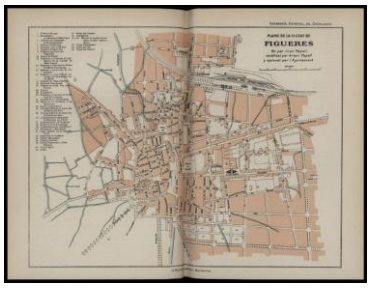

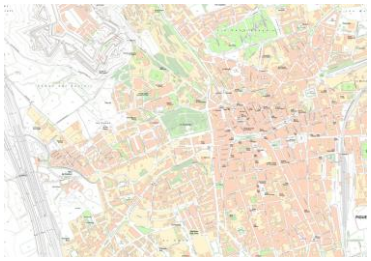

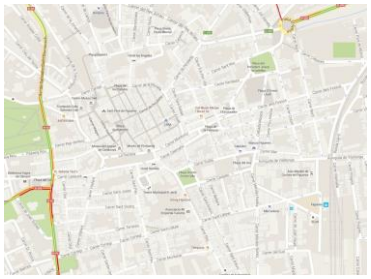

Anàlisi de les dades del trànsit urbà amb sensors de superfície. El cas de Figueres

Figueres, Smart Traffic

Universitat de Girona

INSTITUT d'INFORMÀTICA i APLICACIONS

Smart Cities Master

TFM Smart Cities – UdG
Setembre 2016
Federico Luque i Carrillo
Directora: Dra. Beatriz López

[Aquesta pàgina va ser deixada en blanc intencionadament]

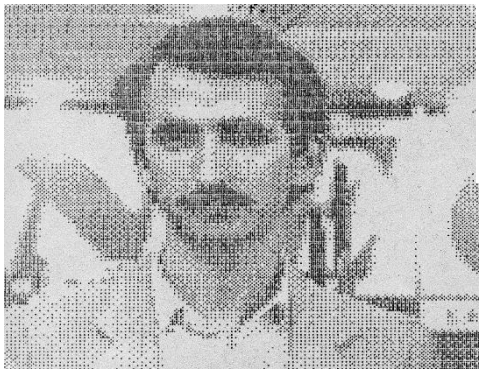

Any 1984: l'autor en una de les primeres captacions comercials de fotografia digital i impressió amb impressora matricial

Antes de Turing se hacian cosas con números;
después de él, los números empezaron a hacer cosas.
La catedral de Turing. George Dyson (pag. 352)

[Aquesta pàgina va ser deixada en blanc intencionadament]

Resum

La presa de decisions en la gestió de la mobilitat d'una ciutat intel·ligent es fonamenta en l'assessorament de l'estat actual del trànsit de la ciutat basat en dades objectives. En aquest treball, es presenta el cas d'estudi de la ciutat de Figueres: s'analitzen les dades procedents d'un conjunt de sensors instal·lats en un àrea urbana àmplia de la ciutat, i es construeixen models predictius de trànsit. Gràcies a aquest estudi, els tècnics d'urbanisme i mobilitat podran saber si els plans que han implementat estan funcionant, o si can fer noves intervencions. El treball està organitzat de la següent manera: en primer lloc es fa una introducció de la situació de l'Smart Mobility bàsicament a escala europea i es situa a Figueres en el seu context d'habitants i parc mòbil. Seguidament es mostra l'oportunitat d'innovació, definint el problema que es vol abordar a partir d'antecedents, i concretat el problema de les dades. A continuació es proporciona un estat de l'art de les diverses tecnologies físiques i de programari utilitzades. Després es fa una descripció de la innovació: selecció i visualització de dades, i anàlisi d'un conjunt de dades delimitats a unes dates concretes i que facin referència només al volum de trànsit d'un determinat conjunt de sensors. Aquesta anàlisi habilita el càlcul de la predicció del volum de trànsit. S'utilitza l'aplicació R per obtenir uns resultats que són posteriorment discutits. Finalment es descriuen unes conclusions i es proporcionen les referències que s'han fet servir en aquest treball.

Paraules clau: SmartCity, mobilitat, ciutat, Figueres, trànsit, sensor, dades, anàlisi, informació, flux, velocitat, estadística, DataMining, visualització, predicció, sostenible.

Per raons de confidencialitat, s'han suprimit els noms de les empreses i els noms dels productes comercials implicats en l'estudi per un nom genèric.

Abstract

Decisions making in smart cities mobility management is based on the advice of the current state of city transit based on objective data. In this paper, the case of Figueres city is presented: we analyze data coming from a group of sensors installed in a big urban area of the city and we create predictive transit models. Thanks to this study, urban and mobility technicians will be able to know if their current actions are working properly or, on the contrary, they should do other procedures. The present paper is organized as follows: on first place, we find an introduction of Smart Mobility situation in Europe and we place Figueres in its context. To continue, the opportunity of innovation is shown by defining the problem we would like to solve based on precedents and specifying the data problem. We continue with the state of the art of technologies and software used and we describe the innovation: selection and visualization of data, analysis of a group of data delimited on specified dates which are referred only to a volume of transit of a certain group of sensors. This analysis enables the calculation of transit volume prediction. R software has been used in order to obtain results which will be discussed afterwards. Finally, conclusions are described and references which have been used are provided.

Keywords: SmartCity, mobility, town, Figueres, traffic, sensor, data, analysis, information, flow, speed, statistics, DataMining, visualization, forecast, sustainable.

For confidentiality reasons, they have been deleted company names and names of commercial products that participate in the study by a generic name.

Reconeixements

M'agradaria donar les gràcies i el meu agraïment a la meva directora d'aquest treball, la Dra. Beatriz López, per la seva paciència i la seva dedicació per donar-me pautes per millorar aquest treball.

També vull donar les gràcies al meu tutor de pràctiques de l'ajuntament de Figueres, el senyor Josep Caimel, per donar-me totes les facilitats d'accés a informació que m'ha permet elaborar molts detalls d'aquest treball.

A tots els professors i companys d'aquest màster amb els quals ha hagut sempre una bona relació.

I especialment a la meva dona, la Carmen, i els meus fills, la Carmina i en Frederic, per aguantar durant tot el curs aquesta situació excepcional i pels recolzaments que m'han donat.

Federico Luque, setembre de 2016

ÍNDEX

1 INTRODUCCIÓ 1
1.1 Control del trànsit. Els projectes europeus. 3
1.2 La ciutat de Figueres 4
1.3 El parc mòbil de Figueres 5
1.4 Objecte d'aquest estudi 6
2 DEFINICIÓ DEL PROBLEMA: OPORTUNITAT D'INNOVACIÓ 8
2.1 El cas de Figueres. Antecedents 8
2.2 Infraestructura del sistema de control de trànsit per sensors a Figueres 10
2.3 Les dades de trànsit a Figueres 14
2.4 El trànsit urbà. El problema de les dades 15
3 ESTAT DE L'ART 17
3.1 Models de trànsit 17
3.2 Sistemes de sensors 18
3.2.1 Tecnologies intrusives 18
3.2.1.1 Magnetòmetres encastats 20
3.2.1.2 Mànega pneumàtica 20
3.2.1.3 Llaços inductius 20
3.2.1.4 Altres sistemes 21
3.2.2 Tecnologies no intrusives 21
3.3 Programari de tractament i d'anàlisi de dades 22
3.4 Programari de representació geogràfica: 26
4 DESCRIPCIÓ DE LA INNOVACIÓ 28
4.1 Selecció de dades 30
4.2 Creació dels fitxers de dades 31
4.2.1 Anàlisi i visualització de les dades 31
4.3 Preparació de les dades 39
4.4 Anàlisi de les dades 40
4.5 El PHF (Peak Hour Factor) 52
4.6 Predicció del volum de trànsit 53
5 RESULTATS 116
6 CONCLUSIONS 124
7 REFERÈNCIES 126

[Aquesta pàgina va ser deixada en blanc intencionadament]

1 INTRODUCCIÓ

La mobilitat, de persones i mercaderies, ve relacionada amb la història de la humanitat. El flux d'aquest dos elements ha condicionat el desenvolupament dels pobles i ciutats donant pas a la creació de carrers principals i carrers secundaris que amb el pas del temps han anat canviant la forma i utilització mitjançant el canvi de fisonomia o la creació de normes i lleis. Lewis Mumford (2014) ja sostenia l'any 1961 que la utilització massiva del cotxe a gran escala ha canviat totalment la utilització del temps en les ciutats i per tant la seva fisonomia, el cotxe allunya al ciutadà d'una cultura crítica i de compromís amb el barri i la ciutat ja que ajudava "a fugir i a la desvinculació" i això precisament és el que a totes les ciutats modernes intenten evitar. També Henry Lefebvre (1969), al seu llibre "*El derecho a la ciudad*" va teoritzar sobre els canvis territorials produïts al segle XX i sobre els nous drets relacionats amb la ciutat moderna, l'habitatge i el barri i reivindica la vida quotidiana i la voluntat de formar part i participar a la ciutat. Durant el segle XX hem arribat al màxim d'ús indiscriminat del vehicle de transport bàsicament privat produint tres tipus de problemes, **de contaminació, de trànsit i d'espai**, però això està canviant amb la consciència de les Smart Cities que amb l'ús de les tecnologies de la informació i la comunicació ens permetrà organitzar les ciutats amb desenvolupament més sostenible[1].

Smart City i mobilitat

Les ciutats estan canviant. L'ús de les tecnologies de de informació i la comunicació ens permetrà organitzar les ciutats amb desenvolupament més sostenible.

Per definir el concepte d'Smart City podem agafar la proposta del *Comité Técnico de Normalización de AENOR AEN/CTN 178 "Ciudades Inteligentes"*[2] que diu el següent:

> *"Ciudad Inteligente (Smart City) es la visión holística de una ciudad que aplica las TIC para la mejora de la calidad de vida y la accesibilidad de sus habitantes y asegura un desarrollo sostenible económico, social y ambiental en mejora permanente. Una Ciudad inteligente permite a los ciudadanos interactuar con ella de forma multidisciplinar y se adapta en tiempo real a sus necesidades, de forma eficiente en calidad y costes, ofreciendo datos abiertos, soluciones y servicios orientados a los ciudadanos como personas, para resolver los efectos del crecimiento de las ciudades, en ámbitos públicos y privados, a través de la integración innovadora de infraestructuras con sistemas de gestión inteligente."*

Però Smart City encara és un terme confús ja que no hi ha una definició universalment consensuada, però ens atendrem al que diu la wikipedia en anglès:

[1] Segons diverses fonts està previst que l'any 2050 el 70% de la població mundial visqui a les zones urbanes
[2] http://www.aenor.es/descargasweb/normas/aenor-Spanish-standardization-on-Smart-Cities-CTN-178.pdf

> *"A smart city is an urban development vision to integrate multiple information and communication technology (ICT) solutions in a secure fashion to manage a city's assets – the city's assets include, but not limited to, local departments information systems, schools, libraries, transportation systems, hospitals, power plants, water supply networks, waste management, law enforcement, and other community services. The goal of building a smart city is to improve quality of life by using technology to improve the efficiency of services and meet residents' needs. ICT allows city officials to interact directly with the community and the city infrastructure and* ***to monitor what is happening in the city****, how the city is evolving, and how to enable a better quality of life. Through the use of* ***sensors integrated with real-time monitoring systems****, data are collected from citizens and objects - then processed and analyzed. The information*

Ens interessa aquesta definició perquè fa referència als conceptes i objectius d'aquest document.

Pel que fa a la relació amb les entitats i organismes públics podem fer referència a la Direcció General per a polítiques internes del Parlament Europeu, de gener de 2014, que també es basa en estudis del Dr. Rudolf Giffinger[3] ("*Mapping Smart Cities in the EU*"). Aquest estudi considera que una ciutat és intel·ligent si té com a mínim una iniciativa que abasti un o més dels següents àmbits: **Smart Economy, Smart People, Smart Mobility, Smart Environment, Smart Governance i Smart Living**.

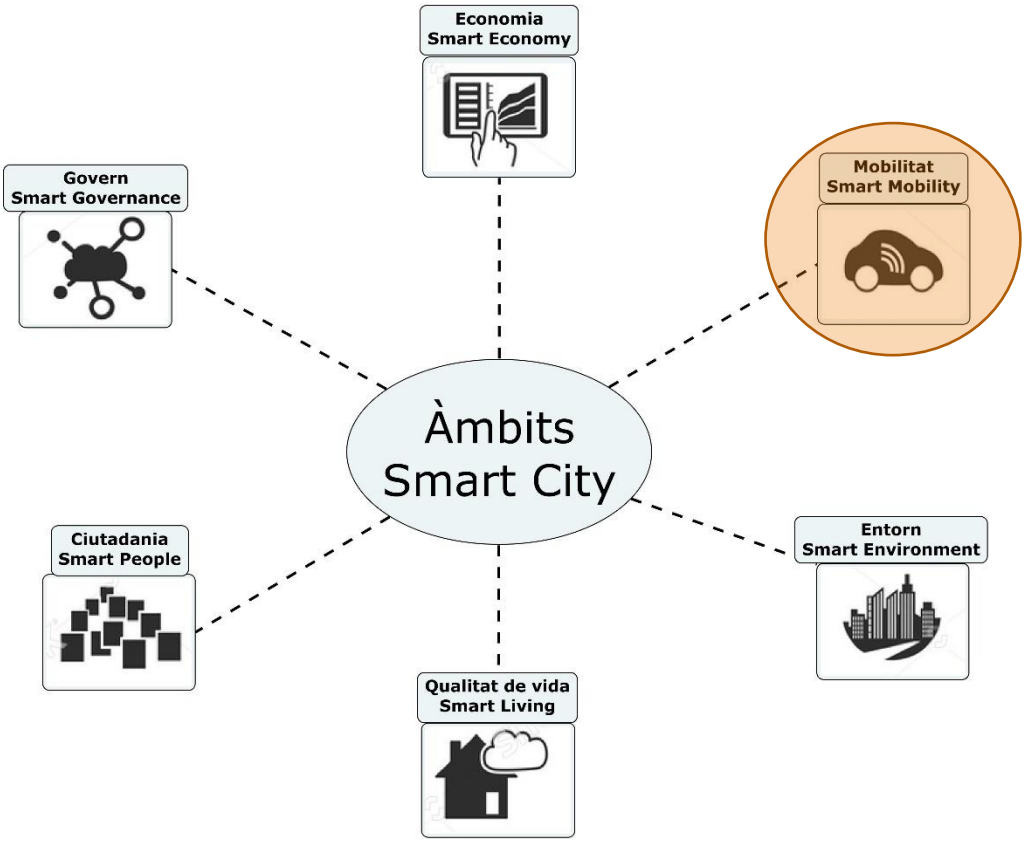

L'àmbit d'estudi d'aquest treball té relació amb la millora de la mobilitat i el transport i l'accessibilitat a la ciutat i podem definir els següents subàmbits: infraestructura viaria, transport i tràfic, aparcament, connectivitat TIC i accessibilitat. L'estudi es concreta en temes de tràfic complementats amb connectivitat TIC que ens permetrà disposar de les dades generades amb la infraestructura de sensors.

[3] http://www.smart-cities.eu/team_1.html

Podem resumir que una Smart City hauria de disposar d'infraestructures que garanteixin els següents paràmetres, que es poden convertir en objectius generals d'aquest treball:

- Un desenvolupament sostenible i millora de la qualitat del medi ambient urbà.
- Una millora en la qualitat de vida dels seus ciutadans.
- Una millora de les condicions d'accessibilitat.
- Una major eficàcia dels recursos disponibles.
- Una participació ciutadana activa.
- Ús i integració de les TIC.

1.1 CONTROL DEL TRÀNSIT. ELS PROJECTES EUROPEUS.

Els Sistemes de Trànsit Intel·ligents (ITS), la seva recerca i desenvolupament d'eines a Europa[4] tenen un origen amb els programes DRIVE[5] I i II i PROMETHEUS[6], bàsicament per les importants inversions que es van fer durant tot el temps de vigència dels projectes (dècada dels anys 90). Després es va continuar amb diversos projectes del "*Transport RTD Programme*"[7] que es troben al dipòsit digital CORDIS[8] i que finalment es van arxivar l'any 2008. Per tenir una visió més detallada de les activitats i investigacions sobre l'àrea de control de vehicles podem llegir l'informe CODE[9] on es parla entre altres temes de l'anàlisi de la situació del trànsit, objecte d'aquest treball.

La mobilitat a la UE

El 60 % dels ciutadans europeus viuen en ciutats de més de 10 000 habitants. La mobilitat urbana representa el 40 % de les emissions de CO_2 i el cost de la congestió urbana és de l'1 % del PIB de la UE.

Tota la informació de la situació actual dels programes i projectes que facin referència al transport urbà la podem trobar a la pàgina de transport de la CE[10]. Hi ha ajudes per a implementar estratègies innovadores, un programa marc de recerca i desenvolupament tecnològic, polítiques de cooperació, programa de gestió d'energies intel·ligent, plataformes i mapes de regulació d'accés urbà, promoció de modes de transport de mobilitat urbana sostenible. Es promou també la setmana europea de la mobilitat del 16 al 22 de setembre de cada any per a promoure i introduir mesures de transport sostenible.

