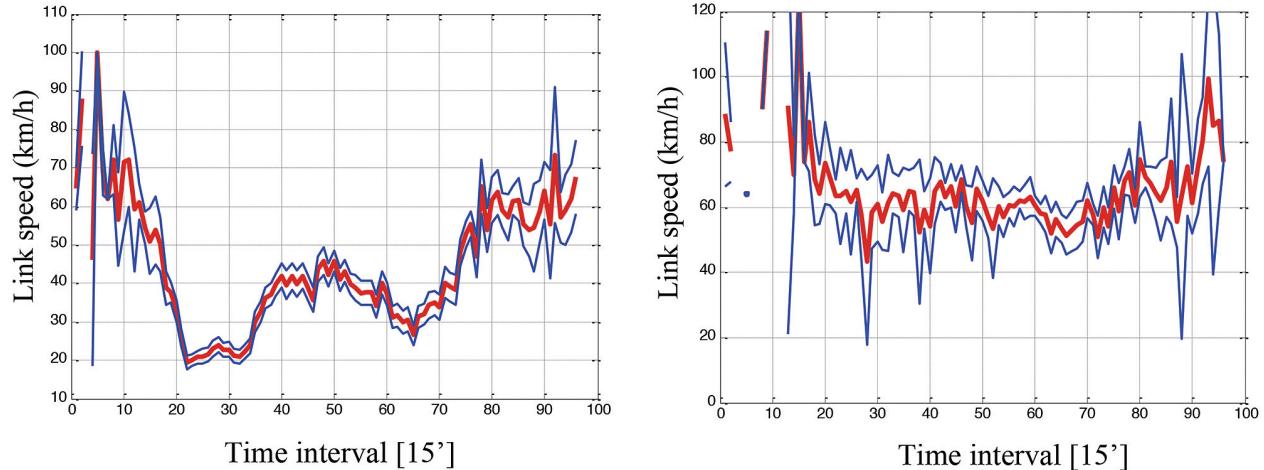


Fig. 2 - Andamento giornaliero della velocità media stimata (curva rossa) mediante dati da veicoli sonda e relativi intervalli di confidenza (curve azzurre) su due tipici archi urbani, appartenenti l'uno alla rete principale (a sinistra) e l'altro alla viabilità locale (a destra).

Fig. 2 - Examples of the average speed estimation (red line) from point floating car data and the related confidence intervals (blue lines) on two typical urban links, belonging to a main road (on the left) and a minor road (on the right).

le così considerare l'approssimazione che si compie utilizzando la velocità media sull'arco, mediante l'intervallo di confidenza del valore medio calcolato con il livello di confidenza $1-\alpha$ come $z_{\alpha/2} \sigma / \sqrt{n}$, dove $z_{\alpha/2}$ è il quantile della normale di ordine $1-\alpha/2$.

La figura 2 fornisce un esempio visivo dell'andamento della velocità media e del relativo intervallo di confidenza con il livello di confidenza pari a 0.90 su due differenti archi, appartenenti uno alla viabilità principale, l'altro alla viabilità locale. È evidente che l'intervallo di confidenza si riduce al crescere del flusso. Su archi caratterizzati da flussi elevati, l'intervallo di confidenza si restringe nelle ore di punta e si allarga nei periodi di morbida⁽¹⁾. Per quanto riguarda l'intera rete stradale e l'intero periodo di osservazione, la velocità media veicolare su tutti gli archi⁽²⁾ è 55,3 km/h, mentre la deviazione standard media della velocità veicolare è 13,2 km/h. Ne consegue che il coefficiente di variazione medio di tutti gli archi della rete è 0,23.

3.2.3. Estensione della congestione

I dati puntuali di velocità raccolti mediante veicoli sonda forniscono un continuo aggiornamento dell'immagine della congestione sulla rete e, nell'insieme, una valu-

road links, like that shown in the chart on the left, the confidence interval narrows in rush hours and widens in off-peak periods⁽¹⁾. As far as the whole road network, the average vehicle speed on all links⁽²⁾ is 55.3 km/h, while the average standard deviation of vehicle speed is 13.2 km/h. It follows that the average coefficient of variation for all links of the network is 0.23.

3.2.3. Extent of congestion

Individual point speed data collected by floating cars continuously update the picture of congestion on the network and enable to assess the extent of congestion both in time and in space. Figure 3 shows the flows and speeds collected by FCD in two time intervals on the principal road network in Rome: line widths reproduces the flows, estimated by inferring the number of vehicles sampled; colours represent the average link speed. The extent of congestion in each time interval can be easily appreciated by looking at the pattern of nuances of red on the road network.

Such information was used to assess the congestion conditions of the main road arteries in the town of Rome. Thus, figure 4 shows the time-dependent values of the average and the minimum speed along each artery, as a whole;

⁽¹⁾ Il restringimento dell'intervallo di confidenza nelle ore di punta dipende da due effetti correlati tra loro: il maggior numero di osservazioni e la maggiore congestione che riduce la libertà dei conducenti di viaggiare alla velocità di crociera desiderata, che è tipicamente una preferenza personale del conducente.

⁽²⁾ È da considerare che l'analisi copre l'intera area metropolitana, inclusi i principali tronchi autostradali.

⁽¹⁾ Narrowing of confidence interval in the rush hours depends on two correlated effects: the increase of the number of observations and the increase of congestion that reduces the drivers' freedom to travel at their desired cruising speed, which is typically a personal preference of the driver.

⁽²⁾ It is worth noticing that the area of analysis covers the whole metropolitan area, and includes branches of expressways.

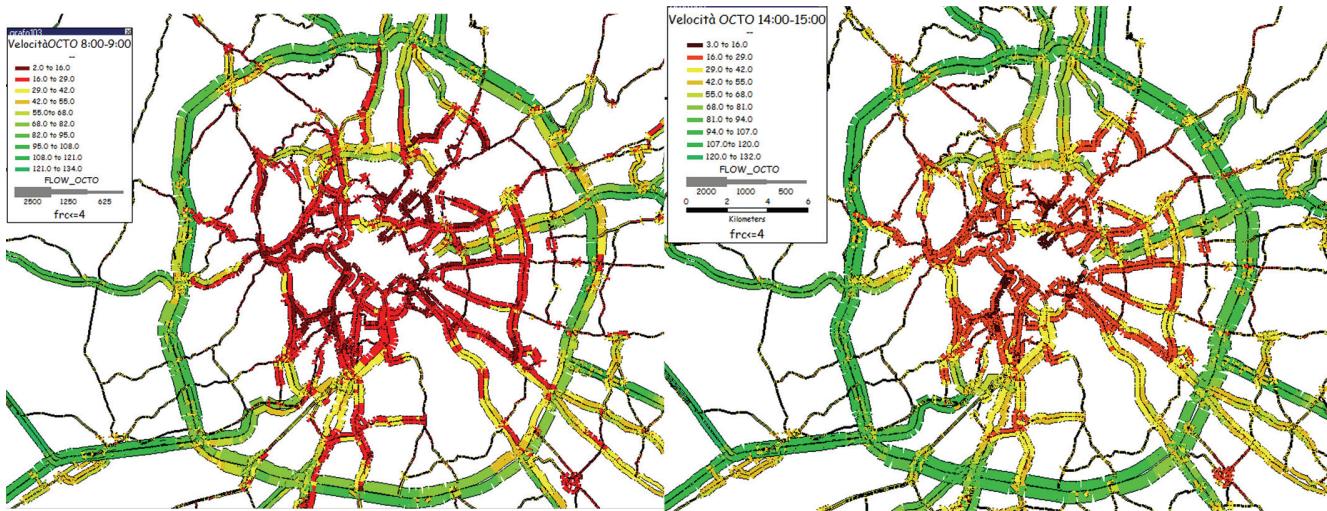


Fig. 3 - Velocità medie rilevate da veicoli sonda sulla rete principale di Roma nell'ora di punta del mattino (8:00-9:00, a sinistra) e in un'ora di morbida del pomeriggio (14:00-15:00, a destra).

Fig. 3 - Average speeds estimated from FCD on the main road network of Rome in the morning peak hour (8:00-9:00, on the left) and in the afternoon off-peak period (14:00-15:00, on the right).

tazione della sua estensione spaziale e temporale. Un esempio è mostrato nella figura 3, che illustra i valori medi dei flussi e delle velocità rilevati nel mese di osservazioni in due diverse fasce orarie sulla rete principale della città di Roma. Secondo la usuale convenzione, lo spessore del flussogramma rappresenta il flusso veicolare, stimato mediante inferenza rispetto al campione rilevato, mentre il colore rappresenta il valore della velocità. L'estensione della congestione in ciascun intervallo di tempo può essere agevolmente stimata osservando le sfumature di rosso sui diversi archi della rete stradale.

I risultati di queste analisi sono stati usati per classificare le principali arterie stradali della città di Roma in funzione del livello complessivo di congestione e identificare le misure più appropriate per la fluidificazione del traffico.

I due grafici in figura 4 riportano le velocità media e minima rilevate sui vari segmenti che compongono alcune delle principali arterie nel corso della giornata, scelte a titolo esemplificativo. La velocità media sull'intera arteria è indicativa del livello di servizio complessivo dell'arteria, e consente di valutare l'estensione temporale e l'intensità della congestione, definita come riduzione rispetto alla velocità libera; la velocità minima evidenzia la presenza e la persistenza di strozzature, elementi critici che maggiormente necessitano di interventi puntuali.

3.3. Comprendere le preferenze e i comportamenti degli utenti

I dati posizionali rilevati nel corso degli spostamenti compiuti dagli utenti forniscono una straordinaria fonte d'informazione per comprendere i comportamenti di mobi-

in such a way, it is possible to evaluate the average performances of each artery and the presence of bottleneck and the time extent of speed reduction. These results were used to rank main road arteries depending on their severity of congestion and identify the most appropriate measure to improve traffic conditions.

3.3. Understand users' behaviour and preferences

Position points detected during the trips provide a great source of information useful to understand travellers' behaviours through the direct observation of their choices on departure time, destination, routes.