S'ha calculat que més del 60 % dels ciutadans europeus viuen en ciutats de més de 10 000 habitants i que la mobilitat urbana representa més del 40 % de totes les emissions de CO_2 del transport per carretera. El cost de la congestió urbana arriba a l'1 % del PIB de la UE (100 mil milions d'euros). Tot això planteja un problema que s'intenta solucionar en part amb les diverses polítiques de la CE a l'àmbit de la mobilitat urbana. Es va publicar el llibre blanc del transport de l'any 2001, el llibre verd de l'any 2007, el pla d'acció de mobilitat urbana del 2009, la revisió del llibre blanc del 2011 i el paquet de mobilitat urbana del 2013.

[4] http://www.fhwa.dot.gov/publications/research/safety/95153/sec5.cfm
[5] Dedicated Road Infrastructure for Vehicle safety in Europe
[6] PROgramMe for European Traffic with the Highest Efficiency and Unprecedented Safety
[7] http://cordis.europa.eu/transport/home.html
[8] http://cordis.europa.eu/home_en.html
[9] http://cordis.europa.eu/pub/telematics/docs/tap_transport/vehicle.pdf
[10] http://ec.europa.eu/transport/themes/urban/programmes_projects_en.htm

Per tenir una idea del consum energètic per viatger i km segons el sistema de transport triat en aquest gràfic es visualitza clarament que els turismes consumeixen 6 vegades més que qualsevol transport públic.

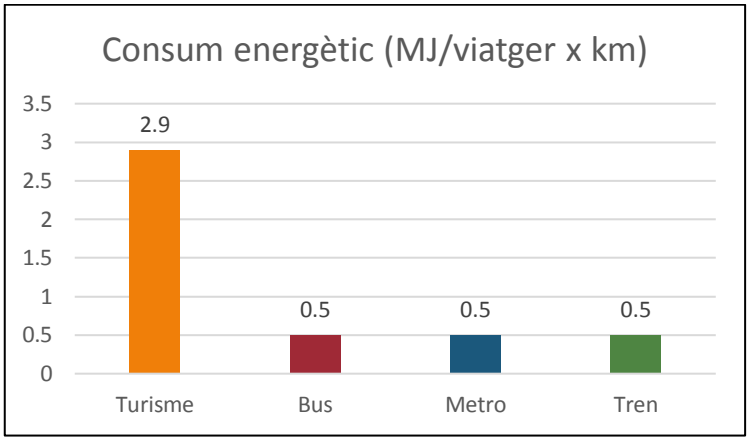

Font: Libro Blanco Smart Cities

1.2 La ciutat de Figueres

La ciutat de Figueres es va guanyar el títol de ciutat intel·ligent quan va començar a treballar amb els organismes internacionals i va fer els seus propis plans per acomplir els objectius. El 10 de febrer de 2009 l'Ajuntament de la ciutat va signar el Pacte dels alcaldes i alcaldesses per aconseguir els objectius energètics i ambientals 20/20/20 pel 2020 que van ser acordats el març del 2007 i ampliat l'octubre del 2015 al nou Pacte de reducció d'emissions del 40% amb límit l'any 2030[11].

Figueres Smart City

Figueres és (PAM):

1. Ciutat creativa i d'oportunitats
2. Ciutat dels detalls
3. Ciutat de les persones
4. Ciutat verda
5. Per una administració més propera, austera i eficient

El desembre del 2012 l'Ajuntament va aprovar el PAM[12] per al quadrienni 2012-2015. Aquest PAM inclou 440 actuacions catalogades en cinc àrees que fan referència a la ciutat i la ciutadania. L'objectiu bàsic és consolidar Figueres com a ciutat creativa i d'oportunitats, que té cura dels detalls i de la sostenibilitat. Els cinc àmbits o àrees d'actuació del PAM, 1) ciutat creativa i d'oportunitats, 2) ciutat dels detalls, 3) ciutat de les persones, 4) ciutat verda i 5) per una administració més propera, austera i eficient, tindran relació amb l'objectiu d'aquest document.

Figueres, capital de la comarca de l'Alt Empordà, és una ciutat que per la seva situació geogràfica és un veritable nus de comunicacions, a prop de tot, pel nord amb la frontera francesa pels Pirineus orientals, per l'est amb la Costa Brava, pel sud mirant les ciutats capitals de Girona i Barcelona i per l'oest relacionada amb les comarques de l'interior. La comarca de l'Alt Empordà és la que té més municipis de tot Catalunya amb 68 en total i per això, degut a la proximitat relativa entre aquets, s'ha definit un conjunt de 16 municipis que forma una àrea urbana amplia més allà dels límits administratius de la pròpia ciutat.

[11] http://www.pactodelosalcaldes.eu/index_es.html
[12] Pla d'Acció Municipal (http://ca.figueres.cat/ajuntament/pla-d-accio-municipal-pam/pam-13862/)

La morfologia de Figueres és de predomini horitzontal i d'escàs pendent. Les alçades del terreny oscil·len majoritàriament entre 10 i 40 metres sobre el nivell del mar.

Figueres té una població força estable des del 2008 coincidint amb la crisi econòmica mundial. Disposa d'una població de 45346 habitants (dades de l'any 2015) i té una superfície de 19,30 km^2 que ens dona una densitat de població de 2350 habitants/km^2. Si volem fer una comparativa amb la ciutat de Girona, capital de la província, sabem que l'any 2015 aquesta ciutat tenia 97227 habitants, més del doble que Figueres, i que la seva superfície és de 39,10 km^2, ens dona una densitat de població de 2496 habitants/km^2, molt similar a la de Figueres.

La mateixa comparativa podem fer entre les respectives comarques per ser el seu territori més proper. L'Alt Empordà té una superfície de 1357,50 km^2 i l'any 2015 tenia 139838 habitants que correspon a una densitat de població de 103 habitants/km^2. Les dades de la comarca del Gironès, una superfície de 575,60 km^2, un total de 184993 habitants l'any 2015 i per tant una densitat de població de 321 habitants/km^2. Observem que hi ha més disparitat entre les dues comarques, una densitat de població al Gironès tres vegades més que a l'Alt Empordà.

Anys	Homes	Dones	Figueres	Alt Empordà
1998	16437	17425	33862	95871
1999	16528	17519	34047	98506
2000	16552	17489	34041	101028
2001	16850	17794	34644	103631
2002	17188	18130	35318	106840
2003	17790	18690	36480	110743
2004	18478	19327	37805	112439
2005	19468	19960	39428	118950
2006	19811	20154	39965	123983
2007	20686	20984	41670	129158
2008	21497	21471	42968	135413
2009	22367	22092	44459	138501
2010	22380	22362	44742	140262
2011	22429	22501	44930	140428
2012	22606	22729	45335	141517
2013	22386	22737	45123	141351
2014	22489	22955	45444	140214
2015	22471	22875	45346	139838

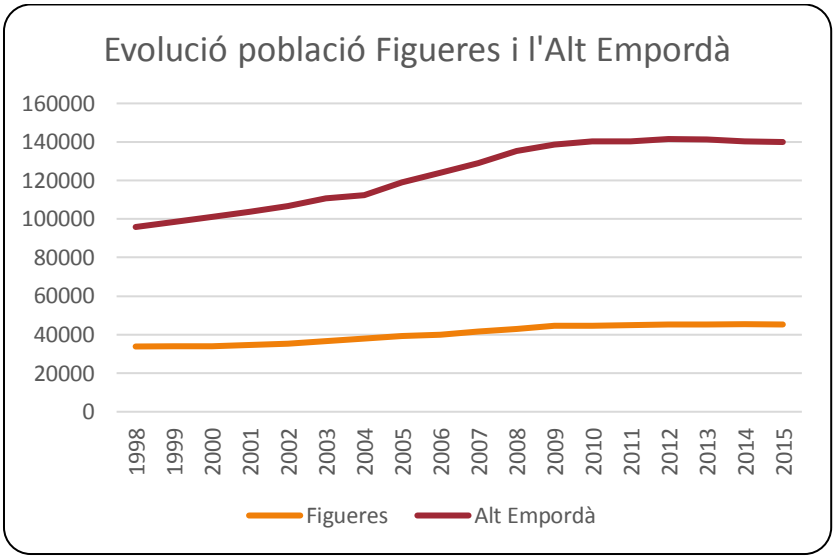

Font: IDESCAT (http://www.idescat.cat/)

1.3 EL PARC MÒBIL DE FIGUERES

La mateixa evolució però amb una petita tendència a la baixa es dona al parc de vehicles considerant només els turismes, les motocicletes, els camions i les furgonetes i descartant els tractors i els autobusos.

Si observem la taula veurem que des de l'any 1997 fins el 2014 (últim any del que disposem dades) hi ha un augment de turismes del 26 % mentre que l'augment de motocicletes durant el mateix període ha sigut del 55,75 %. Aquesta dada pot ser interessant si observem que durant els anys de la crisis el parc de turismes es manté força estable i el de motocicletes té un lleuger augment.

Un indicador, el nombre de vehicles per cada 1000 habitants, ens dona un valor de 464 turismes/1000 habitants però si considerem el total de vehicles tenim un valor de 640 vehicles/1000 habitants. Aquestes dades poden tenir relació indirecta amb l'anàlisi que farem però no és objecte d'aquest estudi.

Anys	Turismes	Motocicletes	Camions i furgonetes	Total
1997	16.721	1.871	4.023	22.615
1998	17.390	1.868	4.146	23.404
1999	18.452	1.992	4.453	24.897
2000	18.214	1.945	4.272	24.431
2001	18.720	1.978	4.358	25.056
2002	18.991	1.996	4.454	25.441
2003	18.840	1.962	4.376	25.178
2004	19.647	2.072	4.533	26.252
2005	20.391	2.312	4.805	27.508
2006	20.868	2.522	5.036	28.426
2007	21.864	2.763	5.300	29.927
2008	21.848	2.860	5.236	29.944
2009	21.713	2.889	5.151	29.753
2010	21.574	2.912	5.041	29.527
2011	21.435	2.892	5.044	29.371
2012	21.414	2.860	5.003	29.277
2013	21.184	2.865	4.941	28.990
2014	21.098	2.914	5.000	29.012

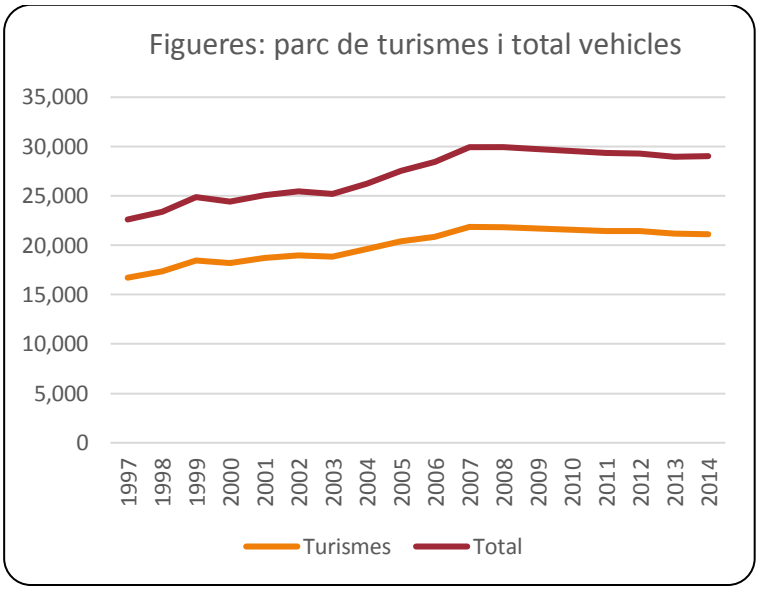

Font: IDESCAT (http://www.idescat.cat/)

1.4 OBJECTE D'AQUEST ESTUDI

Aquest document contribueix al control del trànsit de la ciutat de Figueres, mitjançant l'estudi de la **situació actual de la ciutat de Figueres pel que fa a l'àmbit de Smart Mobility i es farà l'anàlisi i aprofitament de les dades obtingudes per diversos sensors especialitzats de control de trànsit** que es va iniciar la seva implantació l'any 2012 com a prova pilot. Les dades de partida són les que consten al Pla de Mobilitat Urbana del municipi de Figueres, publicat el febrer del 2012[13]. També aprofitarem informació d'altres fonts com ara "Agenda 21. Document de diagnosi municipal[14]", EMQ de Catalunya 2006[15], informació directa de l'empresa municipal de transports FISERSA[16], dades de l'Institut d'Estadística de Catalunya[17], dades meteorològiques de l'estació La Cate de Figueres[18], SIG de l'Ajuntament de Figueres[19], informació d'empreses de serveis i altres.

A partir de l'anàlisi de dades, es proposaran mètodes per fer prediccions de trànsit, que permetin prendre decisions als tècnics de mobilitat de la ciutat.

[13] http://ca.figueres.cat/la-ciutat/medi-ambient-i-sostenibilitat/mobilitat-sostenible/pla-de-mobilitat-16350/
[14] http://ca.figueres.cat/upload/element/mediambient-agenda21-diagnosi.pdf
[15] http://goo.gl/OXUXxJ
[16] http://www.fisersa.es/societats_municipals_transport_urba_linies_i_horaris.aspx
[17] http://www.idescat.cat/emex/?id=170669
[18] http://www.meteofigueres.cat/
[19] http://ca.figueres.cat/la-ciutat/informacio-territorial/mapes-de-la-ciutat/

Libro Blanco Smart Cities

Servicios de innovación y seguridad aplicados al transporte (pág. 37):

- Análisis de los flujos de tráfico, dando prioridad al transporte de emergencias y al transporte público
- Detección automática de las infracciones del código de circulación y los peligros en las carreteras; servicio de información mediante una señalización adecuada e información online de los accidentes producidos en las vías de circulación.
- Desarrollo de modelos matemáticos y simulaciones para poder comparar distintas vías de circulación y distintos escenarios de transporte…
- Implantación de servicios de información online para los ciudadanos mediante Smartphones, dispositivos móviles…
- Sistemas de información online en tiempo real para los ciudadanos, sobre los puntos de recarga para los vehículos eléctricos y las plazas de aparcamiento disponibles para personas con movilidad reducida.

L'objectiu final a partir d'aquest estudi és posar les bases que en un futur ens permetrà **reduir la congestió de tràfic, minimitzar els recorreguts i els temps invertits** pels conductors en els diferents trajectes, **proporcionar eines per a informar en un futur al ciutadà** de la situació del tràfic en temps real i finalment **impulsar el transport públic** així com el desplaçament saludable com anar a peu o en bicicleta. Aquest estudi s'hauria de complementar en un treball futur amb altres que facin referència a una millor gestió dels semàfors i senyals de trànsit en general i altres que facin referència a una millor gestió i informació dels pàrquings tant públics com privats, a l'aire lliure, en edificis o soterrats i amb funcions dissuasives o no.

L'estudi sobre la ciutat de Figueres contribueix al desenvolupament de l'àmbit Smart Mobility que segons el "*Estudio y Guía metodológica sobre Ciudades Inteligentes*"[20], del Ministerio de Industria, Energía y Turismo publicat el novembre de 2015, en la seva pàgina 90 parla d'un grau d'aprofitament d'aquest àmbit en un 27% i un marge de millora d'un 73%.

Aquest mateix estudi a la seva pàgina 196 resumeix en una fitxa la situació actual a Espanya de l'àmbit "*Transporte y tráfico*" i subàmbit "*Control del tráfico*". Els destinataris finals són els ciutadans. Els quatre exemples de ciutats (entre 20000 i 100000 habitants) que apliquen aquesta iniciativa són: **Figueres** (Girona)[21], **Lucena** (Córdoba), **San Sebastián de los Reyes** (Madrid) i **Lorca** (Murcia) i la descripció de la iniciativa té dos punts:

- *"La iniciativa consiste en monitorizar el tráfico en distintos puntos de la localidad. El sistema de monitorización se desarrolla mediante el despliegue de una red de sensores de tráfico y parking, monitorizando y controlando los accesos al centro de la ciudad".*
- *"La información obtenida es transmitida en tiempo real a los ciudadanos a través de paneles informativos".*

Podem trobar objectius genèrics o serveis que tenen incidència als àmbits de la innovació i la seguretat i que es poden aplicar al transport al "*LIBRO BLANCO SMART CITIES*[22]". Aquests objectius tenen relació directa amb el desenvolupament d'aquest treball, destacant els dos principals.

- Anàlisi dels fluxos de trànsit.
- Desenvolupament de models matemàtics per poder comparar entre diverses vies de circulació.

En aquest estudi es donarà prioritat a tot el que faci referència a l'anàlisi de les dades procedents dels diversos sensors implantats a molts carrers de la ciutat de Figueres, centrant-nos exclusivament en dades de trànsit.

[20] https://www2.deloitte.com/content/dam/Deloitte/es/Documents/sector-publico/Deloitt_ES_Sector_Publico_Estudio-sobre-ciudades-inteligentes.pdf
[21] Hi ha un error greu a l'estudi. Situa Figueres a la província de Barcelona
[22] http://www.innopro.es/pdfs/libro_blanco_smart_cities.pdf

2 DEFINICIÓ DEL PROBLEMA: OPORTUNITAT D'INNOVACIÓ

El control del trànsit urbà es pot fer de diverses maneres i amb diverses tecnologies, com veurem més endavant. Qualsevol sistema escollit té les seves avantatges i els seus inconvenients pel que fa a la implantació de la infraestructura que permeti que tot el sistema funcioni amb el mínim d'error, però un cop tot el sistema funciona es generen unes dades que s'han de tractar i analitzar, per poder esdevenir útil en la creació de models per a la presa de decisions, com per exemple els predictius. L'adequació de les dades requereix de models matemàtics i estadístics fonamentalment.

2.1 EL CAS DE FIGUERES. ANTECEDENTS

El 5 d'abril del 2001 es va aprovar el *Consell Municipal de Mobilitat* i es van publicar els seus Estatuts al BOP de Girona núm 130 del 5 de juliol del 2001[23]. L'article 3r parla de l'objecte específic d'aquest Consell i entre d'altres consta la de "*ser escoltat per l'administració municipal, i a petició d'aquesta, en relació a projectes, intencions i propostes sobre la utilització de noves tecnologies, sistemes físics, mecànics i electrònics, etc... així com la senyalització per a la gestió de la seguretat viària, el trànsit i la mobilitat.*"

A partir de la creació d'aquest Consell es van fer alguns estudis de mobilitat. Un d'ells el document de diagnosi municipal Agenda 21, datat al gener de 2003, que ja fa una anàlisi i diagnosi de la mobilitat a la ciutat de Figueres. A destacar la diferència d'un dia feiner d'estiu i d'hivern, essent a l'estiu 150000 viatges amb origen o destinació a Figueres i a l'hivern es redueix a 125000. La diagnosi que fa aquest estudi es resumeixen en aquests punts:

- Una xarxa viària poc jerarquitzada.
- Incidència a Figueres dels desplaçaments des de les poblacions veïnes.
- Progressives millores en el transport públic urbà.
- Una ciutat que hauria de ser amable per al vianant.
- L'ordenació de la mobilitat com a element clau de revitalització del nucli antic.

Aquests cinc punts de la diagnosi encara són plenament vigents, amb més o menys grau.

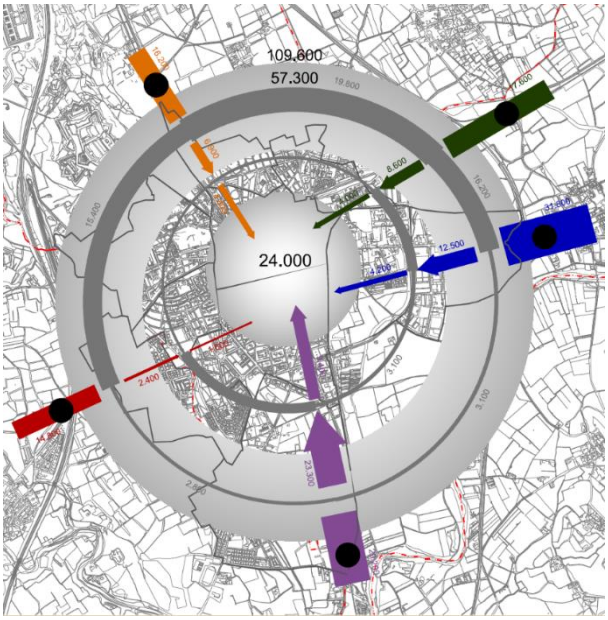

Tornant als Estatuts del Consell Municipal de Mobilitat i considerant l'objecte esmentat de l'article 3r i les funcions que emanen de l'article 5è es va encarregar el Pla de Mobilitat Urbana[24].

Aquest Pla consta de 8 documents i diversos plànols:

- DOCUMENT I: Projecte i contingut del Pla de Mobilitat Urbana.
- DOCUMENT II: Metodologia d'anàlisi de la mobilitat actual a la ciutat.
- DOCUMENT III: Situació actual de la mobilitat a Figueres.
- DOCUMENT IV: Diagnosis de la mobilitat: tendències i escenaris.

[23] http://www.diba.cat/scripts/ftpisa.asp?fnew?cido&bopg/2001/07/20010705/BOPG_20010705_025_026.pdf
[24] http://ca.figueres.cat/la-ciutat/medi-ambient-i-sostenibilitat/mobilitat-sostenible/pla-de-mobilitat-16350/

- DOCUMENT V: Objectius del Pla de Mobilitat.
- DOCUMENT VI: Mesures d'actuació i xarxes proposades.
- DOCUMENT VII: Avaluació de les propostes d'actuació.
- DOCUMENT VIII: Programa d'actuacions i indicadors de seguiment.

Per aconseguir elaborar el Pla de Mobilitat es van fer diversos estudis de camp per completar les següents dades:

- Detecció dels punts d'atracció de viatges (la rambla, els equipaments, escoles i instituts, supermercats, carrers comercials, polígons industrials, etc.).
- Inventari de la infraestructura viària: nombre de carrils i ample, amb actualització de la cartografia existent als nous desenvolupaments.
- Inventari de la infraestructura d'estacionaments públics: tipus, gestió, nombre de places, etc.
- Inventari d'estacionament en carrer, en aparcaments col·lectius i en edificació.
- Organització de la circulació: sentits i semaforització (ubicació, fases i cues)
- Trànsit: velocitat mitjana, nivell de servei, etc.
- Mobilitat de vianants: recorreguts principals i intensitats, camins escolars...
- Conflictes entre modes: indisciplina del vehicle particular, punts de conflicte amb el vianant, adequació de les parades de bus.

Tots aquests estudis es visualitzen en mapes representatius: recorreguts dels vianants, amplada de voreres, xarxa viaria, sentits de circulació, transport públic, inventari d'estacionament, etc. També es fa en aquest estudi la modelització i simulació de dades amb programes informàtics. Aquestes dades són obtingudes mesurant i comptabilitzant manualment.

A grans trets de l'estudi podem destacar les següents dades:

- Figueres, en relació al trànsit, té 2 eixos importants, la N-II i l'Eix Pirinenc (N260 – A26)
- Té una població de menys de 50000 habitants (any 2015: 45346 habitants)
- Té alta densitat de trànsit: + de 2 vehicles/habitant-dia
- Cada dia 109600 vehicles accedeixen o surten de la ciutat (>25 vehicles/10 habitants)
- 57000 vehicles són de pas (52,3%)
- 28300 vehicles volen anar a algun barri del voltant del centre de la ciutat (25,7%)
- 24000 vehicles volen anar al centre de la ciutat (22%)
- Índex de mobilitat total: 3,72 viatges/dia

El resum de la diagnosi de l'estudi destaca els següents punts:

- Inadequació del viari d'accés a Figueres
- Inexistència d'una ronda exterior completa
- Excessiva pressió del vehicle particular sobre el centre
- Problemes de dimensionat de la xarxa de carrers
- L'oferta de pàrquings públics és acceptable
- Les freqüències de pas del transport públic són massa baixes
- Poca atenció a l'espai dels recorreguts a peu

La concreció amb indicadors dels objectius del Pla de Mobilitat Urbana destaca una dada que té relació amb aquest estudi, "racionalitzar l'ús del vehicle privat". En aquest sentit es preveu assolir els següents nivells d'ús del transport en cotxe:

- Actual (any de l'estudi 2012): **50%**
- A 6 anys (any 2018): **46%**
- A 12 anys (any 2024): **40%**

Els indicadors finals que es proposen per analitzar l'evolució de la mobilitat són:

- Evolució de la mobilitat detectada per grups de població i distribució modal
- Evolució de les intensitats de trànsit en els carrers de la xarxa bàsica de distribució
- Evolució del percentatge de vehicles pesats i de distribució de mercaderies en aquests punts
- Evolució del nombre d'usuaris de cada línia de la xarxa d'autobusos urbans
- Grau d'acompliment de les freqüències i la regularitat dels busos
- Intensitat d'ús dels itineraris protegits de vianants i de les ciclovies urbanes
- Evolució d'usuaris als aparcaments públics de dissuasió de la penetració al centre i als dels equipaments importants (estacions, hospital, etc.)
- Nombre d'accidents en les diferents xarxes de la ciutat
- Amidaments d'emissions contaminants i consum d'energia als punts de la xarxa de control

Les conclusions del Pla proposa entre altres moltes actuacions la **creació d'un sistema d'informació de mobilitat urbana mitjançant sensors** que ens doni la freqüència, l'ocupació, la velocitat i la grandària dels vehicles en àrees concretes de la ciutat, a més d'obtenir per la mateixa xarxa nivells de contaminació acústica i de gasos.

La necessitat de la creació d'aquest sistema d'informació ve donat per tres grans eixos o problemes urbans de qualsevol ciutat:

- Augment del parc de vehicles dels habitants de la ciutat
- Augment dels vehicles forans que entren a la ciutat
- Congestió d'algunes vies

2.2 INFRAESTRUCTURA DEL SISTEMA DE CONTROL DE TRÀNSIT PER SENSORS A FIGUERES

La ciutat de Figueres disposa d'una infraestructura de control de trànsit amb sensors de superfície situats en punts estratègics. Aquests sensors es complementen amb una xarxa de comunicacions que permet que els senyals arribin als ordinadors centrals de gestió i finalment es pugui aprofitar per l'usuari final.

Tots els sensors donen senyals que es converteixen en dades segons la magnitud física o química que està mesurant i aquestes dades, per separat o en el seu conjunt, ens donaran la informació segons l'anàlisi que es faci d'aquestes dades.

La xarxa simplificada del Sistema Tecnològic Urbà queda reflectida en la següent representació gràfica.

La instal·lació de tot el sistema de control ho fan empreses privades amb els seus productes. El sistema es composa de quatre elements físics:

- **Sensor de trànsit de superfície**: És un dispositiu sense fil que funciona amb bateria, s'integra a l'asfalt i funciona amb la detecció de les variacions del camp magnètic al pas de vehicles, que tenen a la seva composició materials ferromagnètics. Aquests dispositius, un cop incrustats a l'asfalt es cobreixen amb una capa de resina dura i resistent a la intempèrie. En total hi ha instal·lats actualment 77 sensors.

- **Enrutador de xarxa mesh**: És un dispositiu sense fil que funciona amb alimentació elèctrica directa pel que s'ha d'instal·lar en un lloc que tingui a prop una presa de corrent, o bé a la paret o a les faroles. Fa la funció de captar el senyal dels sensors i transmetre aquest senyal a través d'una xarxa mesh (mallada) fins arribar a un concentrador. Podem disposar d'aquests dispositius en distàncies de fins 100 m. La seva estanqueïtat és IP-54 i tenen una alta resistència mecànica. Hi ha un total de 43 dispositius repartits estratègicament i dels quals 26 només fan la funció d'enrutador i la resta a més tenen incorporats altres tipus de sensors com ara de temperatura, de llum i altres.

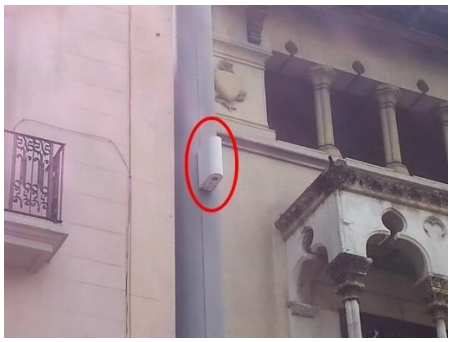

- **Concentrador**: És un dispositiu sense fil que externament té la mateixa forma que l'enrutador. Fa de passarel·la amb configuració d'infraestructura amb els dispositius mesh i transmet els senyal a la base aprofitant diverses interfícies de comunicacions: WiFi, GPRS, 3G o Ethernet, depenent de la disponibilitat més fàcil i econòmica que hagi al lloc de la instal·lació. Hi ha 6 concentradors instal·lats estratègicament als següents llocs:
    - Carrer Tramuntana
    - Plaça el Sol
    - Carrer Col·legi
    - Carrer Sant Llàtzer – carrer Nou
    - Plaça Escorxador
    - Plaça Elíptica

Aquesta xarxa és una aplicació del SIT (Sistemes Intel·ligents de Transports[25]) i ve esquematitzat amb aquest gràfic resum:

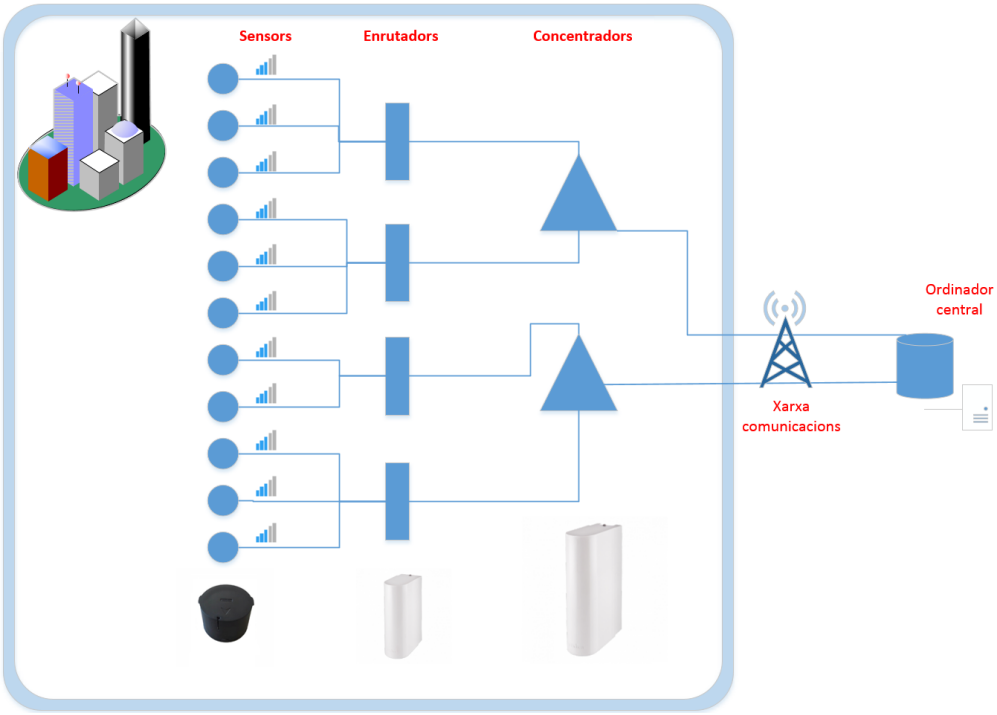

Font: elaboració pròpia

Els 77 sensors de calçada de control de trànsit estan distribuïts en llocs estratègics de la ciutat que d'alguna manera tenen relació amb vies que absorbeixen vehicles d'entrada o de sortida de la ciutat.

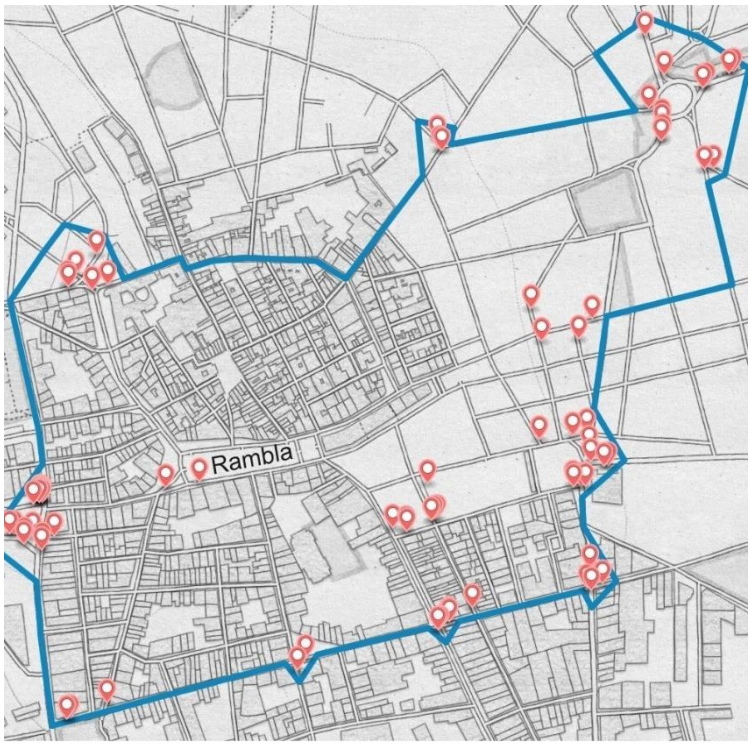

Geolocalització dels 77 sensors de trànsit. Elaboració pròpia

[25] https://es.wikipedia.org/wiki/Sistemas_inteligentes_de_transporte

Amb l'esquema següent es pot tenir una visió més amplia de tot el sistema a partir de la infraestructura, considerant què s'ha de fer amb les dades i marcant l'objectiu final.