Based on the available dataset, an experimental analysis on travellers' behaviour in departure time and route choice has been performed by selecting (among the about 1,300 zones defined by the Municipality of Rome for transport planning) a set of O-D pairs containing at least 30 trips done during the morning peak period (7:00-10:00 am), having a length of at least 6 km, and a travel time of at least 20 minutes, as well. In this way, a suitable sample of about 600 drivers, performing 1,450 trips between 28 Origin-Destination pairs has been obtained.

GPS positions detected every 2 km have been assigned to the road network graph by applying a map matching procedure that minimizes the distances of the detected point position from the nearer links and the differences of the detected speed direction and nearer link directions. The analysis consists of two main procedures: a procedure that applies a k-shortest path algorithm [13] from consecutive collected positions to reconstruct the route followed by each user and select the path whose length is closest to the actual distance travelled measured by the GPS device.

Using the whole set of the reconstructed routes to build

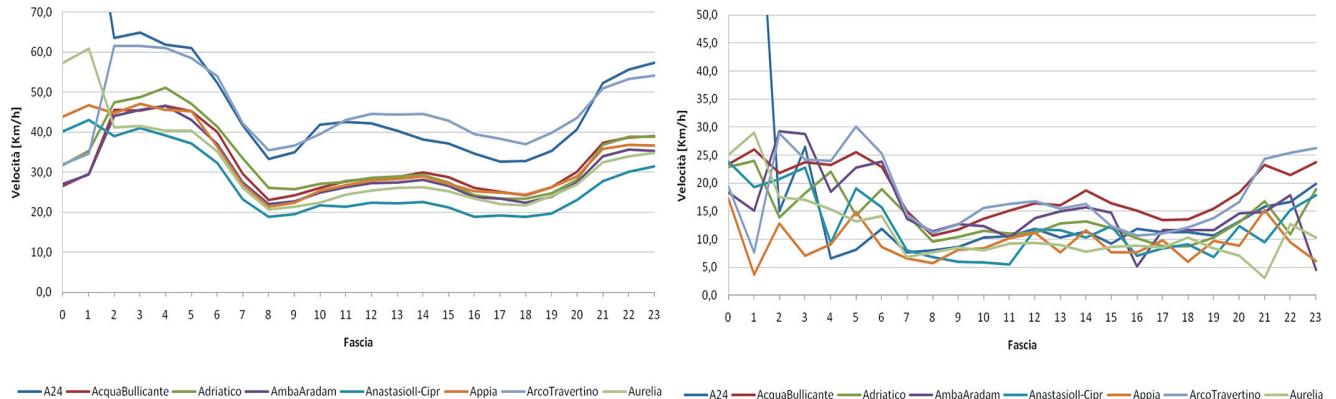


Fig. 4 - Andamento temporale della velocità media (a sinistra) e della velocità minima (a destra) rilevate con veicoli sonda su alcune arterie principali della città di Roma.

Fig. 4 - Time-dependent average speed (on the left) and the minimum speed (on the right) on several main road arteries in Rome estimated from FCD.

lità attraverso la diretta osservazione delle scelte effettuate, come: l'orario di partenza, la destinazione, il percorso.

Utilizzando la base di dati disponibile, è stata realizzata un'analisi sperimentale del comportamento degli utenti nelle scelte del percorso e dell'orario di partenza. Per questo scopo, sono state selezionate, sulle circa 1300 zone definite dal comune di Roma per gli studi di mobilità, le coppie origine-destinazione che contenessero almeno 30 viaggi compiuti durante il periodo di picco del mattino (7:00-10:00), aventi una lunghezza di almeno 6 km e un tempo di percorrenza di almeno 20 minuti. È stato ottenuto in tal modo un campione di circa 600 conducenti, che compiono 1.450 spostamenti tra 28 coppie origine-destinazione.

Le posizioni GPS rilevate ogni 2 km sono state associate al grafo della rete stradale tramite una procedura di 'map matching' che considera la distanza dagli archi e la direzione del dato GPS, tenendo conto di possibili errori di posizionamento del dato. A partire dalle posizioni associate alla rete, per ciascun viaggio è stato ricostruito nel dettaglio il percorso seguito dall'utente mediante una specifica procedura che tra ogni coppia di posizioni consecutive rilevate applica un algoritmo dei k-percorsi [13] e seleziona tra questi quello la cui distanza è più prossima al valore misurato dal dispositivo di localizzazione GPS. Il risultato della procedura evidenzia che per ogni coppia origine-destinazione molti percorsi differiscono solo per piccole deviazioni. Adottare l'insieme di tutti i percorsi così ricostruiti come insieme di scelta dei modelli comportamentali di percorso pone problemi sia pratici che teorici. Infatti, un insieme di scelta troppo vasto rende il problema intrattabile matematicamente; peraltro, dal punto di vista ingegneristico, non risulta nemmeno utile distinguere tra percorsi che differiscono per poche decine di metri percorsi sulla viabilità locale. Infine, è anche dubbio che gli stessi utenti percepiscano questi percorsi come realmente alternativi. E' stata quindi applicata

the choice set of a route choice model may lead to both practical and theoretical issues. A too wide choice set may make the problem intractable. On the other hand, from an engineering point of view, discriminating routes differing because of only few dozens of meters travelled on the local roads may be meaningless. Furthermore, it is questionable if the users actually perceive these similar routes as alternative. A procedure that clusters together similar routes and identifies a representative route for each cluster. Since the analysis is addressed to scrutinise the route choice in standard conditions, routes have been excluded that contained short intermediate stops or atypical paths such as those containing engine turn off for a 3 to 15 minutes time interval or characterised by a much longer travel time than the average between successive detections.

The analysis of the representative routes underlines that the routes chosen by the users may be even very different each other. Figure 5 provides an example of 5 representative routes of drivers' route choices.

The shortest route, labelled as 69 in the figure, was the most frequently chosen; nevertheless, some users chose also a much longer route (labelled as 16) that mainly use expressways as well as routes having intermediate characteristics between them and being anyway curvier than the route 69.

In spite of the high difference between travelled distances, the clusters of routes belonging to the same O-D have rather similar average route travel times, as expected according to Wardrop's principle. Nevertheless, a large difference exists between their minimum and maximum values, as shown in figure 6, which depicts the frequency of travel time percentage difference computed for pairs of individual trips for all O-D pairs.

The continuous monitoring of trips enables an analysis of day-to-day variability, which is useful to specify and calibrate dynamic process models that aim at modelling the evolution of users' choice [14]. The results of the day-to-day variability highlight the propensity of users to follow

ta una procedura che raggruppa tra loro percorsi simili mediante un algoritmo di 'clustering' e seleziona il percorso rappresentativo per ogni 'cluster'. Al fine di valutare la distribuzione della scelta dei percorsi in condizioni standard sono stati esclusi i percorsi che contenevano delle brevi soste intermedie ed i percorsi nelle condizioni atipiche, individuati da uno spegnimento del motore per un tempo compreso tra 3 e 15 minuti o caratterizzati da un tempo di percorrenza tra due rilevazioni consecutive molto maggiore del tempo medio nello stesso periodo, e sono state utilizzate tutte le osservazioni rimanenti durante l'intero periodo di osservazione.

Il confronto tra percorsi rappresentativi evidenzia che i percorsi scelti dagli utenti sono effettivamente anche molto differenti gli uni dagli altri. Un esempio è fornito dalla figura 5, che mostra 5 percorsi rappresentativi tra una zona periferica ad una zona semi-centrale di Roma: il percorso più diretto, identificato dal numero 69 è il più utilizzato; alcuni utenti hanno anche scelto un percorso molto più lungo, che si svolge prevalentemente su strade ad elevato scorrimento, identificato dal numero 16, o percorsi con caratteristiche intermedie, e comunque più tortuosi del percorso 69. Nonostante la notevole differenza tra le distanze percorse, come da attendersi in accordo con il principio di Wardrop, cluster di percorsi appartenenti alla stessa coppia origine-destinazione hanno tempi di percorrenza medi piuttosto simili.

Esiste non di meno un ampio intervallo tra i loro valori minimo e massimo, illustrato nella figura 6, che rappresenta la distribuzione di frequenza delle differenze dei tempi di percorrenza tra tutti i viaggi individuali, espresse come percentuale del tempo medio sulla stessa coppia origine-destinazione.

La rilevazione continua dei viaggi consente inoltre un'analisi della variabilità giornaliera, utile per la specificazione e la calibrazione di modelli di processo dinamico, che mirano a rappresentare l'evoluzione delle scelte degli utenti in un dato intervallo temporale [14].

I risultati dell'analisi della variabilità giornaliera evidenziano la propensione degli utenti a seguire il percorso abituale per raggiungere la loro destinazione, sebbene il 12% degli utenti abbia scelto almeno una volta un percorso alternativo. Tra questi, il 10% degli utenti ha sempre scelto lo stesso percorso alternativo ed il restante 2% ne ha scelto più di uno. Di questo 10%, il 7% ha cambiato percorso una sola volta, mentre il 3% ha scelto il percorso alternativo per più di una volta (figura 7).

Sebbene sia ragionevole attendersi l'esistenza di una correlazione tra cambiamenti del percorso o del tempo di partenza e il tempo di viaggio sperimentato nel giorno precedente, questa correlazione non è stata evidenziata dalle osservazioni sperimentali. In effetti, un'analisi del percorso e del tempo di partenza hanno evidenziato come nel comportamento di scelta del percorso sia predominante una componente casuale che maschera ogni correlazione attesa tra cambiamenti di scelta ed esperienza

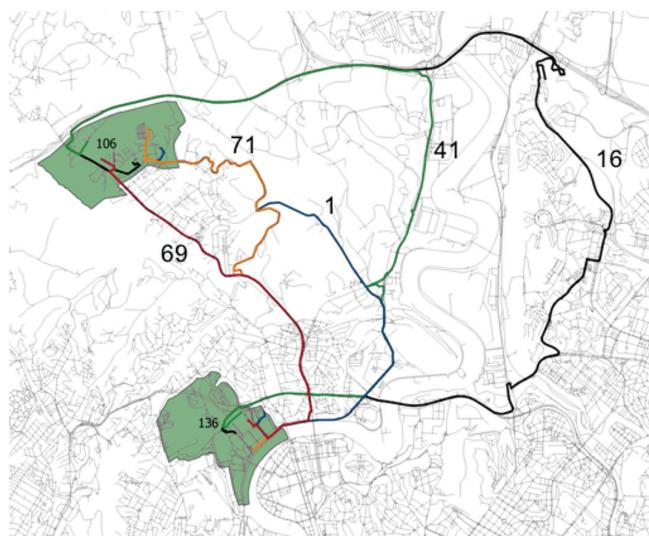


Fig. 5 - Esempi di percorsi rappresentativi tra due zone O-D.
Fig. 5 - Representative routes between two O-D zones.

their 'usual route' to get to their destination, although the 12% of the users switched from it to an alternative route. The 10% of the users always choose the same alternative path with respect to the usual one, while the 2% choose more than one alternative route. Among them, the 7% of the users make a route change just once; the 3% choose more than several different routes with respect to the usual one (figure 7).