Les dades i gràfiques en temps real les tindrem directament de l'aplicació del sistema i són dades en brut que arriben amb només la conversió del senyal en un valor mesurable. A partir de la disponibilitat de dades es podrà fer l'anàlisi que sigui necessari segons els objectius perseguits.

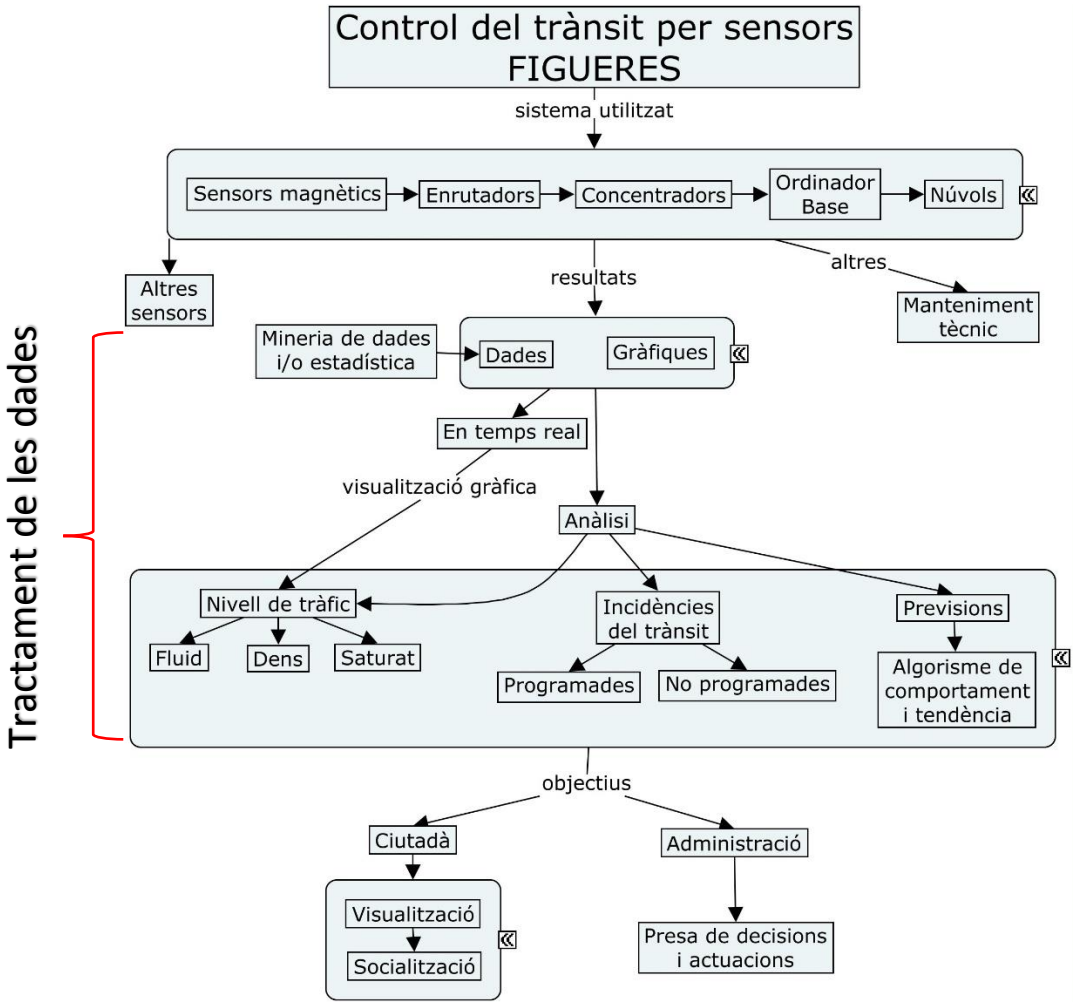

Font: elaboració pròpia

És important fer veure que l'objectiu final principal és l'administració municipal que serà la que, en última instància, prendrà les decisions i farà les actuacions que calguin. Un cop l'administració ho tingui tot controlat tècnicament es pot pensar en un altre objectiu, el ciutadà, que voldrà treure profit d'aquesta despesa dels seus impostos amb informació que pugui ser útil. Les empreses no consten com a objectiu ja que les dades d'aquests tipus d'infraestructures, com d'altres, van lligades a l'Open Data.

2.3 LES DADES DE TRÀNSIT A FIGUERES

Les empreses responsables de la instal·lació disposen d'una plataforma al núvol que, mitjançant usuari i contrasenya, permet accedir a moltes funcions tècniques de manteniment apart d'accedir a totes les dades captades pels sensors.

Les dades d'informació de sensors visualitza la geolocalització de tots els dispositius en un mapa, generalment d'OpenStreetMap. Cada punt és interactiu i ens permet demanar la gràfica en un període concret de temps i importar totes les dades d'aquest període. Seguidament es presenten unes captures d'una aplicació de gestió dels sensors.

Menú general

Zona de cobertura del projecte

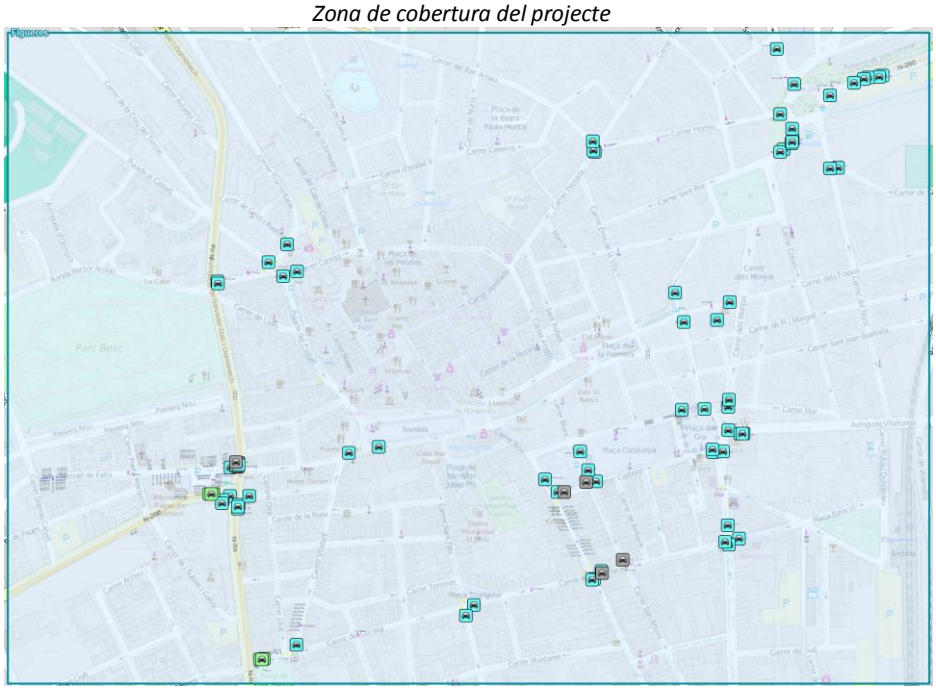

L'aplicació pot subministrar dades de moltes variables. Les dades principals, pel que fa al trànsit, són les de "volum de vehicles", "nivell d'ocupació" i "velocitat mitjana" (aquesta última variable només es pot obtenir amb els sensors dobles nomenats de "carril").

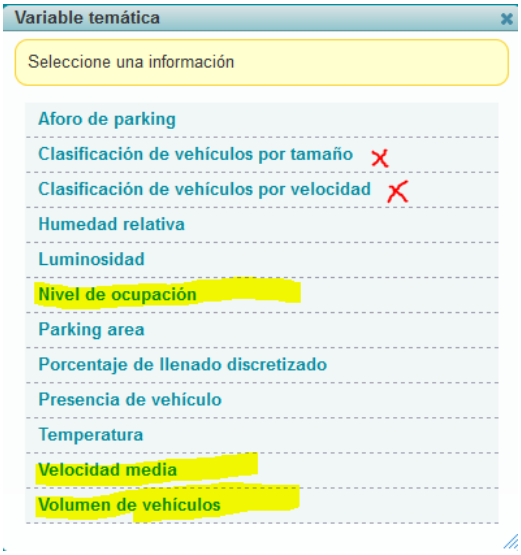

Exemple: volum de vehicles captat per un sensor durant 2 dies

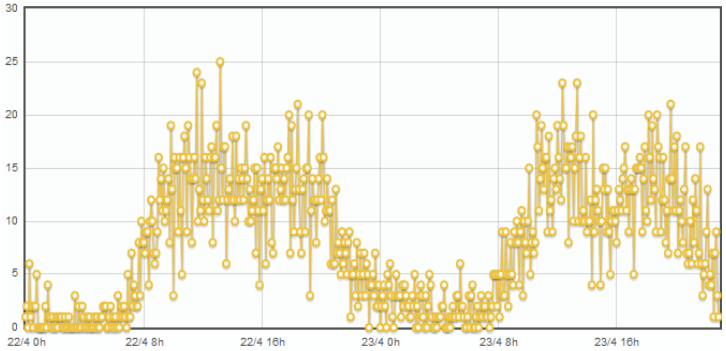

Per observar que la captació i magatzematge de les dades pot tenir errors observem la següent gràfica del sensor nomenat SP-2.1 durant el període de temps que va de l'1 de novembre de 2015 al 30 de juny de 2016. A l'inici de gener de 2016 hi ha mancança de dades i cap a final de febrer del mateix any hi ha una mancança més important. Això pot ser degut a diversos factors essent el principal el mal funcionament de qualsevol punt de la xarxa que porta el senyal des del sensor a l'ordinador central de gestió.

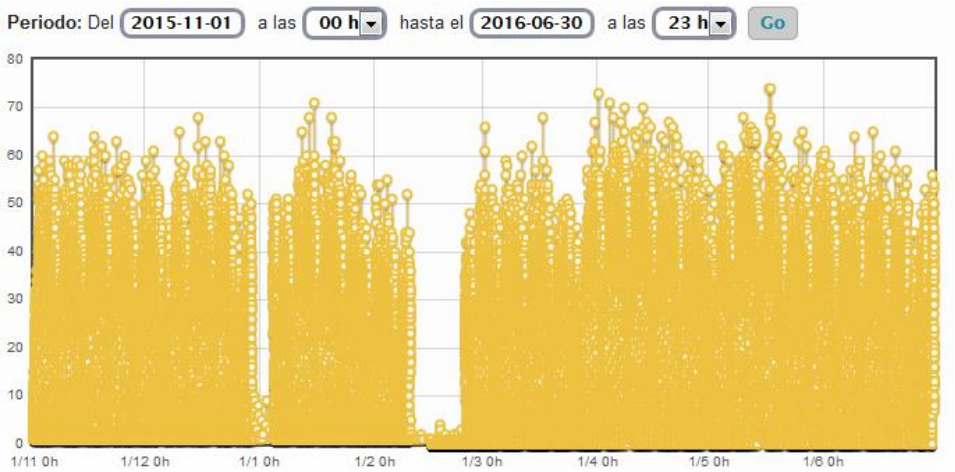

Totes les dades entre períodes es poden descarregar directament en format Excel. Si l'anàlisi de les dades no es fa amb aquest programari es pot exportar a fitxer de text delimitat, tipus CSV, que qualsevol programari d'anàlisi de dades accepta amb importació o lectura directa.

2.4 EL TRÀNSIT URBÀ. EL PROBLEMA DE LES DADES

Primer problema:

Una infraestructura de dispositius tecnològics formada per sensors, xarxa de comunicacions i ordinadors de gestió d'aquestes dades tenen com a objectiu final la conversió dels senyals físics generades a l'origen en dades numèrics o alfanumèrics comprensibles per l'humà. Aquestes conversions las fan uns algorismes que normalment les empreses que implanten les infraestructures no donen a conèixer.

Segon problema:

Els algorismes utilitzats poden esser més o menys correctes i per tant tenir un marge d'error més petit o més gran. L'única manera de resoldre aquest problema és sobre el terreny amb proves pilots i comprovació manual en períodes de temps aleatoris.

Tercer problema:

Les dades generades són necessàriament sèries temporals i per tant s'ha de trobar la unitat de temps idònia, ni massa gran ni massa petita, que ens permeti fer anàlisi i obtenir resultats suficientment realistes.

Quart problema:

La visualització de les dades es pot fer en un instant determinat o en un espai de temps concret però per fer l'anàlisi es necessari disposar de dades històriques. Aquestes dades es van acumulant amb el temps i arriba un moment que no és factible fer l'anàlisi amb eines tradicionals i hem de passar a eines de Big Data.

Model Lighthill-Whitham-Richards (LWR)

Els models de trànsit poden ser macroscòpic, microscòpic i mesoscòpic. Els models macroscòpics consideren el trànsit com un continu.

Segons Prothmann (2011), si considerem un conjunt de vehicles en un temps t i una posició x d'un segment de carrer amb tres variables

- Densitat $\rho(x,t)$
- Velocitat mitjana $V(x,t)$
- Flux de trànsit $Q(x,t)$

La relació ve donada per:

$$Q(x,t) = V(x,t) \cdot \rho(x,t)$$

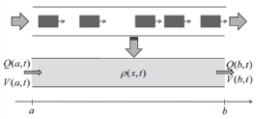

Des d'un punt de vista matemàtic, segons el Dr. Pushkin Kachroo[26] (Kachroo, P. & Sastry, S., 2014), els models macroscòpics de trànsit poden ser de diversos tipus.

- Model Lighthill-Whitham-Richards (LWR)
- Model Payne-Whitham
- Model Aw-Rascle
- Model Zhang
- Altres models …

Tots aquests models es basen en modelat i simulació del trànsit però no és el cas d'aquest treball ja que farem servir dades reals subministrats pels sensors. En aquest treball farem servir eines comuns d'estadística i de mineria de dades.

Segons Ricardo Galli[27], "*l'estadística és una eina fonamental per analitzar i entendre els problemes en un món tan complex com l'actual*".

[26] http://faculty.unlv.edu/pushkin/TrafficFlowTheory.pdf
[27] https://gallir.wordpress.com/

3 ESTAT DE L'ART

El control del trànsit urbà es pot fer de molts diverses maneres essent el més conegut la regulació mitjançant semàfors. A l'inici de la utilització d'aquests sistemes tots els semàfors es posaven en verd o en vermell a l'hora però després es va optimitzar el sistema amb la sincronització i encara s'ha arribat a un punt de sincronització depenent de l'hora del dia. Aquests sistemes molt automatitzats encara no proporcionen ni s'aconsegueix un control òptim a la fluctuació del volum de trànsit (H Kulkarni & G Waingankar, 2007). És per això que s'estan implementant sistemes complementaris de monitorització i control.

Un estudi que combina dos sistemes[28] (Al-Khateeb & A. Y. Johari, 2005) utilitzava sensors que capten informació electromagnètica (RFID) en un creuament de cicle semafòric. La informació d'aquests sensors donarà la lectura de la cua generada a l'últim cicle dels semàfors i enviarà aquesta informació a un servidor remot que mitjançant un algorisme prendrà la decisió més òptima del control semafòric.

La monitorització i control del tràfic urbà a Espanya és avui dia encara un tema incipient, molt localitzat i poc normalitzat. L'explotació comercial està majoritàriament en mans d'empreses privades i per tant l'administració pública dels municipis contracta aquests serveis i haurà de seguir les directius pròpies de l'empresa pel que fa als dispositius, infraestructures i gestió de les dades.

Aquest monopoli del mercat dels Sistemes de Control de Transit Urbà (SCTU) ha provocat des de fa uns anys que la Unió Europea rellanci projectes aplicats als Sistemes de Tràfic Intel·ligent (ITS) com s'ha comentat a la introducció. Aquests sistemes intel·ligents depenen del model de trànsit, del sistema de sensors, i dels programaris utilitzats.

3.1 MODELS DE TRÀNSIT

Per adaptar el màxim possible l'estudi del trànsit a la realitat es poden considerar tres models.

- **Models macroscòpics:** són models continus que consideren totes les variables com a un conjunt global de tot el flux del trànsit (Wageningen-Kessels, Femke van et al. 2014). Per evitar l'ús de complicades fórmules d'equacions diferencials s'establiran relacions empíriques entre les principals variables utilitzades. Per simplificar només fan servir la relació entre dos variables. Al llarg de la història s'han aplicat diversos models macroscòpics.
    - *Model de Greenshields:* model aplicat des de l'any 1931. Considera que si el trànsit és continu existeix una relació lineal entre la velocitat i la densitat.
    - *Model de Greenberg:* Neix del model anterior i aplica una relació logarítmica. És útil per mesurar el trànsit pesant.
    - *Model Underwood:* També de relació logarítmica però aplicat al trànsit lleuger.
    - *Model de Eddie:* combinació dels dos anteriors i aplicats a zones de baixa densitat de trànsit.
- **Models microscòpics:** són models discrets i descriuen el comportament del trànsit a través del comportament de cada element (vehicle). És difícil d'aplicar de forma empírica ja que el comportament de cada conductor és molt variable. Existeix un model de tipus empíric aplicat en aquests casos, el model Gipps, basat en la possibilitat de circular a dues velocitats.

[28] http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.690.9932&rep=rep1&type=pdf

- **Models mesoscòpics:** aquests models es poden definir com a la probabilitat que un vehicle a una determinada velocitat es trobi un cert temps en una determinada posició. Es basa en funcions de distribució de probabilitats que depenen de varies variables.

En aquest treball es farà servir el model macroscòpic Greenshield que permet actualment fer servir la densitat de flux (mitjana de vehicles per unitat de temps) i inclús establir una relació entre el flux i la velocitat.

3.2 SISTEMES DE SENSORS

Podem definir la sensorització com a la captura d'informació simple d'una realitat que volem observar amb detall, mitjançant dispositius que registren esdeveniments físics o químics i que finalment en són processats per obtenir dades que puguin ser manipulats. Aquestes dades podran ser convertits mitjançant sistemes TIC en informació útil per a l'usuari final i a partir d'aquesta informació es podran prendre decisions i donar solucions i serveis per exemple en un entorn de ciutat sostenible.

Els dispositius sensors utilitzats en un entorn Smart City són molts diversos i depenen del tipus de tecnologia, de la dada a observar o de la informació que es vol aconseguir.

Podem considerar que el transport intel·ligent urbà (smart mobility) és aquell que de forma genèrica compleix els següents requisits de mobilitat del ciutadà:

- Millora la qualitat de vida
- Redueix el consum energètic
- Augmenta la sostenibilitat

Si es fa servir un sistema de sensorització es podran complir els tres requisits ja que l'usuari final podrà accedir, en temps real, a la informació sobre el transport públic, congestions o accidents.

La utilització de sensors a nivell de calçada és una tècnica menys sofisticada que altres sistemes com ara la tècnica de visió mitjançant càmeres però és un sistema més econòmic i per tant es pot generalitzar més fàcilment i estendre a un territori més ampli. També s'ha de dir que la tecnologia dels sensors està evolucionant molt ràpidament i ens permet tenir dades de control més precisos i depenent de la infraestructura de comunicacions disposar d'aquestes dades en temps quasi real.

Els sensors de trànsit són tecnologies in situ i poden ser de dos tipus,

- **Tecnologies intrusives**[29]: sensors que s'instal·len en la superfície de la calçada o per sota d'ella i que per tant poden, ocasionalment, provocar interrupció del trànsit durant la instal·lació.
- **Tecnologies no intrusives**: sensors que s'instal·len en la superfície de la calçada o per sobre d'ella i que per tant no provoquen interrupcions significatives del trànsit durant la seva instal·lació.

3.2.1 Tecnologies intrusives

Els sistemes més comuns de configuració de **tecnologies intrusives** són:

- Magnetòmetres encastats
- Mànega pneumàtica
- Llaços inductius

[29] https://www.civil.iitb.ac.in/tvm/1111_nptel/525_AutoLoop/plain/plain.html

El sistema utilitzat en l'estudi de cas d'aquest treball és el magnetòmetre encastat amb tecnologia sense fil incorporada.

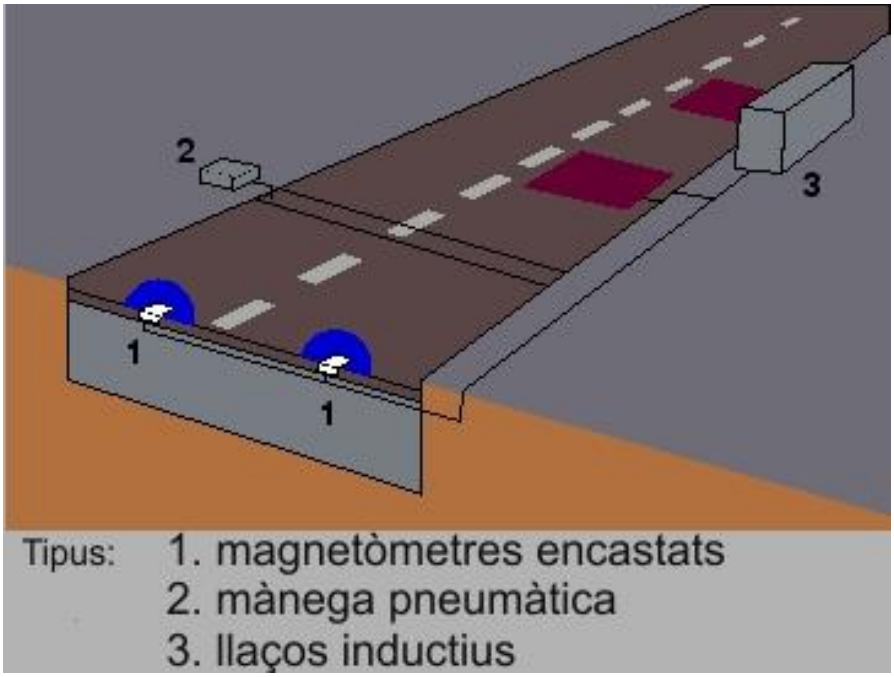

Configuració de detectors intrusius. Font: IMAGINE – Collection Methods for Additional Data

Exemple de sensor de trànsit per encastar. Font: https://goo.gl/CvSe4u

3.2.1.1 Magnetòmetres encastats

Font: http://goo.gl/K4ejmA

Aquests tipus de sensors són magnètics passius i s'encasten permanentment en un forat de cada vial del carrer i finalment s'emplena amb una resina que farà de protecció a la intempèrie. La comunicació amb la unitat base es fa amb fils enterrats o bé amb comunicacions sense fils. En aquest cas s'ha de tenir present que les bateries que porten tenen una durada teòrica de molts anys.
Un únic dispositiu pot mesurar flux (volum de trànsit) i ocupació de la calçada i dos dispositius la velocitat mitjana i la llargària del vehicle.

3.2.1.2 Mànega pneumàtica

Font: http://goo.gl/nplRTq

Són tubs pneumàtics travessant la calçada i actuen amb la pressió del vehicle que passa per sobre. La seva instal·lació és temporal degut a la fragilitat del material que es pot fer malbé amb el pas dels vehicles. S'han de fixar al terra amb algun sistema que no es puguin desplaçar del seu lloc original.
Segons els paràmetres que es volen mesurar s'estiren un o dos tubs, per exemple si només volem comptar vehicles amb un n'hi ha prou però si volem mesurar velocitats necessitem dues mànegues.

3.2.1.3 Llaços inductius

Font: http://goo.gl/AQ0Do0

Aquests sensors funcionen amb la variació del camp magnètic d'un llaç que fa de bobina magnètica encastada al terra. Degut a la seva dimensió no són aptes per diferenciar vehicles d'un o més eixos però sí poden classificar per la llargària del vehicle.
El senyal s'envia a través del cable a una central de procés al costat de la via.
Són sistemes econòmics i de fàcil manteniment.

3.2.1.4 Altres sistemes

- Sensors piezoelèctrics
- Sensors basats en fibra òptica

3.2.2 Tecnologies no intrusives

Hi ha diversos sistemes de **tecnologia no intrusiva**, alguns dels quals són molts recents i per tant poc comuns.

- Detector de vídeo
- Detector d'infrarojos passius o actius
- Detector de radar de microones
- Detector d'ultrasons
- Detector acústic passius
- Detector làser
- Fotografia aèria

Hi ha altres tecnologies no intrusives però no són "**in situ**". Són les nomenades tecnologies "**in vehicle**" o Floating Car Data (FCD). La principal d'aquest tipus és la basada en GPS. Actualment molts vehicles porten incorporat el sistema GPS de navegació i també gran part dels conductor porten a sobre un dispositiu amb el sistema GPS, típicament l'Smartphone. La seva precisió és de menys de 30 m i la seva utilitat és més pràctica en llocs oberts com ara carreteres, autopistes o zones rurals.

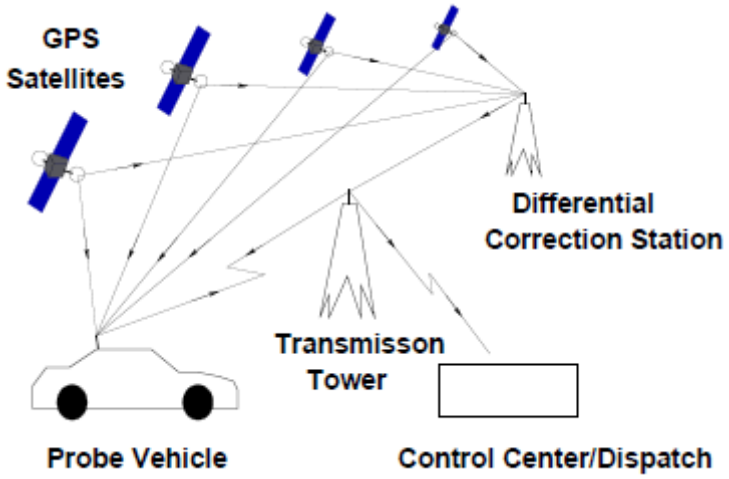

Sistema de comunicacions des del GPS. Font FHWA vehicle detection manual

3.3 PROGRAMARI DE TRACTAMENT I D'ANÀLISI DE DADES

- **SQLite Manager**[30]**:** És un complement gratuït del navegador Firefox de Mozilla que podem afegir com a una icona del menú del propi navegador i que permet gestionar fàcilment bases de dades SQLite. Té un menú propi textual i d'icones. Permet visualitzar de forma jerarquitzada els objectes de la base de dades que treballem. Permet importar des de formats CSV, XML o SQL i també podem exportar qualsevol dels objectes a aquests mateixos formats. Permet visualitzar les dades, veure la seva estructura, fer cerques i afegir, modificar o esborrar registres. Permet executar fàcilment ordres SQL. Aquest programari és l'eina ideal per a gestionar molts registres sense problemes. En aquest treball s'ha fet servir amb taules de quasi 5.000.000 de registres.

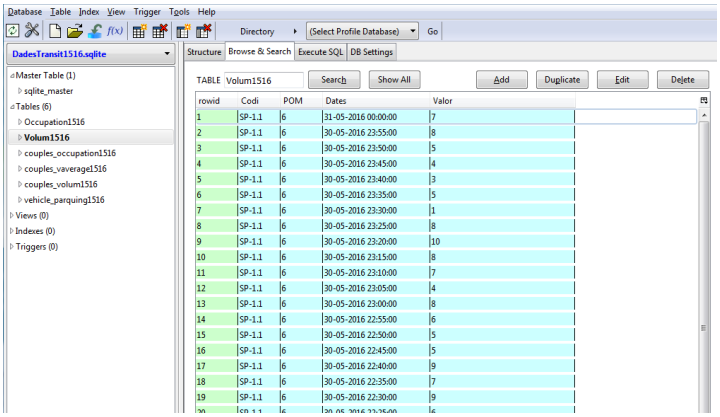

- **Weka**[31]**:** De l'anglès *Waikato Environment for Knowledge Analysis*. És una col·lecció d'algorismes d'aprenentatge ML (*Machine Learning*) i DM (*Data Mining*) desenvolupada a la Universitat de Waikato de Nova Zelanda l'any 1993 i és de codi obert i escrit en Java. Amb aquest programari podem fer preprocessament de dades, visualització, selecció, classificació, clustering, regressió i associació. Permet la lectura de dades ARFF apart de formats CSV, Excel, C45, Matlab, JSON i altres, però s'ha de tenir present que la lectura de text pla CSV és lenta ja que comprova cada línia i no pot tenir qualsevol separador de camp, per exemple no accepta el separador ";". Això és degut a que el fitxer CSV no porta cap informació a la capçalera, al contrari del fitxer ARFF que sí porta informació a la capçalera sobre el contingut de cada camp.

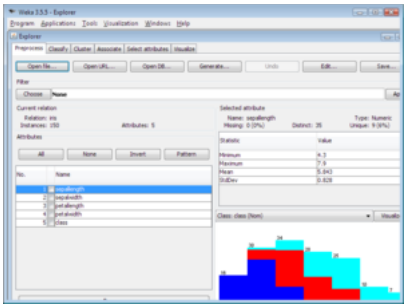

[30] https://addons.mozilla.org/es/firefox/addon/sqlite-manager/
[31] http://www.cs.waikato.ac.nz/ml/weka/

- **KNIME**[32]: *Konstanz Information Miner*. Eina de mineria de dades que permet l'anàlisi en entorn visual mitjançant blocs d'entrada i sortida. Es va desenvolupar a la Universitat de Constanza (Alemanya). Els blocs o nodes són algorismes empaquetats que enllacen amb altres nodes mitjançant fletxes que representen el flux de dades. Els blocs o nodes representen una gran varietat d'accions que podem fer servir sobre una taula de dades de forma molt visual i interactiva. Hi ha la possibilitat d'incorporar directament Weka o codi nadiu d'R.

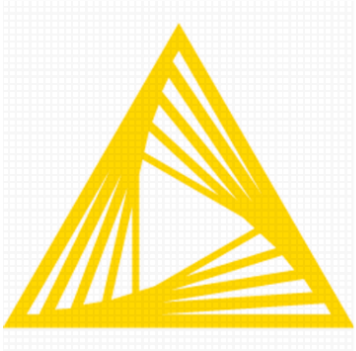

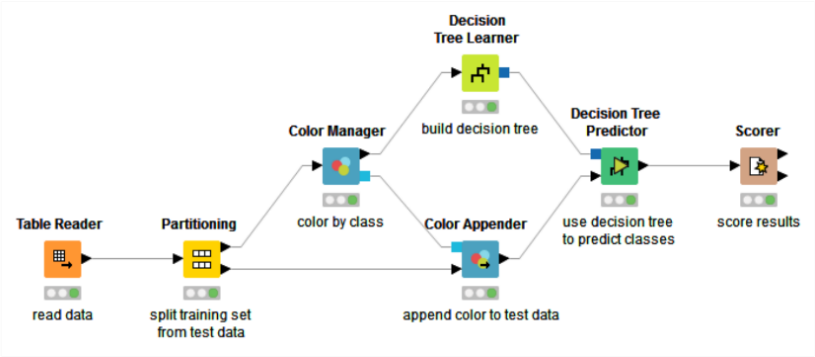

- **R**[33]: R és un llenguatge i entorn per a estadística per ordinador i per a gràfics. Es basa en el llenguatge S de Bell Laboratories (AT&T). R permet una gran varietat de tècniques estadístiques lineals i no lineals, de sèries temporals, de classificació, associació, agrupaments, etc. Permet una manipulació total sobre els paràmetres de totes les seves funcions i per tant podem obtenir un resultat visual d'acord amb les nostres necessitats. Té una gran varietat d'Script o paquets que podem anar carregant d'acord amb el tema que volem treballar. Es pot fer servir en sistemes Linux, Windows i MacOS entre altres.
  El seu entorn de treball original és mitjançant comandos amb R Console però s'han desenvolupat molts paquets o programaris independents que ens permet treballar en un entorn visual, per exemple R Commander[34], RStudio[35] o RKWard[36].

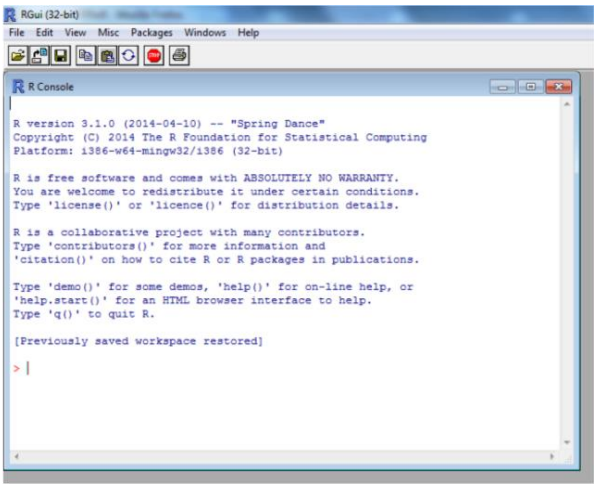

[32] https://www.knime.org/
[33] https://www.r-project.org/
[34] http://www.rcommander.com/
[35] https://www.rstudio.com/
[36] https://rkward.kde.org/

- **Rapidminer**[37]**:** És una eina d'anàlisi de mineria de dades que anteriorment es deia YALE (*Yet Another Learning Environment*) i que va ser desenvolupada per la Universitat de Dormund l'any 2001 i a partir del 2007 va canviar el nom de YALE a RapidMiner. Compta amb una col·lecció de més de 500 operadors o tècniques de pre-processament de dades. Es pot fer servir a través de GUI o mitjançant comandos i s'ha implementat en Java i per tant per fer-ho servir és necessari tenir instal·lat aquest entorn.
  La versió free només permet fins 10.000 registres. La versió de fins 1.000.000 té un cost de 5.000$ per any i la versió sense límits 10.000 $ per any. Hi ha bàsicament dues versions, la versió stand-alone "RapidMiner Studio" i la versió col·laborativa de servidor "RapidMiner Server".
  Integra sense problemes els codis de Weka i permet realitzar ML i DM. Amb els operadors podem fer modelació predictiva i descriptiva, prova de models, visualització de dades i altres funcions.
  Amb Rapidminer es pot importar dades amb diferents formats coma ara ARFF, CSV, C45, Excel, SPSS o a partir de bases de dades SQL de diverses versions, MySQL, PostgreSQL, MicrosoftSQL, etc.