Although the existence of a correlation is reasonable between the changes of route or departure time and the travel time experienced the day before, experimental observations did not reveal it. In fact, the analysis of departure time and route choice behaviour highlighted the predominance of a random component that hides any expected correlation be-

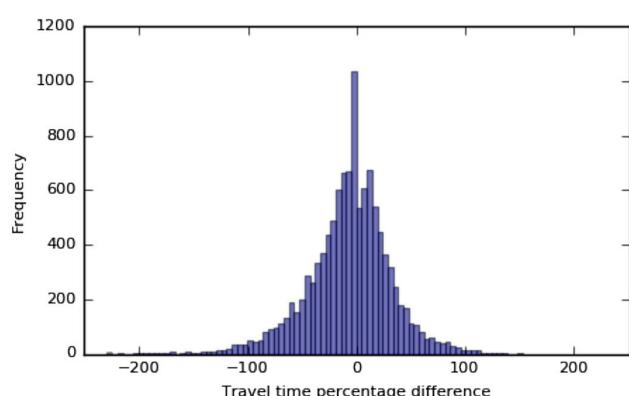


Fig. 6 - Frequenze osservate delle differenze dei tempi di percorrenza espresse come percentuali del tempo medio tra coppie di viaggi individuali per tutte le coppie O-D.
Fig. 6 - Observed frequency of travel time percentage difference computed for pairs of individual trips for all O-D pairs.

di viaggio. Ciò è probabilmente dovuto alla necessità di disporre di un periodo di analisi molto lungo che consente di osservare un numero sufficiente di cambiamenti della scelta abituale, eventi che ci si attende siano molto rari e legati a circostanze eccezionali. A tal fine, è in corso un'ulteriore analisi, che utilizza una base di dati che copre circa un anno di osservazioni.

3.4. Previsioni di traffico a breve termine

La maggior parte dei sistemi di informazione agli utenti fornisce una rappresentazione delle condizioni di traffico attuali su una mappa digitale su cui sono riportate le code, il traffico rallentato ed eventuali incidenti rilevati in tempo reale.

Per spostamenti da effettuare ad un orario o in un giorno futuro, questi sistemi indicano i percorsi ottimali ed i relativi tempi di percorrenza, utilizzando metodi di previsione di tipo statistico. Al contrario, non affrontano il problema di prevedere le condizioni di traffico nel breve termine se non estendendo la stima attuale (previsione cosiddetta 'naïf'): problema di prevalente rilevanza in caso di condizioni anomale per gli utenti che stanno viaggiando o sono in procinto di iniziare i loro spostamenti.

La ricerca presentata in questa memoria ha per oggetto lo sviluppo di metodi di previsione a breve termine applicabili online che utilizzano modelli di previsione del traffico, sia con approccio esplicito (cosiddetto approccio 'model-based') sia con approccio implicito ('data-driven').

3.4.1. Modelli di previsione esplicativi

L'approccio esplicito alla previsione applica modelli di assegnazione dinamica che riproducono esplicitamente il processo dipendente dal tempo consistente nella relazione circolare tra caricamento della rete, variazione delle prestazioni della rete conseguente alla distribuzione dei flussi di traffico, comportamento di scelta dei conducenti in funzione delle prestazioni di traffico percepite o previste. Modelli di assegnazione dinamica basati sulla simulazione esplicita del traffico sono stati introdotti negli anni '90 per riprodurre non solo i fenomeni di diffusione della congestione sulla rete stradale, ma anche per modellare il comportamento degli utenti informati e non informati in differenti scenari comprendenti sistemi di informazione collettivi o a bordo dei veicoli [15]. Questi modelli sono stati in seguito integrati con versioni in tempo reale che, seguendo un approccio 'Rolling Horizon', sono in grado di acquisire i dati di traffico online, aggiornare matrici origine-destinazione dinamiche e simulare le condizioni di traffico, sia attuali che conseguenti all'applicazione di possibili scenari di gestione del traffico e di informazione agli utenti (figura 8). Il centro di controllo del traffico riceve i dati raccolti sulla rete stradale con un intervallo di aggiornamento Δt (in genere, non superiore a 5 minuti); aggiorna la stima della ma-

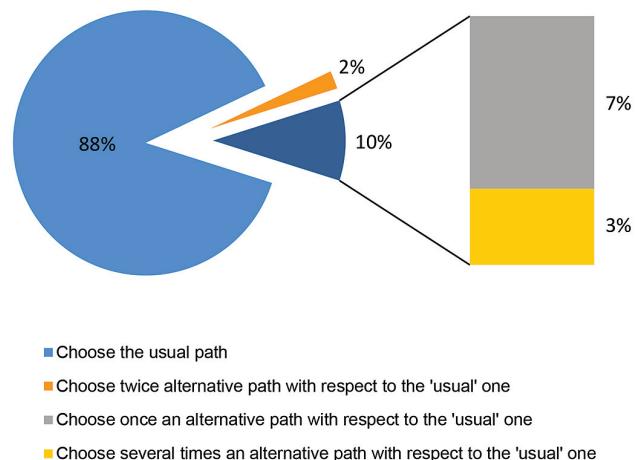


Fig. 7 - Risultati dell'analisi della variabilità giornaliera della scelta di percorso.

Fig. 7 - Results of route choice variability analysis.

tween choice changes and the travel experience. This is probably due to the need of a very long period of analysis that allows observing a sufficient number of users' decision changes, which are expected to be very rare and related to the occurrence of exceptional events. To this goal, further analyses are ongoing on a larger dataset collected during about one year of observations

3.4. Short-term traffic predictions

Most traffic information systems provide the users with the picture of the current traffic conditions: queues, slow traffic and accidents detected in real-time are displayed on a digital map. Moreover, these systems use statistical data to derive predictions of travel times at different hours and different days that they use to provide users with route suggestions based on the travel times forecasted at the time they will make their trip. This feature is very useful to allow the users planning the trips they are going to make in the next hours or days; however, these systems do not face the main issue to predict traffic conditions in the short-term, which is of a paramount relevance in case of anomalous conditions for users who are already traveling or are starting their trips.

The research presented in this paper aims at developing online models that combine statistical data with real-time methods to derive short-term predictions on traffic performances, by following either implicit or explicit modelling approaches.

3.4.1. Explicit Prediction Models

Explicit prediction models apply dynamic traffic assignment models that reproduce explicitly the time-dependent process consisting in the circular relationship be-

trice O-D sulla base delle precedenti configurazioni di traffico rappresentate dalla matrice di assegnazione o da una sua opportuna approssimazione; assegna la matrice O-D per simulare il traffico sulla rete stradale su un intervallo di tempo $\Delta T > \Delta t$ e aggiorna i flussi simulati ed i tempi di viaggio nella base di dati. Poiché l'intervallo di simulazione è più lungo del periodo di aggiornamento, la previsione è valida per tutto l'intervallo di simulazione, finché non vengono ricevuti nuovi dati e non viene effettuata una nuova simulazione.

I modelli esplicativi hanno il grande vantaggio di prevedere le prestazioni della rete anche in condizioni anomale e di poter simulare condizioni non ancora esistenti, consentendo così di valutare, ad esempio, gli effetti di differenti politiche di gestione della mobilità o l'impatto di diverse strategie di informazione. Inoltre, mentre i modelli impliciti sono abitualmente applicati su un numero molto limitato di archi, i modelli esplicativi forniscono risultati su tutti gli archi della rete simultaneamente. Di converso, i modelli esplicativi richiedono un processo di calibrazione del modello estremamente impegnativo ed un grande sforzo per raccogliere tutti i dati di input necessari. In particolare, la stima in tempo reale di matrici O-D dinamiche è un problema particolarmente difficile, che richiede un aggiornamento frequente e dettagliato dei dati di traffico. Inoltre, i modelli esplicativi non sono scalabili e non sono generalizzabili esportando in una città un modello calibrato in un'altra. Pertanto, appare conveniente un approccio alla previsione del traffico che sfrutta

tween traffic network loading, variation of network performances due to traffic flow distribution, and the route choice behaviour of drivers depending on perceived or predicted traffic performances. Advanced simulation-based dynamic traffic assignment models were introduced in the '90s to reproduce not only phenomena of congestion spreading on the network but also the behaviour of informed and uninformed users under different scenarios of collective and on-board dynamic traveller information systems [15]. These models were finally complemented with real-time versions capable to collect traffic data in real-time, update the time-dependent origin-destination demand trip matrix, simulate the current traffic conditions and possible traffic management or driver information scenarios under a rolling horizon approach. Figure 8 shows the functional flow-chart of the simulation-based dynamic assignment rolling horizon approach. The traffic centre receives real-time data collected on the road networks with the update time period Δt (typically, 5 minutes or less); then, it updates the estimation of the Origin-Destination (O-D) demand trip matrix on the basis of previous assignment pattern, which is represented by the assignment matrix or by a suitable approximation, it assigns the O-D matrix to simulate the vehicular traffic on the road network over a longer time interval ΔT than Δt , and updates simulated flows and travel times in the traffic centre database. Since the simulation interval is longer than the update period, a longer prediction (typically 1 hour or more) holds until new data are received and a new simulation is run.

Explicit models have the great advantage that they can predict network performances in non-standard conditions and can simulate even non-existing conditions such as the effects of mobility management policies or the impact of different information strategies. Moreover, while implicit models are usually applied on a very limited set of links, explicit models provide results on all links of the network simultaneously. However, explicit models require a huge effort to collect all data necessary as inputs and a cumbersome process to calibrate the model. Specifically, deriving reliable time-dependent origin-destination demand in real-time is a very challenging task, which requires detailed and frequently updated traffic data. Furthermore, they are not scalable and they are not generalizable from one application to another. Finally, a convenient approach to traffic prediction could consist in exploiting the complementary features of the two kinds of models and combine them in an integrated framework.