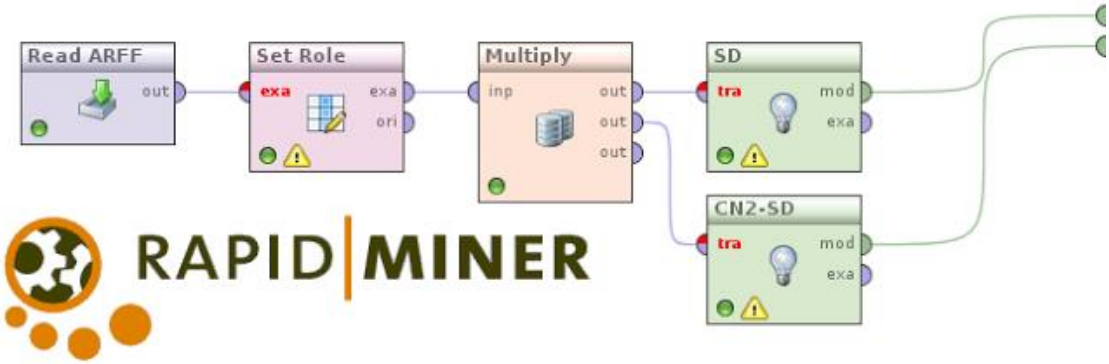

- **Excel**[38]: Excel és un entorn de full de càlcul propietari de la casa Microsoft. La versió actual (2016) permet llegir fins 1048000 línies. Té una gran potència de manipulació de dades amb fórmules i de representació gràfica. L'opció de "Dades" del menú principal ens dona opcions d'ordenar, filtrar, agrupar, transposar, anàlisi d'hipòtesi, validació, predicció, etc. Igualment amb la representació gràfica podem fer ràpides manipulacions de forma visual.

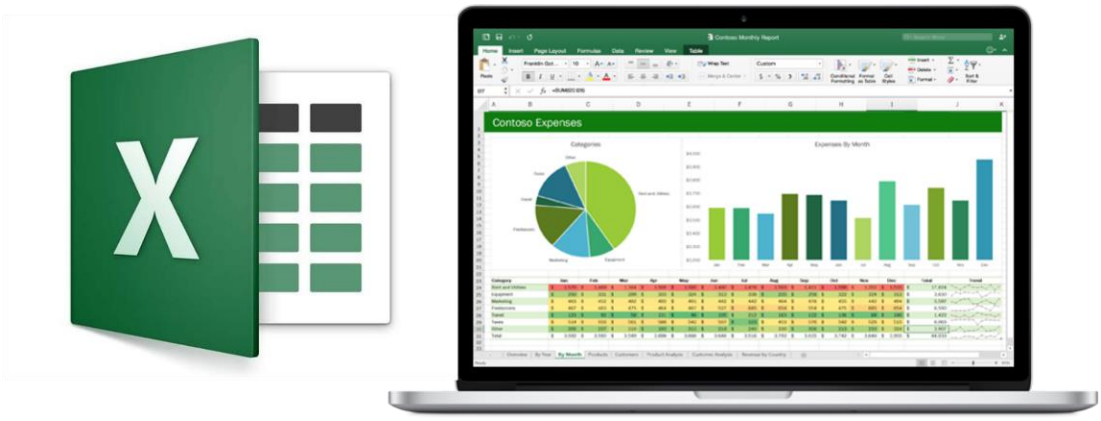

[37] https://rapidminer.com/
[38] https://products.office.com/es-es/excel

- **MatLab**[39]: Sistema de càlcul i llenguatge de programació propietari de la companyia MathWorks. És molt utilitzat a l'àmbit acadèmic, bàsicament les universitats, però també és utilitzat per les grans empreses del disseny i la indústria.
  Disposa d'un potent sistema d'importació de fitxers de dades i d'imatges i la consola ens permet fer servir tots els seus comandos. La pestanya Plot ens dona opció a utilitzar un bon grapat de gràfics predefinits i amb la pestanya APPS tenim l'opció d'utilitzar moltes caixes d'eines (toolboxes) que amplien les possibilitats de MATLAB.
  Simulink és un complement que permet la simulació de sistemes dinàmics de forma visual amb la utilització de blocs i la connexió entre ells.

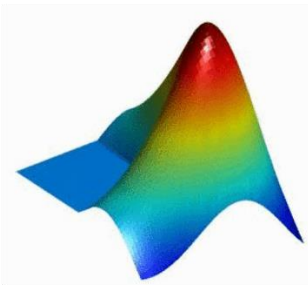

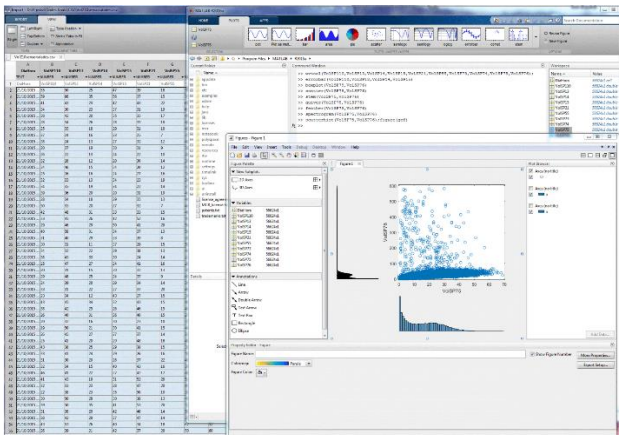

- **Wolfram Mathematica**[40]: És un programa creat per Stephen Wolfram i es va posar a la venda l'any 1988. Originalment estava dedicat a les tècniques de càlcul algebraic però actualment s'utilitza en totes les àrees del coneixement. Fa servir un llenguatge de programació poderós que amb poques primitives podem obtenir grans resultats. El programa està dividit en dues parts, el nucli on es fan els càlculs i la interfície que presenta els resultats. Apart de les seves funcions matemàtiques té moltes funcions d'estadística, de mineria de dades, d'anàlisi de series temporals, d'aprenentatge de màquina, GIS, reconeixement d'imatges, etc.

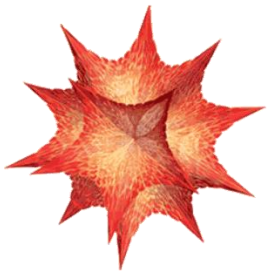

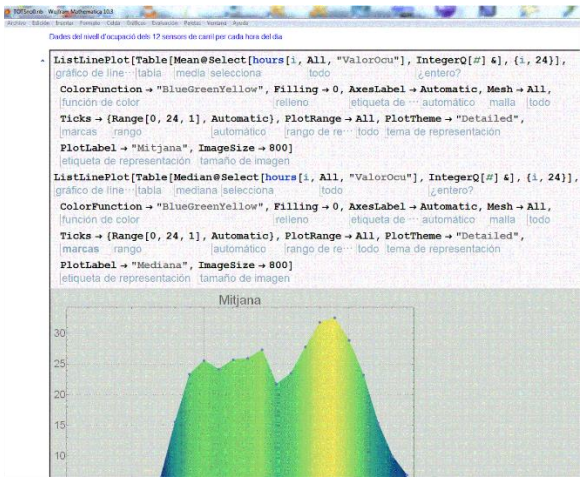

[39] https://es.mathworks.com/products/matlab/index.html
[40] https://www.wolfram.com/mathematica/

3.4 PROGRAMARI DE REPRESENTACIÓ GEOGRÀFICA:

- **OpenStreetMap**[41]: OSM és un projecte lliure i col·laboratiu creat pel britànic Steve Coast i ara gestionat per una fundació. Els mapes es visualitzen amb qualsevol navegador però també es poden visualitzar de forma nativa amb plug-in o altres programes com ara el Marble[42]. Qualsevol usuari, amb identificació prèvia, pot editar els mapes directament des del mateix editor del navegador o fent servir al navegador el Potlatch o bé editar de forma remota amb JOSM o Merkaartor. Els mapes OSM tenen moltes possibilitats d'exportació que ens permetrà fer servir tota la informació en diferents Sistemes d'Informació Geogràfica (GIS). S'ha de tenir present que les coordenades geogràfiques de l'OSM estan en format WGS84.

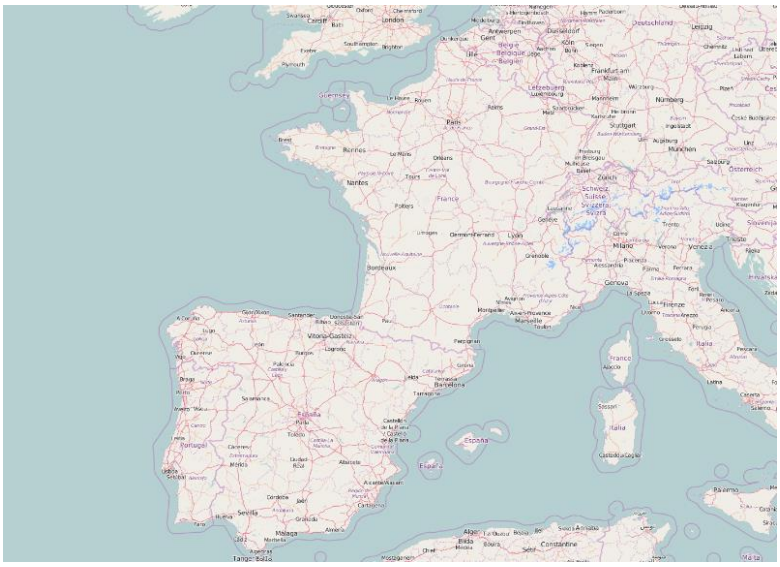

- **Carto**[43]: Fins la primera meitat d'aquest any (2016) aquest producte es deia CartoDB i ara per una qüestió d'estratègia es diu Carto. Aquesta empresa va ser fundada l'any 2012 i des de llavors el seu creixement ha sigut imparable. Només es necessari un navegador i donar-se d'alta. La idea bàsica de Carto és que qualsevol usuari pugui crear eines geoespacials amb les seves dades sense tenir grans coneixements. Amb el canvi d'estratègia l'empresa ha desenvolupat el "Carto Builder", una eina intuïtiva que permet analitzar i predir informació.

[41] https://www.openstreetmap.org/
[42] https://marble.kde.org/
[43] https://carto.com/

- **QGis**[44]: QGIS és un Sistema d'Informació Geogràfica (GIS) que pot córrer sobre qualsevol plataforma, Linux, Windows, MacOS, Android... i és suportat per la fundació OSGeo.
  QGIS pot visualitzar, editar i analitzar dades geoespacials i pot construir mapes a mida segons les necessitats. Està desenvolupat en C++ i té la possibilitat de fer servir tant fitxers vectorials com raster. A l'entorn es pot carregar molts complements d'importació, d'exportació, de manipulació de dades, manipulació de mapes, fer càlculs estadístic, etc. La comunitat d'usuaris està contínuament desenvolupant complements que faciliten el seu ús.

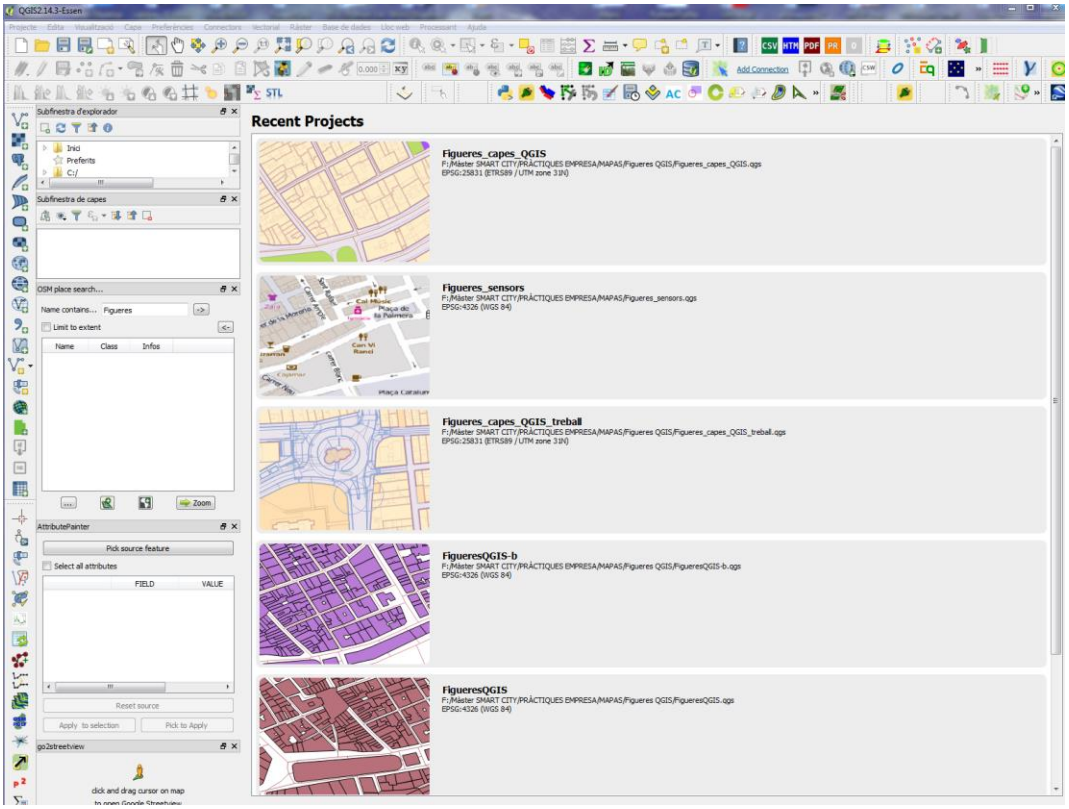

[44] www.qgis.org/

4 DESCRIPCIÓ DE LA INNOVACIÓ

Donades les lectures dels sensors del sistema de control de trànsit de la ciutat de Figueres, en aquest treball es desenvolupa una tasca d'anàlisi de dades i predicció de trànsit. Per aquest propòsit, es desenvolupen les següents tasques:

Medidas para estimar la utilización de las calles (Holgado, Emma , 2012)

- **Flujo:** es la cantidad de vehículos por unidad de tiempo en un determinado segmento
- **Velocidad:** distancia recorrida por unidad de tiempo. La velocidad a la que circulan los vehículos es un dato importante para medir el nivel de congestión que existe.
- **Tiempo:** es el tiempo de viaje sobre un segmento del camino conocido. Esta medida es obtenida dividiendo el largo de la calle entre la velocidad media en recorrer la calle, en el caso de los vehículos, o en atravesarla, en el caso de los peatones.
- **Ocupación:** es el porcentaje de tiempo que en un segmento de una ruta es ocupado por vehículos.
- **Densidad:** es la cantidad de vehículos por unidad de distancia, en un periodo de tiempo.
- Tiempo entre el paso de un vehículo y otro.
- Distancia entre un vehículo y otro.

1. Selecció de dades
2. Creació dels fitxers de dades
3. Visualització de dades
4. Preparació de dades
5. Anàlisis de dades
6. Obtenció del PHF (Peak Hour Factor)
7. Predicció de trànsit.

A continuació es detallen els procediments aplicats a cada tasca, incloent resultats parcials.

De totes les referències bibliogràfiques i referències web es fa una recopilació dels conceptes que es fan servir en aquest treball.

- **Flux (Flow):** es mesura comptabilitzant el nombre de vehicles, n_t, que passen per un determinat punt en un carril d'un carrer en un determinat període de temps t.

$$q = \frac{n_t}{t}$$

- **Ocupació de vehicles (Vehicle Occupancy):** és una part important de la gestió de la congestió del transport i s'utilitza per avaluar l'eficiència dels sistemes vials. Es defineix com el percentatge de temps que la zona de detecció està ocupada pels vehicles.
- **Velocitat mitjana (Time mean speed):** És la velocitat mitjana de tots els vehicles que passen per un punt en un determinat temps. Per cada vehicle, i, per a un nombre d'observacions (vehicles) n, la fórmula ve donada per

$$v_t = \frac{1}{n}\sum_{1=1}^{n} v_i$$

No podem relacionar la velocitat amb la densitat[45] de trànsit ja que amb la topologia dels sensors no disposem d'aquesta variable, però sí relacionar la velocitat amb el flux i obtenim de forma genèrica la gràfica següent

[45] Quantitat de vehicles entre dos punts.