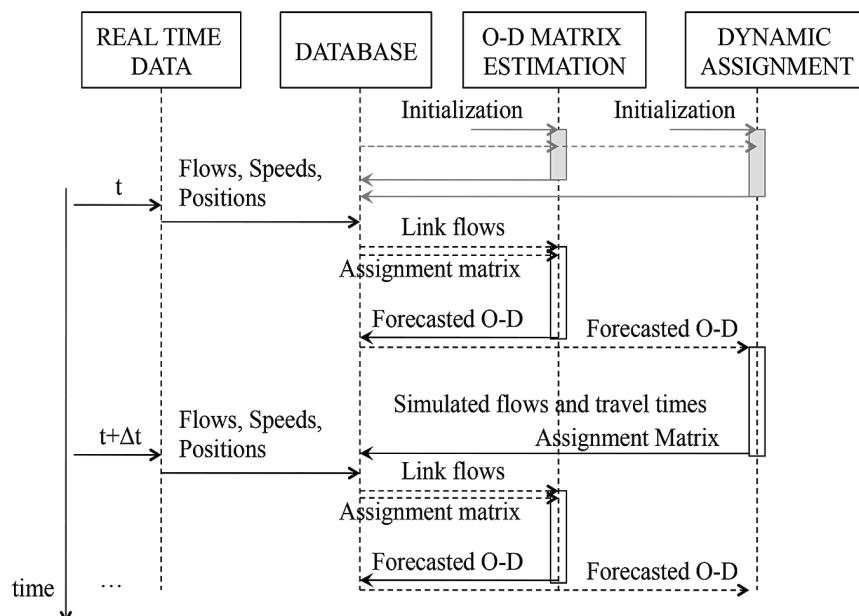


Fig. 8 - Diagramma di flusso dell'approccio 'rolling horizon' al problema dinamico di assegnazione-simulazione e di stima della matrice di domanda di spostamenti Origine-Destinazione (O-D).

Fig. 8 - Functional flow-chart of the rolling horizon approach to simulation-based dynamic traffic assignment and Origin-Destination (O-D) trip demand matrix.

le caratteristiche complementari dei due tipi di modelli e li combini in un approccio integrato.

A titolo esemplificativo, vengono riportati i risultati di un'applicazione condotta in simulazione dagli autori [16], che hanno applicato all'area metropolitana di Roma un modello di assegnazione quasi-dinamico [17] ed un modello dinamico di assegnazione-simulazione rappresentativo dello stato dell'arte, Dynasmart [18]. Nella tabella 1 sono riportati l'errore assoluto medio (MAE) e l'errore quadratrico medio normalizzato (NMSE), ottenuti confrontando le velocità simulate con quelle rilevata con i veicoli sonda nello stesso periodo simulato, il periodo di punta del mattino. Entrambi i modelli hanno fornito una leggera sovrastima dei valori di velocità media sulla rete⁽³⁾, contenuta all'interno dell'intervallo di confidenza della stima della velocità media nell'area di studio, pari all'11%.

3.4.2. Modelli di previsione impliciti

Il problema di previsione del traffico a breve termine con approccio隐式 è oggetto di studio da parte della comunità scientifica dalla fine degli anni '70. I primi studi hanno prodotto modelli di serie temporali che applicano il metodo Box-Jenkins per prevedere i valori futuri di una variabile mediante una combinazione iterativa dei suoi valori precedenti [19]. Nei fenomeni di traffico le prestazioni di ciascun elemento della rete possono essere condizionate dalla formazione di code o rallentamenti sugli elementi vicini: la sovraccarico di un nodo o di un arco produce la propagazione all'indietro di una coda che può raggiungere l'intersezione a monte e ridurne la capacità; inoltre, dagli archi che convergono nel nodo possono propagarsi altre code, così che nell'area si può formare un'ancor più vasta congestione. I metodi di previsione del traffico urbano dovrebbero pertanto essere in grado di cogliere le relazioni fisiche esistenti tra archi vicini della rete. In effetti, in letteratura sono stati proposti numerosi modelli multivariati che estendono i modelli di serie temporali introducendo formulazioni vettoriali finalizzate appunto a rappresentare la correlazione spaziale tra le variabili di traffico di diversi elementi sulla rete. Tenendo conto anche dell'aspetto temporale, sono stati poi sviluppati modelli multiparametrici non lineari più complessi, quali le reti neurali artificiali ([20]; [21], e molti altri autori successivi), le reti bayesiane ([22]; [23]) e modelli cosiddetti di 'deep learning' ([24]), che mirano a cogliere la natura intrinsecamente spazio-temporale del traffico in forma implicita.

TABELLA 1 – TABLE 1

Validazione dei modelli esplicativi di stima della velocità rispetto alle velocità FCD rilevate nel periodo di punta del mattino
Validation of dynamic traffic assignment models with respect to FCD measures of speed

Dati/Modello Model	Velocità media Avg. speed (km/h)	MAPE (%)	NMSE (adimensionale)
Floating Car Data	39,7	Rif.	Rif.
Quasi-Dynamic Traffic Assignment	43,3	+9%	+0,21
Dynasmart	40,8	+4%	+0,18

An experimental application was conducted in simulation by the authors month [16], who applied an approximate Quasi-Dynamic Traffic Assignment model [17] and the state-of-art dynamic traffic assignment model Dynasmart [18] to the urban area of Rome. Both the models were validated against the average speed values of collected Floating Car Data. Mean Absolute Percentage Errors (MAPE) and Normalized Mean Square Errors (NMSE) resulting from the application are summarized in Table 1. Both the models provided slight overestimates of the average observed values⁽³⁾. However, the average errors were limited within the confidence interval of measured speed in the study area, which is about 11%.

3.4.2. Implicit prediction models

Scientific community has been studying the short-term traffic prediction problem since late '70s. The earliest studies applied time-series models developed according to the Box-Jenkins method to predict future values of one variable as an iterative combination of its previous observed values [19].

Since traffic phenomena are movements of streams of vehicles onto the road network, the performances of each element of the network can be affected by formations of queues on neighbour elements. Oversaturation at one node or on one link produces a queue spilling back that can reach the upstream junction and reduce its capacity. New queues can propagate from the links entering this node, so that a wider congestion can propagate on that area. Traffic prediction methods should be able to capture such physical relationships among close links of the network.

Several attempts were made to catch spatial correlation between traffic variables on the road network by extending time-series models to multivariate form introducing vectorial formulations. More complex multi-parameter non-linear mathematical models were introduced, such as artificial

⁽³⁾ Il valore della velocità media nella tabella 1 è calcolato con riferimento al periodo di punta del mattino, mentre il valore commentato nella nota 2 è riferito all'intera giornata.

⁽³⁾ The average value of the speed in Table 1 is computed with reference to the morning peak period, while the value commented in Note 2 is referred to the whole day.

Nel seguito, viene riportato il risultato delle applicazioni di alcuni modelli di previsione impliciti, basati su reti neurali e reti bayesiane, sviluppati dagli autori utilizzando la base di dati di veicoli sonda descritta in precedenza.

Il vantaggio di modelli previsionali basati su un'architettura di rete, come le reti neurali e le reti bayesiane, consiste nella presunta capacità della struttura di rete di cogliere la correlazione spaziale degli stati di traffico della rete stradale.

Nel caso della rete neurale, è stata utilizzata una classica rete 'feedforward' [25] che fornisce la previsione delle velocità v_{t+1} su un arco come una funzione non lineare dei valori osservati $\mathbf{u} = \{u_j\}$ di m variabili di traffico rilevate in p intervalli temporali precedenti su l archi, incluso quello da prevedere, essendo $j=1, 2, \dots, N=m \cdot l \cdot p$.

$$\hat{v}_{t+1} = f_1 \left[\sum_{h=1}^H \alpha_h f_2 \left(\sum_{j=1}^N \beta_{j,h} u_j + \delta_j \right) + \delta_h \right] \quad (1)$$

Nell'equazione (1) t è l'intervallo temporale corrente, H è il numero di neuroni dello strato nascosto, f_1 e f_2 sono funzioni di attivazione non lineare, $\{\alpha_h\}$ e $\{\beta_{j,h}\}$ sono i coefficienti delle matrici dei pesi, δ_j e δ_h sono valori soglia associati, rispettivamente, allo strato nascosto e allo strato di uscita.

La figura 9 illustra l'architettura del modello di previsione denominata 'a stella doppia', introdotta per rappresentare un modello alimentato con i valori delle variabili degli archi che compongono la stella entrante e la uscente dell'arco di previsione.

La figura 10 mostra la corrispondente struttura della rete stradale.

Le reti bayesiane (BN) sono modelli grafici probabilistici. Questa definizione evidenzia le due componenti che devono essere specificate in una rete bayesiana: una componente grafica, rappresentata da un grafo aciclico orientato, e una componente probabilistica, rappresentata dal-

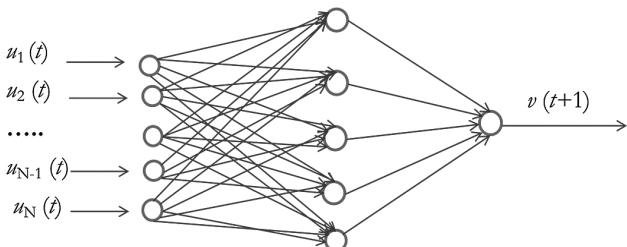


Fig. 9 - Architettura della rete neurale (NN) a stella doppia per la previsione della velocità in funzione della velocità sull'arco stesso e sugli archi della stella entrante e della stella uscente.

Fig. 9 - Double-Star Neural Network (NN) architecture for short-term speed prediction as a function of the target link, backward star and forward star average speed v .

neural networks [20]; [21], and many other authors later on), Bayesian networks [22]; [23] and deep architecture models [24], with the aim of capturing the inherent time-space nature of road network traffic implicitly.