Estadístico Q de Ljung-Box

Utilice el estadístico q de Ljung-Box para comprobar si una serie de observaciones en un período de tiempo específico son aleatorias e independientes. Si las observaciones no son independientes, una observación puede estar correlacionada con otra observación k unidades de tiempo después, una relación que se denomina autocorrelación. La autocorrelación puede reducir la exactitud de un modelo predictivo basado en el tiempo, como la gráfica de series de tiempo, y conducir a una interpretación errónea de los datos.
El LBQ también se utiliza para evaluar los supuestos después de ajustar un modelo de series de tiempo, como ARIMA, para asegurar que los residuos sean independientes.
El estadístico de Ljung-Box es una prueba de Portmanteau y una versión modificada del estadístico de chi-cuadrado de Box-Pierce. (ref: http://support.minitab.com/es-mx/minitab/17/topic-library/modeling-statistics/time-series/diagnostic-checking/what-is-the-ljung-box-q-statistic/)

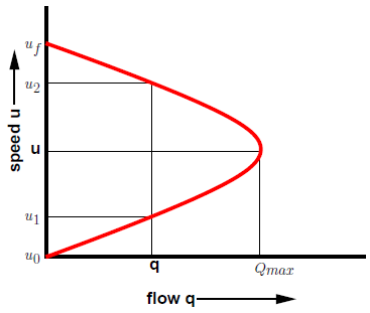

- **Factor horari pic (Peak hour factor):** S'utilitza per fer l'anàlisi de la capacitat de les vies, d'acord amb el capítol 7 del "*Highway Capacity Manual*"[46]. Normalment es fan servir períodes de temps de 15 minuts però el nostre cas d'estudi té dades acumulats cada 5 minuts i per tant es fan servir 12 períodes (60/5). Essent V_{av}^{60} el volum mitjà pic d'una hora[47] i V_{av}^{5} el valor pic màxim observat, la fórmula a aplicar serà

$$PHF = \frac{V_{av}^{60}}{\frac{60}{5} \cdot V_{av}^{5}}$$

  Es considera, segons el manual, que si no tenim per calcular aquest factor podem agafar el valor de 0,92 per a àrees urbanes.
  Després de calcular el PHF podem preveure el pic màxim de flux de trànsit amb l'expressió $V_{màx}^{60} = \frac{V_{av}^{60}}{PHF}$

- **Sèries temporals:** Una sèrie temporal és un conjunt d'observacions d'una variable recollides seqüencialment en el temps. Les unitats de temps han de ser sempre del mateix valor; si la recollida de dades es fa de forma continuada s'han de convertir aquests valors als corresponents a unitats de temps uniformes, per exemple per acumulació. Per tant les observacions de sèries temporals es poden classificar en discretes o contínues.
  Els components de les sèries temporals a tenir en compte:
  - *La tendència:* El valor de la variable tendeix a augmentar o disminuir en un període llarg.
  - *Variació cíclica:* La tendència pot ser plana. Els valors varien cíclicament.
  - *Variació estacional:* dona patrons de canvi en un espai de temps, per exemple quan en un any es repeteixen les dades trimestralment.
  - *Variació irregular:* Les dades són impredictibles i els canvis són aleatoris.

  Una sèrie temporal és **determinista** si podem predir exactament els valors. Si només podem predir els valors de forma parcial es considera que aquests valors futurs tenen una probabilitat condicionada a valors passats. Aquest tipus de sèrie temporal es diu **estocàstica.**
  De les quatre components ressenyades de les sèries temporals, les tres primeres són deterministes i l'última és aleatòria.
  Si es compleix mínimament una sèrie temporal estacional necessitem fer tres etapes per descriure aquesta sèrie:
  - Desestacionalització de la sèrie de temps.
  - Desenvolupament d'una línia de tendència.

[46] http://www.gsweventcenter.com/Draft_SEIR_References%5C2000_TRB.pdf
[47] Es fa servir el període horari que tingui el pic màxim d'un període de 5 minuts.

- Cerca de la variació cíclica d'aquesta línia de tendència.

Mètodes de predicció: Els mètodes més utilitzats en sèries temporals són:

- Mitjana mòbil
- Suavització exponencial
- Box-Jenkins

Tendència evolutiva (mitjanes mòbils): Una tendència evolutiva és quan varia lentament en el temps i podem aplicar la mitjana mòbil de l'ordre que fem servir (intervals curts).

Suavització exponencial: És un mètode exponencial i està basat en la possibilitat de calcular una mitjana nova a partir d'una mitjana anterior a més de l'última dada observada. Utilitza una constant de suavització alfa (α) que té un valor entre 0 i 1 però que normalment varia entre 0,05 i 0,5. És de poca precisió i per això s'utilitza el suavitzat exponencial doble o model Holt que fa servir una altra constant de suavitzat delta (δ) per reduir l'error i que també pren marges de valor com la constant alfa.

Mètode Box-Jenquins: S'aplica la relació ($X_t = T_t + E_t + I_t$) on X_t és el valor observat, T_t és la tendència, E_t és la component estacional i I_t és la part probabilística. Si fem $I_t = X_t - T_t - E_t$ i eliminem la part T_t i E_t quedarà només la part probabilística.

4.1 SELECCIÓ DE DADES

La disponibilitat de les dades és molt acceptable pel que fa a les variables de volum de trànsit i velocitat mitjana. No es disposa de suficients dades de la variable d'ocupació de la calçada. Tots les dades es van registrant cada 5 minuts però ens podem trobar que, per raons que ja hem comentat, no tinguem dades en unes dates i/o hora concretes.

Les dades a estudiar són dels 12 sensors nomenats de "carril" incloent-hi els sensors SP-1.3AB anterior al SP-1.3CD i el SP-1.4AB anterior al SP-1.4CD ja que encara disposem de dades. L'emplaçament de tots els sensors són els següents:

Sensors de carril
SP-1.10 (Av.Salvador Dalí, direcció nord)
SP-1.3 (Av.Salvador Dalí, direcció sud, carril lateral)
SP-1.4 (Av.Salvador Dalí, direcció sud, carril central)
SP-1.5 (Inici carretera cap a Besalú)
SP-2.1 (entrada al carrer del Col·legi)
SP-5.5 (entrada Av. Vilallonga)
SP-7.3 (carretera Llançà – Plaça el·líptica)
SP-7.4 (Plaça el·líptica – carreta Llançà)
SP-7.5 (Plaça Josep Tarradellas – Plaça el·líptica)
SP-7.6 (Plaça el·líptica – Plaça Josep Tarradellas)

Considerem que els **sensors de trànsit** ocupen un punt d'un segment d'una xarxa viària. Les diferents unitats de mesura o variables que podem disposar amb aquests sensors són:

- **Volum**: és la quantitat de vehicles per unitat de temps en un determinat punt.
- **Ocupació**: és el percentatge de temps d'ocupació de la calçada per vehicles.

- **Velocitat mitjana**: és la distància recorreguda per unitat de temps i ens permetrà tenir una referència del nivell de congestió.
- **Grandària del vehicle**: només ens dona una idea de la longitud total però no del tipus de vehicle.

4.2 CREACIÓ DELS FITXERS DE DADES

- Agafem les dades del **volum de vehicles** de l'any 2015 des de l'1 de març i les dades, també de volum, de gener i de febrer de 2016, amb els camps "Codi de geoposicionament", "POM", "Data i hora" i "ValorVol" i prescindim del camp de coordenades. Fem la unió dels dos fitxers i obtenim un únic fitxer de text delimitat "*10-volum1516f.csv*".
- Agafem les dades d'**ocupació de la calçada** de l'any 2015 des de l'1 de març i les dades, també d'ocupació, de gener i de febrer de 2016, amb els camps "Codi de geoposicionament", "POM", "Data i hora" i "ValorOcu" i prescindim del camp de coordenades. Fem la unió dels dos fitxers i obtenim un únic fitxer de text delimitat "*11-ocupa1516f.csv*".
- Agafem les dades de **velocitat mitjana** de l'any 2015 des de l'1 de març i les dades, també de velocitat, de gener i de febrer de 2016, amb els camps "Codi de geoposicionament", "POM", "Data i hora" i "ValorVel" i prescindim del camp de coordenades. Fem la unió dels dos fitxers i obtenim un únic fitxer de text delimitat "*12-velo1516f.csv*".
- Un cop tenim els tres fitxers fem una base de dades relacional. Agafem per exemple l'eina Access i creem tres taules a partir de la importació d'aquests tres fitxers. Fem la relació del camp datetime (data i hora) i es crea una consulta amb un fitxer únic amb tres variables de valor. Aquest fitxer s'exporta amb format de text delimitat "*19-Consulta3ValorsTOTS.csv*". Observem que hi ha mancances de valors d'ocupació i de velocitat en molts registres.
- Agafem de nou l'Access i fem la consulta eliminant els valors buits i fem l'exportació amb format de text delimitat "*29-Consulta3ValorsTOTSno0.csv*".

Els cinc fitxers estan disponibles en aquest enllaç:
https://drive.google.com/open?id=0B728doyg6XT-MzJHRGFTU2l6Rlk

4.2.1 Anàlisi i visualització de les dades

Aprofitant que tenim el fitxer "*29-Consulta3ValorsTOTSno0.csv*" amb un nombre de registres que abasta un any i té les tres variables "volum", "ocupació" i "velocitat" decidim fer servir l'eina "Mathematica[48]" de Wolfram, amb llicència d'ús temporal.

Un cop creat el data set de les dades amb el Mathematica "totsno0.m" fem la seva importació a l'entorn de treball.

```
dataset1516carril = Import["totsno0.m"]
```

[48] https://www.wolfram.com/mathematica/
Mathematica és una eina que permet fer càlculs importants de computació, amb molts algorismes incorporats i amb un llenguatge propi que intenta simplificar al màxim la sintaxis. També és una eina poderosa per representar tots tipus de gràfics matemàtics, representacions geogràfiques i altres tipus de gràfiques per visualitzar dades.

Veiem que dels 589787 registres sense eliminar els incomplets hem passat a 314723 registres complets amb les tres variables. Si fem un recompte per cada sensor,

```
CountsBy[dataset1516carril, "Codi"]
```

obtenim la següent taula:

Sensor	Count
SP-1.3 CD	40968
SP-1.4 AB	17931
SP-7.6	41861
SP-1.10	26247
SP-1.3 AB	26247
SP-1.4 CD	25144
SP-1.5	26085
SP-7.3	25005
SP-7.4	25121
SP-7.5	23254
SP-2.1	19384
SP-5.5	17476

*El fitxer d'origen de dades "**totsno0.m**" ho podem trobar en aquest enllaç:*
https://drive.google.com/open?id=0B728doyg6XT-NVpHdmVDSW9NOTg

*Tots els codis de programació i l'anàlisi més complet ho tenim al fitxer de Mathematica "**TOTSno0.nb**". Aquest fitxer es pot executar i visualitzar amb el CDF Player de Wolfram (https://www.wolfram.com/cdf-player/)*

La primera observació: cap dels sensors estudiats tenen el mateix nombre de registres i a més hi ha molta variació entre alguns. Els sensors que tenen més registres es consideren que tenen més fiabilitat i han donat més dades de les tres variables conjuntament.

Ara fem la primera aproximació gràfica. Agrupem tots els datetime per hores en un marge de 24 i representem en aquestes hores la intensitat o **volum de vehicles** i l'**ocupació** de la calçada. Tenim la situació previsible de poc volum i poca ocupació a la matinada i un màxim a les 19 h aprox. i podem comprovar que el volum de vehicles i l'ocupació de la calçada van molt relacionats.

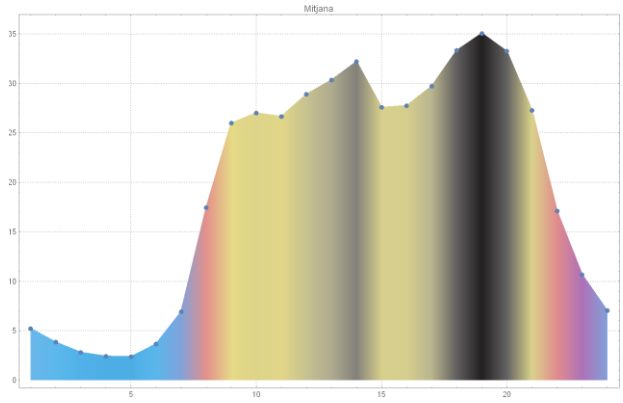

Mitjana del volum de vehicles diari

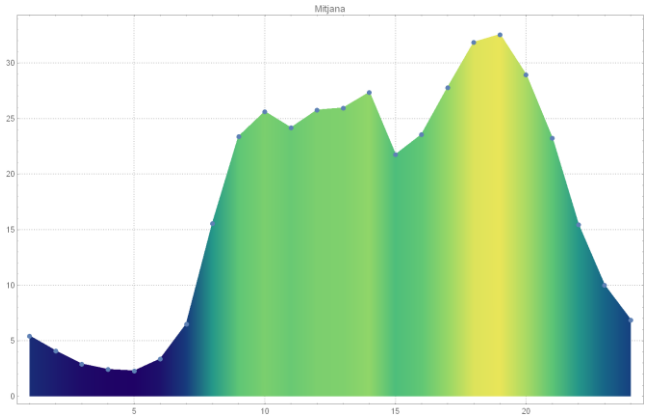

Mitjana diaria d'ocupació de la calçada

Però si també ho fem amb la variable **velocitat**, la gràfica és la següent:

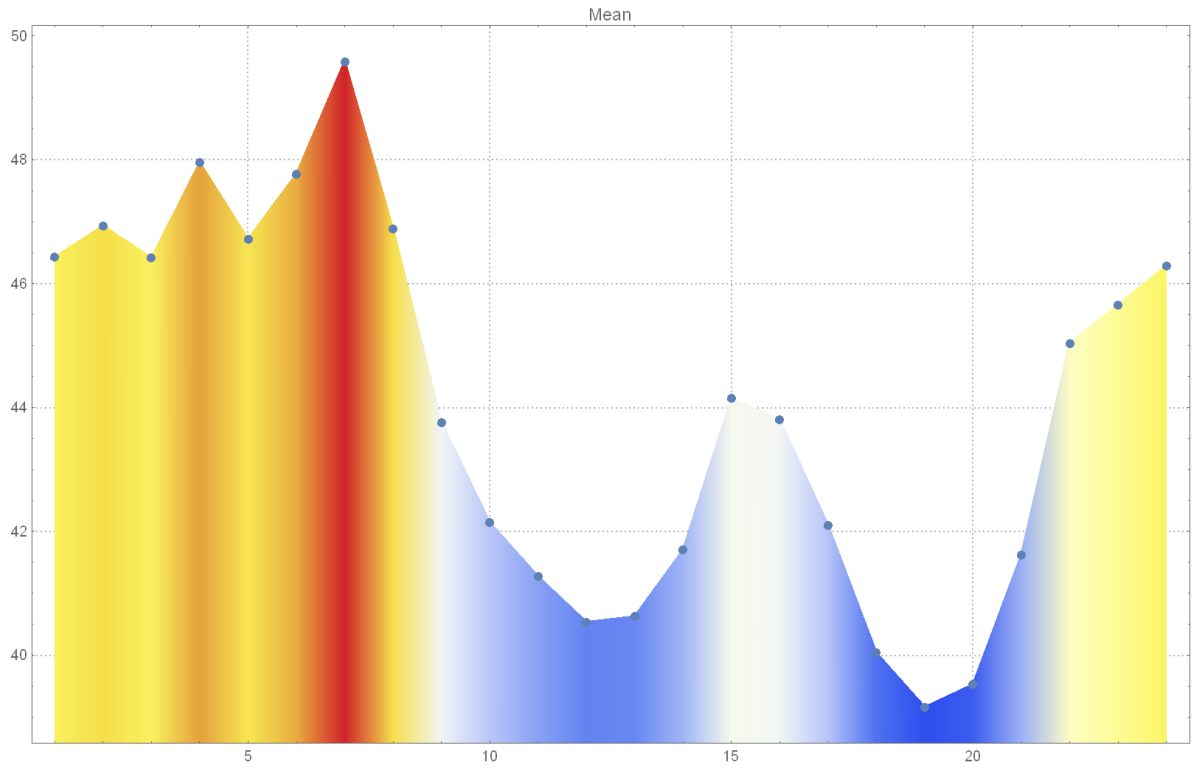

També és previsible que els màxim de velocitat sigui a la matinada i primeres hores del matí i la velocitat mínima es produeix quan hi ha més intensitat de trànsit o més ocupació de la calçada.

Ara volem saber com estan distribuïts en el temps les dades de cada sensor. Mirem primer el **volum de vehicles** per cada sensor i observarem, com ja hem comentat, la gran diversitat i mancances de dades.