A brief overview of the prediction models and a summary of the results achieved by the authors in their previous work using the same database of Floating Car Data are reported in the following as an example. The expected advantage of prediction methods based on network architecture, such as Neural Networks and Bayesian Network, is that their graph structure should have the capability to catch the time-dependent spatial correlation of traffic states on the road network. Artificial Neural Networks NN is a static nonlinear feedforward vector multivariate function [25] that forecasts the future value of speed v_{t+1} on an output link as a nonlinear function of the observed values $\mathbf{u} = \{u_j\}$ of m traffic variables detected in p previous time intervals on l links, including the output one, being $j=1, 2, \dots, N=m \cdot l \cdot p$.

$$\hat{v}_{t+1} = f_1 \left[\sum_{h=1}^H \alpha_h f_2 \left(\sum_{j=1}^N \beta_{j,h} u_j + \delta_j \right) + \delta_h \right] \quad (1)$$

In the formula, t is the current time interval, H is the number of neurons in the hidden layer, f_1 and f_2 are nonlinear activation functions, $\{\alpha_h\}$ and $\{\beta_{j,h}\}$ are coefficient matrices, δ_j and δ_h are threshold values associated with the hidden and output layers, respectively.

Figure 9 illustrates the so-called 'double star' architecture of the prediction model fed by the variables measured on the forward star and the backward star of links; figure 10 shows and the corresponding structure of the road network.

Bayesian Networks (BN) are probabilistic graphical models. This definition outlines the two components that must be specified in a BN: a graphical component, represented by a directed acyclic graph, and a probabilistic component, expressed by probability distributions. In particular, each node of the graph represents a random variable, while the links that connect the nodes represent probabilistic dependencies between the corresponding random variables. The cause-effect relations used in BNs can be represented by considering the neighbour links in case of traffic dynamics.

The forecasted value \hat{v}_{t+1} on a generic link is the expected value of the posterior probability function of the speed, attained as the result of an a priori estimation v_{t+1}^0 and conditioned by the probability density function of the variables $\{\mathbf{u}_t^{(1)}, \mathbf{u}_t^{(2)}, \dots\}$ observed in the recent past on some parent nodes. The input variables \mathbf{u} are composed, other than the speeds v , by their standard deviations σ and the numbers of observations n in the same observation periods, to take into account of the statistical significance of the average speeds. Both upstream and downstream links of the prediction link were included to take into account both forward flow progression that occurs in light traffic and spillback

le distribuzioni di probabilità delle variabili rilevanti. In particolare, i nodi del grafo rappresentano ciascuno una variabile casuale, mentre gli archi che li connettono rappresentano dipendenze probabilistiche tra le variabili. Le relazioni di causa-effetto usate nelle reti bayesiane possono essere rappresentate considerando la dinamica del traffico che si svolge tra archi contigui.

Il valore di velocità \hat{v}_{t+1} previsto su un generico arco della rete è il valore atteso della funzione di probabilità a posteriori della velocità, ottenuto quale risultato di una stima a priori v_{t+1}^0 condizionato dalla funzione di densità di probabilità delle variabili di input $\{u_t^{(1)}, u_t^{(2)}, \dots\}$ osservate in un recente passato sui nodi antecedenti (o nodi genitori, secondo la terminologia delle reti bayesiane). Sia gli archi a monte che quelli a valle dell'arco di previsione sono stati inseriti nella rete bayesiana per tenere conto, rispettivamente, della progressione in avanti del flusso che avviene in condizioni di scarso traffico e della progressione all'indietro che si verifica in condizioni di congestione. Le variabili di input u sono costituite, oltre che dalle velocità v , dalla loro varianza σ e dal numero n di osservazioni nel periodo di osservazione, così da tenere conto della significatività statistica delle velocità medie.

La figura 11 illustra l'architettura del modello di previsione bayesiana basato sulla stessa architettura 'a stella doppia', introdotta per la rete neurale e corrispondente alla rete stradale rappresentata in figura 10.

La validazione dei modelli di previsione è stata effettuata confrontando le velocità previste da ciascun modello con le corrispondenti velocità medie osservate durante l'ultima settimana del mese di osservazione su un insieme di 20 archi che costituiscono la rete principale del quartiere EUR di Roma [12]. La tabella 2 riporta gli indicatori di errore della rete neurale (NN) e una rete bayesiana (BN) che utilizza come stima a priori il risultato di un modello di serie temporali SARMA. Quale termine di

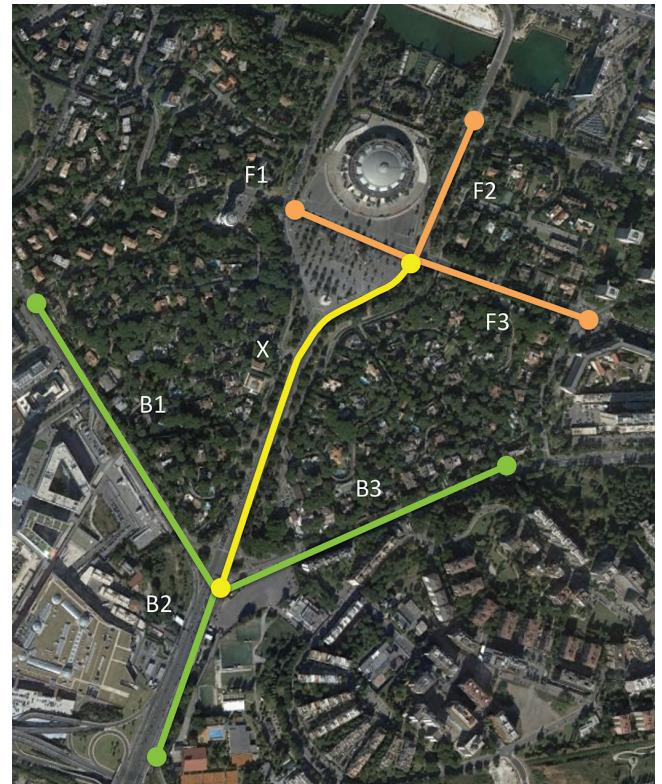


Fig. 10 - Arco di previsione (identificato dalla 'X'), archi a monte (B1, B2, B3) e archi a valle (F1, F2, F3) corrispondenti alla rete neurale illustrata in figura 9 e alla rete bayesiana illustrata in figura 11.

Fig. 10 - Target link for predictions (labelled as 'X'), backward links (B1, B2, B3) and downstream links (F1, F2, F3) with reference to the Neural Network architecture in figura 9 and the Bayesian Network illustrated in figura 11.

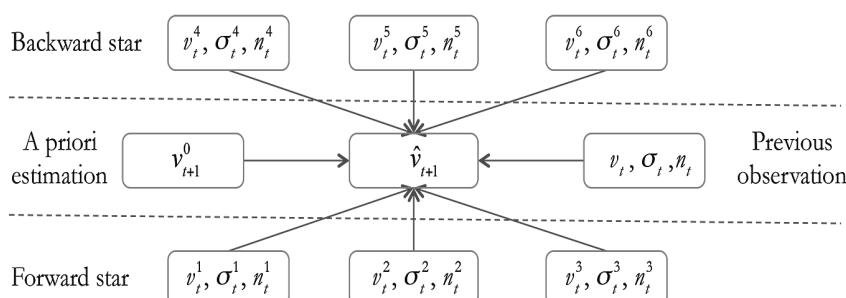


Fig. 11 - Architettura della rete bayesiana a stella doppia per la previsione della velocità in funzione della stima a priori, delle velocità v , della varianza σ delle velocità e del numero n di osservazioni sugli archi della stella entrante e della stella uscente.

Fig. 11 - Double-Star Bayesian architecture for short-term speed prediction as a function of a priori estimation, backward star and forward star average speed v , speed standard deviation σ , and number of observations n .

progression that arises in congested conditions. Figure 11 illustrates the architecture of the Bayesian prediction model based on the same 'double star' architecture introduced for the Neural Network and corresponding to the road network depicted in figure 10.

Model validation was performed by comparing speeds forecasted by different models with the corresponding average speeds observed during the last five weekdays of the month on a set of 20 main road links in the EUR borough in Rome [12]. Table 2 reports the error indicators for the Bayesian Network with a priori estimation obtained by SARMA time-series model (BN) and the Neural Network (NN). To appreciate the contribution achieved by applying the prediction

paragone, sono riportati anche gli indicatori di errore ottenuti applicando metodi di previsione semplici, quali un semplice filtro di media mobile (MA) calcolata sulle ultime tre osservazioni e la media statistica (HA) calcolata sull'insieme dei dati raccolti in precedenza.

La rete bayesiana con stima a priori SARMA fornisce i risultati migliori, con valori dell'errore medio assoluto (MAE) e dell'errore quadratico medio (RMSE) di 6,73 km/h e 9,28 km/h, rispettivamente. La rete neurale presenta prestazioni analoghe, con valori di MAE e RMSE rispettivamente pari a 6,82 km/h e 9,48 km/h. Gli indici di errore della media statistica e della media mobile, riportati a titolo di confronto, eccedono valori MAE di 8 km/h per MAE e RMSE di 11 km/h.

Ai fini di un eventuale confronto tra approccio implicito ed approccio esplicito, che peraltro qui non viene proposto direttamente, si deve tenere conto del fatto che il modello esplicito è stato applicato per simulare l'ora di punta su tutti gli archi della rete con intervalli temporali di 15 minuti e che la sua validazione è stata compiuta con riferimento ai valori giornalieri medi; al contrario, le previsioni del modello implicito sono state eseguite su 20 archi della rete per intervalli di 5 minuti e la relativa validazione è stata effettuata con riferimento ad una settimana di osservazioni, mediando successivamente i valori.

4. Futuri sviluppi

L'analisi dei dati individuali esposta nei paragrafi precedenti ha evidenziato la necessità di stimare lo stato del sistema di mobilità e di prevederne le prestazioni future al fine di fornire agli utenti servizi personalizzati che tengano conto delle loro preferenze e delle loro abitudini. Questi temi sono più diffusamente esposti in un recente volume degli autori [26], di cui si riportano nel seguito le considerazioni principali, con l'obiettivo di definire le caratteristiche e i requisiti dei futuri sistemi di informazione basati sull'uso dei Big Data acquisiti con continuità sulla rete o forniti direttamente dagli utenti, in forma di condivisione o di richiesta di servizio.

4.1. Personalizzazione ed estensione della informazione

Comprendere le preferenze degli utenti rende l'informazione più efficace. Proporre solo le alternative che corrispondono alle preferenze degli utenti, infatti, agevola il compito di scegliere tra molteplici alternative e rende l'uso del servizio più veloce e più agevole. Nonostante i sistemi d'informazione possano richiedere al conducente di definire esplicitamente le proprie preferenze di scelta secondo criteri come costo, tempo, distanza e sicurezza, i metodi di intelligenza artificiale come il 'machine learn-

TABELLA 2 – TABLE 2

Indicatori di errore per i modelli di previsione basati su rete bayesiana (BN), su rete neurale (NN), per la media storica (HA) dei dati e per un filtro di media mobile su tre intervalli precedenti
Error indicators for the selected models and for the historical average on the validation data set for a confidence levels $P=0.90$ of the average speed estimates

Modello Model	MAE [km/h]	MAPE [%]	RMSE [km/h]	RMSEN [adim.]
BN	6.73	11%	9.28	0.15
NN	6.82	12%	9.48	0.15
MA	8.47	14%	12.03	0.19
HA	8.23	14%	11.83	0.19

models to speed forecasts with respect to a simple data filtering technique, we applied simple predictors such as the moving average filter (MA) computed on the last three observations and the Historical Average (HA) computed on the calibration dataset.

BN with SARMA a priori estimate provides the best results for all the confidence levels examined, with MAE and RMSE indicators equal to 6.73 km/h and 9.28 km/h, respectively. NN shows similar indicators with MAE and RMSE, that is 6.82 km/h and 9.48 km/h respectively. The error indicators of the historical average –that is, the statistical estimate– and the moving average (MA) are reported as a reference value. For both of them, MAE and RMSE exceed 8 km/h and 11 km/h, for MAE and RMSE respectively. In the table, Mean Absolute Percentage Error and Root Mean Square Error Normalized are also reported to provide relative error indicators.

A comparison between the results of the implicit and the explicit models is not proposed here, because the two applications are not consistent with each other. In fact, the explicit model has been applied to simulate the whole road network for one hour with 15-minute time intervals and has been validated with reference to the average daily speed values. However, the predictions of the implicit model have been performed on 20 road links with 5-minute intervals and the corresponding validation has been conducted over one week of observations.

4. Future Applications

The modelling mobility issues described in the previous section open new perspectives to develop advanced applications of control methods, information strategies and mobility services. Traveller information services should exploit the richness of the big data collected by individual devices to obtain personalized services that take into account users' preferences and habits. The issue is widely dealt with in a recent book [26], whose main considerations are reported here, with the aim to define characteristics and requirements of future information systems based on Big Data continuously collected on the network or directly provided by the users, in the form of crowdsourcing or for services required.

ning', le reti neurali artificiali, le reti bayesiane e gli algoritmi di 'clustering' sono in grado di apprendere autonomamente le preferenze degli utenti e i loro meccanismi di scelta direttamente dalla continua osservazione dei loro comportamenti di mobilità. L'autoapprendimento riduce la quantità di informazioni che l'utente deve fornire al sistema e non lo distoglie dallo svolgimento di altre attività, ed in particolare dalla guida.

4.2. Disponibilità di parcheggio

La più diretta estensione dei sistemi di guida di percorso consiste nel fornire agli utenti un'informazione sulla disponibilità di parcheggio e aggiungere al tempo di percorrenza una stima del tempo necessario per trovare uno stallone libero.

I parcheggi fuoristrada sono spesso equipaggiati con sensori infrarossi in grado di rilevare la presenza dei veicoli negli spazi di sosta. Per i parcheggi su strada sono stati di recente introdotti sistemi di rilevamento che usano sensori video con elaborazione di immagini o sensori magnetici.

In tal modo, i conducenti possono essere informati in tempo reale del numero di stalli di sosta disponibili in prossimità della loro destinazione e possono essere guidati verso il parcheggio prescelto. Il tempo necessario per trovare uno spazio di sosta libero su parcheggi non monitorati può essere stimato sviluppando metodi che utilizzano i dati da veicoli sonda. Se i veicoli monitorati sono campionati con elevata frequenza, i metodi di stima confrontano direttamente il percorso seguito in prossimità della destinazione con il percorso più veloce ed assumono che il tempo in eccesso sia il risultato di percorsi più contorti effettuati alla ricerca di uno stallone libero. Se il campionamento di veicoli monitorati ha una frequenza più bassa, il tempo in eccesso alla ricerca del parcheggio può essere stimato confrontando la distanza percorsa tra punti consecutivi rilevati in prossimità della destinazione con la distanza attesa, che può essere derivata da valori precedentemente rilevati per lo stesso veicolo così come dai valori di altri veicoli rilevati nella stessa area nello stesso intervallo di tempo.

4.3. Informazione intermodale

L'approccio intermodale è un requisito importante dei sistemi di informazione agli utenti. Infatti, mentre il trasporto stradale è caratterizzato da effetti di congestione che riducono la velocità al crescere della domanda, i sistemi di trasporto collettivo sono caratterizzati da economie di scala, che consentono di ridurre il costo unitario per passeggero al crescere della domanda. Infatti, la maggiore capacità del veicolo e la possibilità di formare convogli consentono di accrescere la capacità della linea di trasporto collettivo per rispondere ad una domanda elevata e ridurre così il contributo relativo ai costi fissi dell'infrastruttura sul costo totale del trasporto.

4.1. Personalisation and extension of information

Understanding users' preferences makes the information more effective. Only the alternatives that match with expected preferences of the user can be proposed directly. This reduces the effort of the users to choose among many alternatives and makes the use of the service quicker and easier. Although traveller information systems can ask the driver to explicitly state his/her choice preferences by ranking criteria like cost, time, distance, safety, scenery, some machine learning methods, like artificial neural networks, Bayesian networks, and clustering pattern matching, try to learn users' preferences and choice mechanism directly from continuous observations of his/her travel behaviour.

Individual travel information can be integrated with other personal services. Since mobility usually depends on the need of performing other activities, this feature would allow the users to optimize his/her activity plan by selecting the optimal schedule of activities. Optimization routines that solve scheduling and travel salesman problems can help the user to find the most convenient sequence of activities. Self-learning reduces the amount of information that the user has to provide to the system and does not distract him from his task and overall from the driving attention.

4.2. Parking availability

The simplest extension of route guidance systems is to provide estimation on parking availability and to add the time needed to find a free parking space to the travel time. Out-street parking is often equipped with infrared sensors able to detect the presence of vehicles in parking spaces. Detection systems using video image processors or magnetic sensors were recently introduced also for on-street parking. So, drivers can be informed online about the number of available parking places near their destination and can be guided toward the parking they have chosen. Methods to estimate the time needed to find a free parking place on unmonitored parking could be derived by exploiting floating car data. If tracked vehicles are sampled at high-frequency rate, the estimation method directly compares the route followed in the neighbourhood of the destination with the quickest route and assumes the overtime resulting from the convoluted path be due to parking search. If sampling of tracked vehicles has a low rate, the overtime to find a free parking can be determined by comparing the speed or the distance travelled between consecutive points detected near the destination with respect to the expected values, which can be derived from the previous values detected for the same vehicle as well as by the values of other vehicles in the same area and the same time

4.3. Intermodal information

The intermodal approach is a fundamental feature for traveller information systems. In fact, while car transport is affected by congestion effect that reduces the speed as the

Sono oggi disponibili molti dispositivi di assistenza ai viaggiatori ('travel assistant') che considerano i differenti modi di trasporto alternativi al percorso stradale. Poiché la maggior parte degli autobus sono equipaggiati con tecnologie di localizzazione, i 'travel assistant' sono aggiornati automaticamente sulle posizioni dei veicoli e fornire ai viaggiatori previsioni in tempo reale dei tempi di attesa alle fermate. D'altra parte, le ferrovie sono sistemi chiusi abitualmente equipaggiati con sistemi di monitoraggio specifici, così che le informazioni sulla posizione dei treni e le previsioni dei tempi di attesa sono anch'esse incluse nei 'travel assistant' dinamici che dipendono da accordi con le imprese ferroviarie. Per acquisire maggiore efficacia, i sistemi di informazione intermodale devono fornire agli utenti un insieme completo di alternative che includano tutti i singoli modi di trasporto e i possibili interscambi con un livello di dettaglio sufficiente a consentire al viaggiatore trasbordi rapidi e confortevoli da un modo all'altro. Al riguardo, vanno rese disponibili ai viaggiatori mappe dettagliate delle stazioni ferroviarie e di metropolitana, così come di porti ed aeroporti, che, unitamente a sistemi di localizzazione terrestre, forniscano una copertura complementare ai sistemi satellitari che non sono ricevibili in luoghi chiusi.

4.4. Mobilità come servizio

Nuovi servizi di trasporto come 'car sharing', 'car pooling', 'bike sharing', così come altri servizi di trasporto pubblico flessibile, quali gli autobus a deviazione di percorso, consentono di estendere le opportunità di mobilità e di migliorare le prestazioni del sistema di trasporto nel suo complesso. I sistemi ICT hanno migliorato grandemente l'accessibilità a questi servizi; la loro quota di mercato si è accresciuta significativamente negli ultimi anni e ci si attende continui a crescere in futuro. Una rivoluzione simile a quella attuata dall'e-commerce nel trasporto merci, che consente agli utenti di acquistare i prodotti su Internet e di riceverli a casa, si può pensare avvenga nella mobilità dei passeggeri grazie ai nuovi servizi di assistenza alla mobilità. L'accettazione da parte degli utenti è un aspetto cruciale per assicurare che questi nuovi servizi siano realmente efficaci al fine di ridurre la congestione di traffico, accrescere la mobilità sostenibile e infine migliorare le prestazioni del sistema di trasporto.

Un aspetto fondamentale della mobilità come servizio consiste nel disgiungere le scelte di mobilità dal possesso di un veicolo. Pertanto, l'approccio alla mobilità come servizio implica che l'uso di una autovettura debba essere solo una delle possibili alternative. Poiché la mobilità è un'esigenza secondaria, condizionata al soddisfacimento di esigenze primarie (lavoro, studio, acquisti, impegni personali, svago), è importante che la mobilità come servizio sia sviluppata considerando l'insieme delle attività personali nel loro complesso, nonché le preferenze comportamentali e le esigenze personali dell'utente, che includono condizioni di salute, attitudine alle interazioni sociali ed aspetti legati alla sicurezza personale.

demand flow increases, mass transit systems is characterized by scale economies, which allow reducing the unit cost for passenger as the demand increases. The reason for such opposite features is due to the large vehicle capacity of mass transit that makes it possible to increase the transit line capacity if required by higher demand and so reduce the relative contribution of infrastructure fixed cost on the total travel cost.

Many travel assistants are now available that consider the different transport modes as alternatives to usual car routes. Since most buses are equipped with locating technologies, travel assistants are updated dynamically and provide travellers with real-time information on expected bus arrival times. Railways are closed systems that are usually equipped with specific monitoring system. Information on train positioning and expected delays are also included in dynamic travel assistants depending on agreements with rail companies.

To be more effective, intermodal traveller assistants must provide users with a full set of alternatives that include all single modes and possible interchanges with a sufficient level of detail to allow the traveller making comfortable and timely transfers from one mode to another. On this regard, detailed maps of rail and underground stations, as well as ports and airports, should be developed and made available to travellers through ground locating systems that provide complementary indoor coverage to positioning satellite systems where they are not receivable.

4.4. Mobility as a service

New transport services such as car sharing, car pooling, as well as bike sharing, and other flexible public transport services enlarge transport opportunities and improve overall transport system performances. ICT improved greatly the accessibility of these services and their market share increased significantly in the last years and is expected to continue its growth in future. A similar revolution actuated by e-commerce in freight transport (where customers buy their products on the Internet and receive them at home) can be envisioned in passenger mobility thanks to new mobility assistance services. Users' acceptance is a crucial issue to ensure that the new services be really effective in order to reduce traffic congestion, increase sustainable mobility and finally improve transport system performances.

Specific mobility assistance services include information on available travel alternatives, real-time information as well as ticket booking and buying. A full deployment of the concept of 'mobility as a service' requires that mobility-specific services be integrated within a more general approach to the complex dynamic individual-specific set of users' needs. On the other hand, different user groups may exhibit different needs and require so different kinds of services.

Mobility assistance should be integrated into the personal user agenda and provide users with best solutions for

4.5. Partecipazione degli utenti

Le reti sociali sono uno straordinario prodotto dello sviluppo delle tecnologie di comunicazione (ICT), che consentono agli utenti di interagire e di scambiarsi informazioni. Nel sistema di trasporto le reti sociali sono anche uno strumento che consente di raccogliere e distribuire informazioni sulle qualità del sistema di trasporto, quali la pulizia, i ritardi, l'affollamento, la puntualità. Gli utenti possono valutare la qualità del servizio di trasporto direttamente comunicando una loro personale opinione o indirettamente, venendo tracciati durante il proprio spostamento e contribuendo così alla rilevazione di eventuali scostamenti del servizio dall'orario o dalla frequenza prevista. A differenza del traffico stradale, in cui gli utenti che usano lo stesso percorso possono condividere l'informazione sulla presenza di congestione ma non possono agire direttamente per ridurla, nel caso del trasporto pubblico, l'informazione raccolta dagli utenti, se condivisa con l'azienda di trasporto, consente a questa di intervenire sul servizio e di migliorarlo, adattandolo alla domanda o per risolvere altre criticità. I servizi di trasporto pubblico dinamici ('para-transit') possono essere regolati in tempo reale per servire gli utenti attraverso percorsi 'many-to-many' che raccolgono gli utenti all'origine del proprio spostamento e li trasportano verso la loro destinazione oppure alla stazione del trasporto pubblico più conveniente. Un siffatto approccio alla partecipazione degli utenti al trasporto pubblico consente a questi ultimi di influenzare la modalità di erogazione del servizio, fornendo maggiore flessibilità al sistema e garantendo lo sviluppo di una progettazione del servizio 'dal basso'. Gli utenti diventano in tal modo partner del progetto e dell'innovazione dei servizi pubblici, mentre partecipano direttamente allo uso di nuovi servizi [27].

4.6. Integrazione con i sistemi di controllo del traffico

I sistemi dinamici di controllo del traffico adattano le strategie di regolazione ai flussi di traffico rilevati in stazioni di monitoraggio generalmente fisse [28]. Il flusso di controllo è monodirezionale e diretto dal monitoraggio del traffico agli attuatori (semafori, pannelli a messaggio variabile). In accordo con le tecniche di controllo a circuito chiuso, le strategie di regolazione possono essere modificate quando l'output osservato si discosta dall'obiettivo di regolazione. Lo sviluppo di sistemi di tracciamento dei veicoli e di informazione agli utenti rende possibile lo sviluppo di strategie di controllo proattive che, monitorando le posizioni individuali dei veicoli e prevedendo i tempi di arrivo alle intersezioni, modificano i tempi di verde dei semafori e indicano a ciascun conducente una velocità consigliata per giungere alla intersezione a valle durante il verde o gli suggeriscono di decelebrare gradualmente se è previsto che il semaforo a valle sarà a rosso per un tempo relativamente lungo.

Inoltre, in una forma di interazione più avanzata, il sistema di informazione può invogliare i conducenti ad

his/her needs. Similarly, it might suggest alternative activities between different segments of the trips to optimize users' agenda. A key issue of the mobility as a service is to decouple mobility choices to ownership of a vehicle. Since mobility is a secondary need conditioned to fulfil a primary need (work, study, shopping, personal duties, leisure), it is important that mobility as a service be approached by considering the overall set of personal activities. Thus, the approach to 'mobility as a service' implies that the use of a car should be just one of possible alternatives and that individual's mobility choices depend on the opportunities provided by each different alternative with reference to the specific patterns of daily activities, behavioural preferences and personal motivations of the user, including health, attitudes to social interactions and security issues.

4.5. Users' participation

Social networks are an extraordinary product of the ICT deployment that allows users interacting and exchanging information with them. In the transport system, social networks are a parallel way to collect and distribute information on the transport system features like overall quality, cleanliness, delays, crowdedness, and timeliness. Users can detect transport service quality both directly by communicating their personal opinion and indirectly being tracked during their trip. Unlike car traffic, in which travellers using the same route can share information about possible congestion but do not act directly to reduce it, transit service can be improved if the information collected by the travellers is provided to the transit agency. In fact, transit service can be adapted to travel demand. The frequency of scheduled transit services can be increased to serve higher peaks of demand or reduced in the contrary case of fewer users. Dynamic public transport services like so-called paratransit can be adapted in real-time to serve the users in many-to-many transport services where users are collected at their origins and transported to either their destination or a suitable transit station.

In such an approach to users' participation to public transport, users should be empowered to influence the service, which will give flexibility to the system and foster bottom-up development. They can become partners in the design and innovation of public services and entrepreneurs in the exploitation of new services [27].

4.6. Integration with traffic control systems

Dynamic traffic control systems adapt regulation strategies to traffic flows detected at fixed monitoring stations [28]. The control loop is one-way and directed from the traffic monitoring to the traffic actuators, which determine drivers' rights of way. According to feedback control, regulation strategy can be adjusted when the observed output deviates from the regulation objective.

Deployment of individual vehicles tracking and traveller information systems makes it possible to develop proactive

avere un comportamento cooperativo e formare plotoni compatti, così da realizzare configurazioni di traffico che possano sfruttare la capacità stradale di arterie stradali sincronizzate in maniera più efficiente, servendo flussi di traffico più elevati con migliori livelli di servizio. Al tempo stesso, il sistema di regolazione può modificare dinamicamente la banda di verde in funzione del numero di veicoli in arrivo a ciascun approccio. Una volta definita la banda di verde, i conducenti possono essere informati direttamente sulla velocità da mantenere per rientrare nel verde alle intersezioni. Il sistema può essere progettato naturalmente per riconoscere i veicoli dotati di priorità e modificare l'inizio o la fine del verde per servirli.

I sistemi di comunicazione veicolo-veicolo (identificati in genere con la sigla V2V), oggi in fase avanzata di sviluppo consentono ai veicoli di comunicare tra loro. È così possibile applicare tecniche di monitoraggio del traffico [29] e di rilevamento automatico degli incidenti [30] e attivare strategie di guida cooperativa al fine di mantenere una velocità di crociera coerente con la distanza di sicurezza. In futuro, la comunicazione tra veicoli attraverso protocolli V2V consentirà di regolare la precedenza alle intersezioni senza semafori fissi: i veicoli potranno negoziare la precedenza scambiandosi messaggi che contengono la posizione, la velocità, la direzione del viaggio e altri possibili informazioni riguardanti lo spostamento. La logica di regolazione assegna la precedenza a ciascuno dei possibili veicoli in arrivo, preservando per quanto possibile le opportunità di progressione dei veicoli senza essere fermati alle intersezioni a valle. In tal modo, la logica di regolazione dovrebbe conformarsi a schemi di controllo globale che tengano conto degli stati di traffico delle altre intersezioni e delle configurazioni di traffico veicolare nell'area circostante.

5. Conclusioni

In questa memoria sono state presentate e discusse alcune opportunità offerte dai 'Big Data' per sviluppare modelli e servizi innovativi di trasporto e ne sono state esposte le principali problematiche, con riferimento all'aggregazione dei dati, al livello di significatività delle misure e alla variabilità intrinseca del fenomeno.

Sono stati presentati i risultati di alcune analisi sperimentali eseguite su una base di dati costituita da circa 100 milioni di posizioni e di velocità raccolte per un mese nella città di Roma. Da questa analisi sono state tratte le seguenti conclusioni riguardanti la variabilità dei dati e, conseguentemente, il livello di accuratezza desiderato:

- tra un giorno e l'altro della settimana, il coefficiente di variazione delle velocità è mediamente compreso tra il 3,5% e il 5%, con riferimento ai soli giorni feriali;
- il coefficiente di variazione inter-veicolare della velocità, misurato sull'intera rete e per l'intero intervallo di rilevazione, è pari al 23% della velocità media, ma si riduce significativamente in presenza di congestione.

control strategies that monitor individual vehicle positions and predict arrival times at intersections, adjust the green at signals and supply each driver with the information about the suggested speed to arrive at the intersection during the green or the advise to decelerate gently up to the stop line because the signal will be red for a relatively long time. Drivers can be pushed to have a cooperative behaviour and form compact platoons, so realizing traffic patterns that can be more easily served with synchronized signals and exploit the road capacity more efficiently. Higher traffic volumes can be served with better levels of service.

Green bandwidth can be adapted dynamically and drivers can be advised to keep the speed that allows them to stay within it. The system can be designed to recognize priority vehicles and adjust the start or the end of green to serve them.

Forthcoming Vehicle-to-Vehicle (V2V) communications systems allow vehicles to communicate with them. In such a way, it is possible to develop new monitoring strategies to estimate the current traffic states [29] and automatic incident detection [30] as well as activate cooperative driving in order to keep safe distance. In the future, communication between vehicles through V2V protocols would make it possible to regulate right of way at intersections without fixed signals. Vehicles can negotiate the right of way by exchanging messages containing position, speed, travel direction, vehicle type and other possible information about the trip. The regulation logic that assigns right of way to one of the several possible competing vehicles should preserve the opportunities of vehicles for progression without being stopped at downstream intersections. Thus, the regulation logic should refer to global control schemes that take into account the traffic states of the other intersections and the patterns of vehicular traffic moving within the surrounding area.

5. Conclusions

The paper presented and discussed some opportunities offered by the 'Big Data' to develop innovative models and services for transport and examined the main issues, with reference to the aggregation of data, the significance level of the measures, and the inherent variability of the mobility phenomenon.

The results of several experimental analyses have been presented by using a dataset of about 100 million individual positions and speeds collected during one month in the town of Rome. The following conclusions have been derived from these analyses concerning the variability of the data and, consequently, the desired accuracy level:

- the coefficient of variation of the speed among different weekdays ranges between 3.5% and 5%;*
- the coefficient of variation of the inter-vehicle speed, computed over the whole road network and for the whole observation interval, is 23% of the average speed, but it reduces significantly in case of congestion.*

Sono stati inoltre presentati i risultati di alcune applicazioni volte a individuare le condizioni di congestione più critiche sulle arterie stradali della città di Roma e a prevedere le condizioni di traffico nel breve termine. Al riguardo, sono stati presentati due modelli di previsione che, applicando un'architettura a stella doppia, colgono le correlazioni tra archi stradali contigui. I due modelli hanno fornito risultati paragonabili, con errori percentuali assoluti dell'ordine dell'11% per una rete bayesiana con stima a priori SARMA e del 12% per una rete neurale 'feedforward'.

Infine, sono state descritte e commentate alcune possibili applicazioni di Big Data finalizzate a realizzare servizi di trasporto più flessibili, con una maggiore partecipazione degli utenti, con più integrazione tra informazione e controllo.

The results of several applications were presented aimed at identifying the most critical congestion conditions on the road arteries in the town of Rome and at performing short-term traffic predictions. On this regard, two prediction models were introduced that apply a double star architecture to capture the correlation among neighbour road links. The two models exhibited similar performances: mean absolute percentage errors as 11% for a Bayesian network with a priori estimation computed by a SARMA model and as 12% for a feed forward neural network.

Finally, possible applications of Big Data were discussed that aim at developing more flexible transport services, a wider users' involvement through crowdsourcing, and a closer integration between information and control

BIBLIOGRAFIA - REFERENCES

- [1] PROVOST F. & FAWCETT T. (2013), *Data Science and its Relationship to Big Data and Data-Driven Decision Making*. Big Data. February 2013, 1(1), pp. 51-59. <https://doi.org/10.1089/big.2013.1508>.
- [2] CHEN M., MAO S., & LIU Y. (2014), *Big data: A survey*. Mobile networks and applications, 19(2), 171-209.
- [3] SUTHAHARAN S. (2014), *Big data classification: Problems and challenges in network intrusion prediction with machine learning*. ACM SIGMETRICS Performance Evaluation Review, 41(4), 70-73.
- [4] WARD J.S., & BARKER A. (2013), *Undefined by data: a survey of big data definitions*. arXiv preprint arXiv:1309.5821.
- [5] CASTRO-NETO M., JEONG Y.-S., JEONG M.-K., HAN L.D., 2009, *Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions*. Expert Syst. Appl. 36, 6164–6173. <http://dx.doi.org/10.1016/j.eswa.2008.07.069>.
- [6] HERRERA J.C., WORK D.B., HERRING R., BAN X. (JEFF), JACOBSON Q., BAYEN A.M., 2010, *Evaluation of traffic data obtained via GPS-enabled mobile phones: TheMobile Century field experiment*. Transp. Res. Part C Emerg. Technol. 18, 568–583. doi:10.1016/j.trc.2009.10.006.
- [7] BUCKNELL C., HERRERA J.C., 2014, *A trade-off analysis between penetration rate and sampling frequency of mobile sensors in traffic state estimation*. Transp. Res. Part C Emerg. Technol. 46, 132–150. <http://dx.doi.org/10.1016/j.trc.2014.05.007>.
- [8] ZHU S., & LEVINSON D. (2015), *Do people use the shortest path? An empirical test of Wardrop's first principle*. PloS one, 10(8), e0134322.
- [9] COLOMBARONI C. & FUSCO G. (2014), *Artificial neural network models for car following: experimental analysis and calibration issues*. Journal of Intelligent Transportation Systems, 18(1), 5-16.
- [10] CIPRIANI E., NIGRO M., FUSCO G. & COLOMBARONI C. (2014), *Effectiveness of link and path information on simultaneous adjustment of dynamic OD demand matrix*. European Transport Research Review, 6(2), pp. 139-148.
- [11] DENG W., LEI H., ZHOU X., 2013, *Traffic state estimation and uncertainty quantification based on heterogeneous data sources: a three detector approach*. Transp. Res. Part B Methodol. 57, 132–157. <http://dx.doi.org/10.1016/j.trb.2013.08.015>.
- [12] FUSCO G., COLOMBARONI, C., ISAENKO, N. (2016a), *Short-term speed predictions exploiting Big Data on large urban road networks*. Transportation Research Part C: Emerging Technologies, 73, 183-201.
- [13] DE LA BARRA T., PEREZ B., & ANEZ J., *Multidimensional path search and assignment*. In PTRC Summer Annual Meeting, 21st, 1993, University of Manchester, United Kingdom.
- [14] WATLING D.P., & CANTARELLA G.E. (2015), *Model representation & decision-making in an ever-changing world: the role of stochastic process models of transportation systems*. Networks and Spatial Economics, 15(3), 843-882.

- [15] MAHMASSANI H. AND JAYAKRISHNAN R. (1991), *System Performance and User Response under Real-Time Information in a Congested Traffic Corridor*, Transportation Research Part A, 25(5), 293-307.
- [16] FUSCO G., COLOMBARONI C., COMELLI L., ISAENKO N. (2015), *Short-term traffic predictions on large urban traffic networks: Applications of network-based machine learning models and dynamic traffic assignment models*, in: 2015 International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS). IEEE, Budapest, Hungary, pp. 93–101. doi:10.1109/MTITS.2015.7223242.
- [17] FUSCO G., COLOMBARONI C., GEMMA A. & LO SARDO S. (2013), *A quasi-dynamic traffic assignment model for large congested urban road networks*, International Journal of Mathematical Models and Methods in Applied Sciences, 7 (4), pp. 341-349.
- [18] MAHMASSANI H., ZHOU X., QIN X., & LU C-C. (2004), *DYNASMART-X User's Guide and Programmer's Guide*.
- [19] AHMED M.S., COOK A.R. (1979), *Analysis of freeway traffic time-series data by using Box-Jenkins techniques*. Transp. Res. Rec., 722, 1–9.
- [20] FUSCO G., GORI S. (1996), *The Use of Artificial Neural Networks in Advanced Traveler Information and Traffic Management Systems*, in: Proceedings of the 1995 4th International Conference on Applications of Advanced Technologies in Transportation Engineering. ASCE, New York, NY, United States, Capri, Italy, pp. 341–345.
- [21] DOUGHERTY M.S., COBBETT M.R. (1997), *Short-term inter-urban traffic forecasts using neural networks*. Int. J. Forecast. 13, 21–31. doi:10.1016/S0169-2070(96)00697-8.
- [22] SUN S., ZHANG C., YU G. (2006), *A Bayesian network approach to traffic flow forecasting*. IEEE Trans. Intell. Transp. Syst. 7, 124–132. doi:10.1109/TITS.2006.869623.
- [23] FUSCO G., COLOMBARONI C., ISAENKO N. (2016b), *Comparative analysis of implicit models for real-time short-term traffic predictions*. IET Intell. Transp. Syst. doi:10.1049/iet-its.2015.0136.
- [24] LV Y., DUAN Y., KANG W., LI Z., WANG F. (2015), *Traffic Flow Prediction with Big Data: A Deep Learning Approach*. Intell. Transp. Syst. IEEE Trans. 16, 865-873. doi:10.1109/TITS.2014.2345663.
- [25] SANGER T.D. (1989), *Optimal unsupervised learning in a single-layer linear feedforward neural network*. Neural networks, 2(6), pp. 459-473.
- [26] FUSCO G., COLOMBARONI C., ISAENKO, N. (2017), *Dynamic Traveler Information Systems*, in FUSCO G. (Ed.): *Intelligent Transport Systems (ITS): Past, Present and Future Directions*, Nova Science, New York.
- [27] FILIPPI F., FUSCO G., NANNI U. (2013), *User Empowerment and Advanced Public Transport Solutions*. Procedia - Social and Behavioral Sciences, Volume 87, pp. 3–17.
- [28] DALLA CHIARA B., DEFLORIO F. & CARBONI A. (2017), *Basic technologies for ITS and applications: the present and future of traffic and vehicle monitoring*, in FUSCO G. (Ed.): *'Intelligent Transport Systems (ITS): Past, Present and Future Directions'*, Nova Science, New York.
- [29] DE FELICE M., BAIOCCHI A., CUOMO F., FUSCO G., & COLOMBARONI C. (2014), *Traffic monitoring and incident detection through VANETs*. In 11th IEEE Annual Conference on Wireless On-demand Network Systems and Services (WONS), pp.122-129.
- [30] BAIOCCHI A., CUOMO F., DE FELICE M., & FUSCO G. (2015), *Vehicular ad-hoc networks sampling protocols for traffic monitoring and incident detection in Intelligent Transportation Systems*. Transportation Research Part C: Emerging Technologies, 56, 177-194.