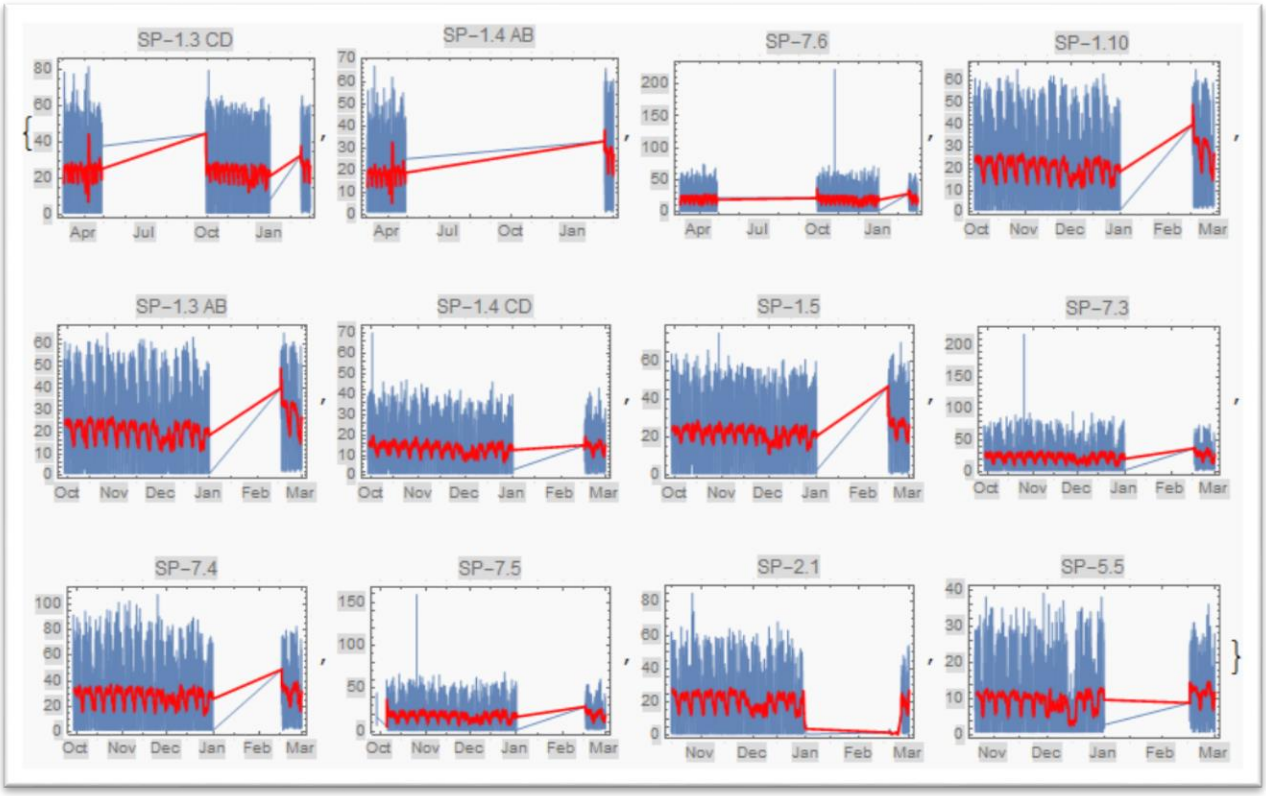

La mateixa observació podem fer de l'**ocupació de la calçada**,

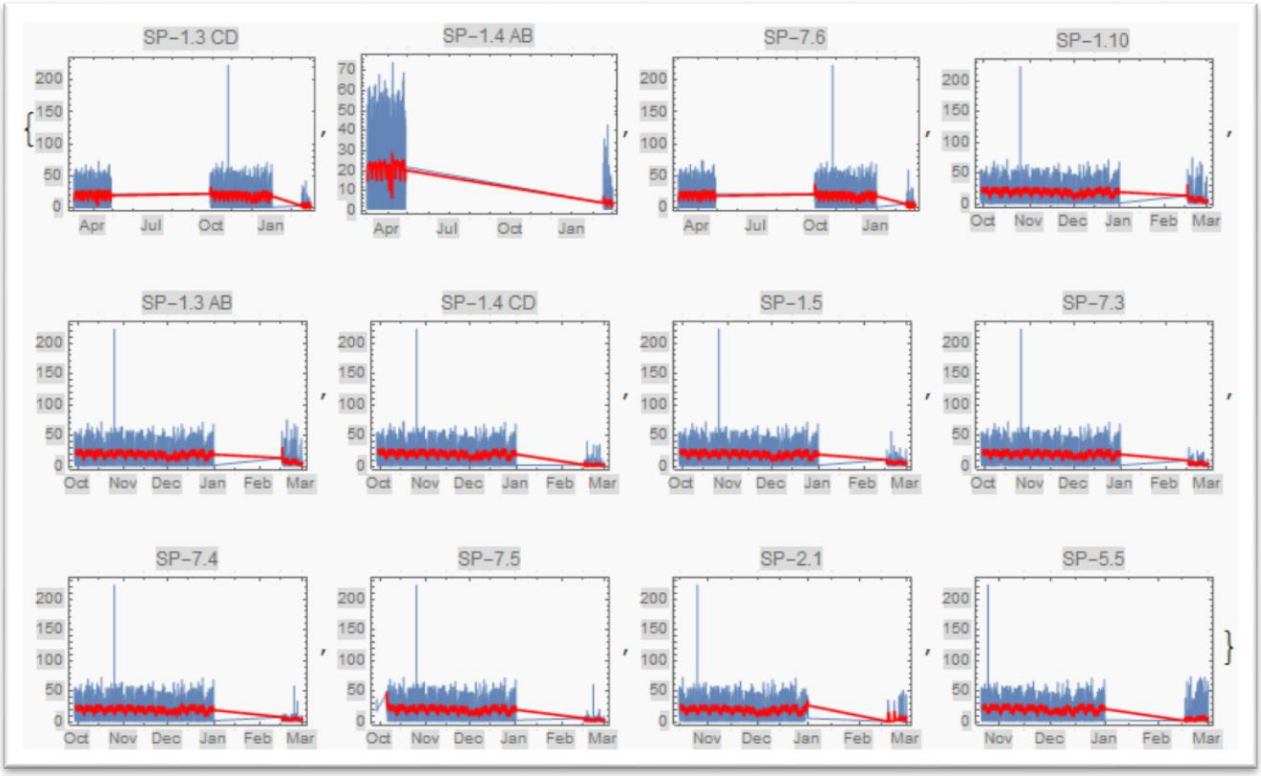

I de la **velocitat mitjana**,

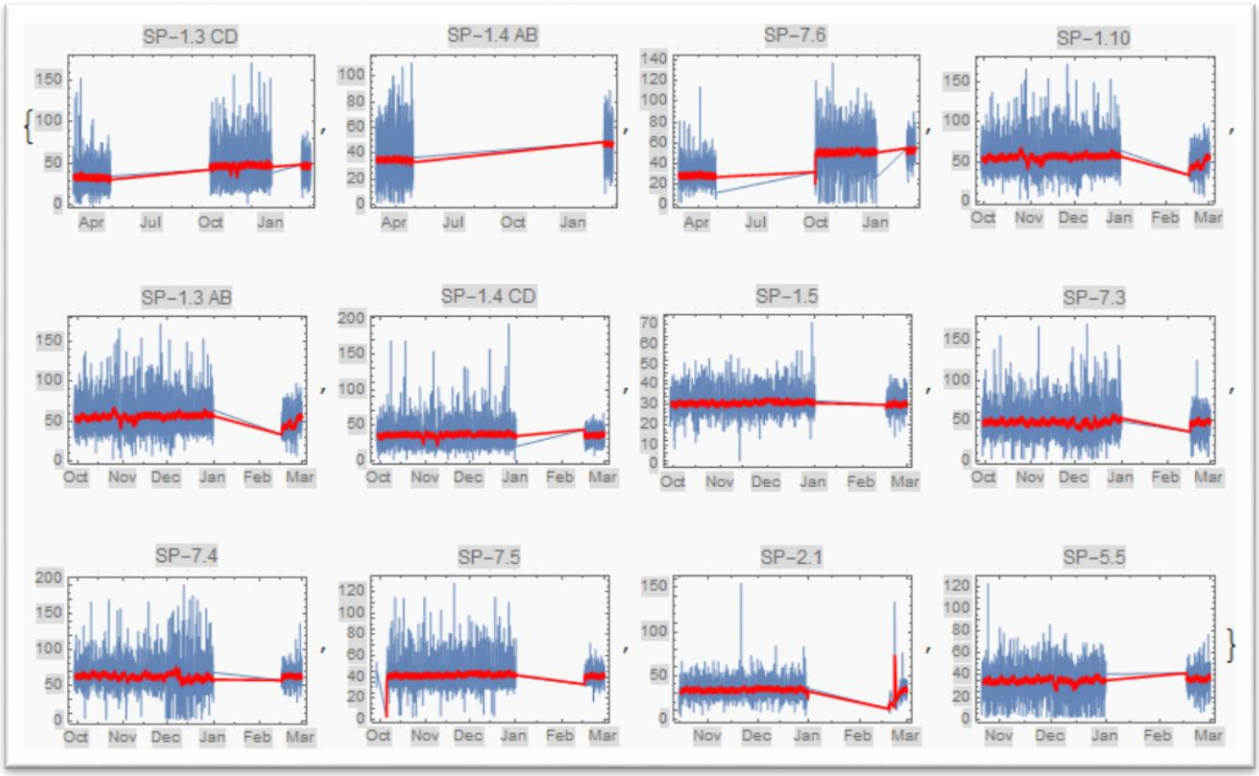

Si fem una visualització de tots els registres dels 12 sensors pel que fa al volum vehicles o intensitat de trànsit el resultat és aquest:

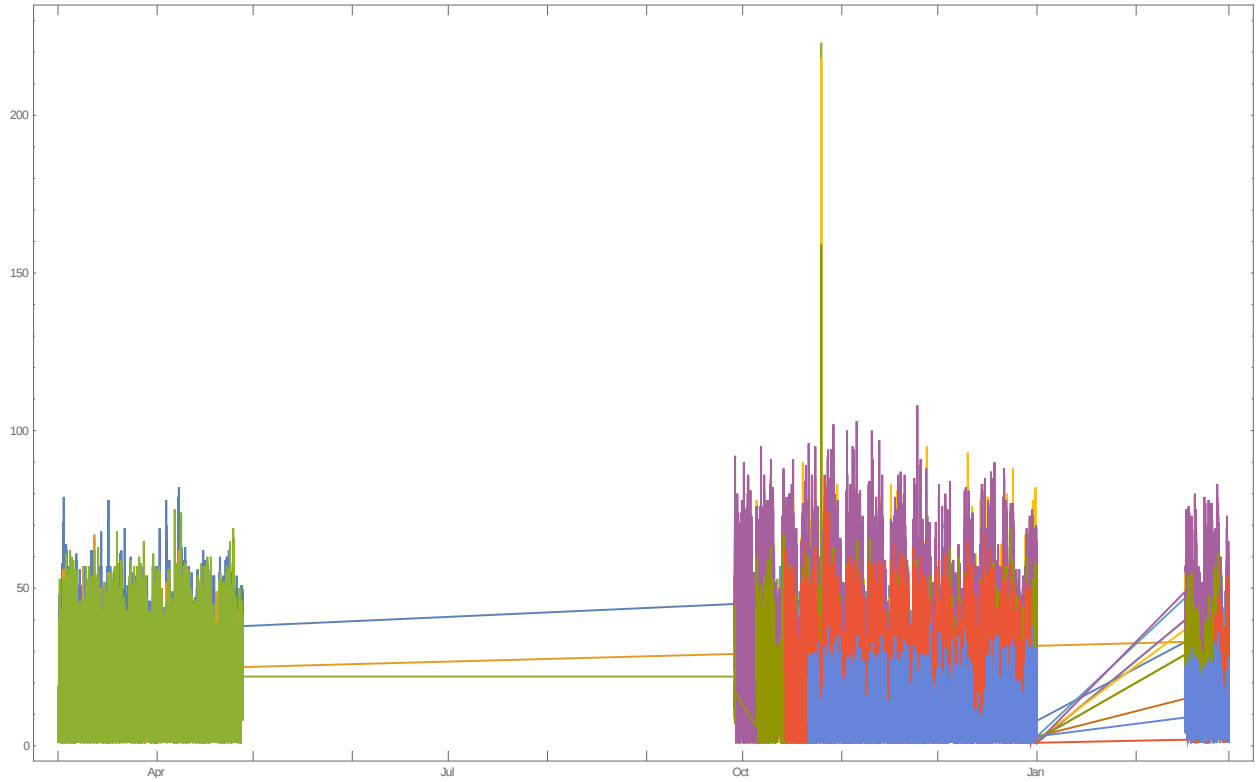

Amb aquesta gràfica podem tenir una visió clara de les èpoques on falten dades, recordant que vàrem eliminar tots els registres que no tenien valor en alguna de les tres variables "volum", "ocupació" o "velocitat". També s'observa que entre els mesos d'octubre i novembre hi ha uns valors atípics però això és un tema més fàcil de resoldre. A partir d'aquesta gràfica es podria fer la selecció de registres que ens podria servir per fer un estudi complet amb les tres variables i que pot ser l'època que va de novembre de 2015 a gener de 2016.

Ara farem l'anàlisi del que passa cada una de les 24 hores del dia segons el dia de la setmana. Agafarem primer els valors del **volum de vehicles** i obtenim la gràfica següent:

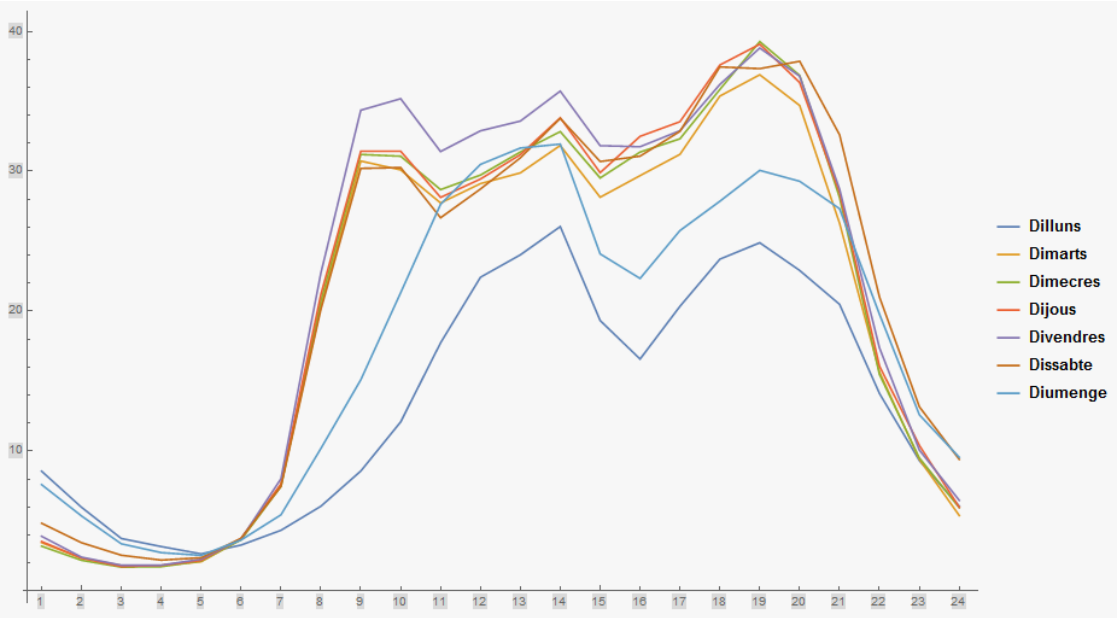

A destacar la baixa intensitat de trànsit dels dilluns, menys encara que els diumenges. Tots els dies segueixen menys o menys el mateix patró horari. I si fem la representació amb un diagrama bidimensional de discos obtenim la següent gràfica:

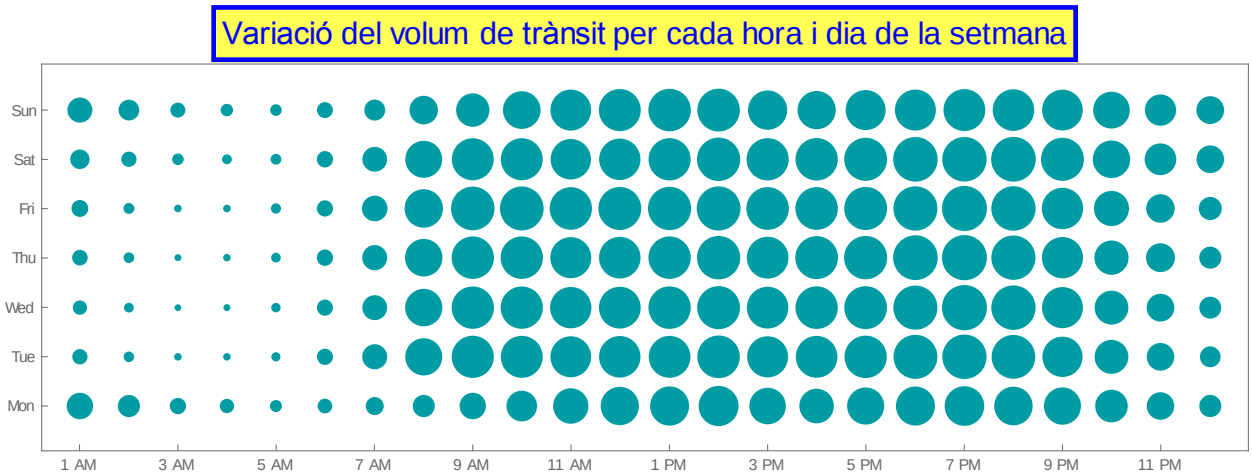

Com és d'esperar, a la matinada hi ha poca intensitat de trànsit.

Ara farem el mateix procés amb les dades de l'**ocupació de la calçada**. La comparativa és molt real ja que es fa sobre la mateixa correlació de dates.

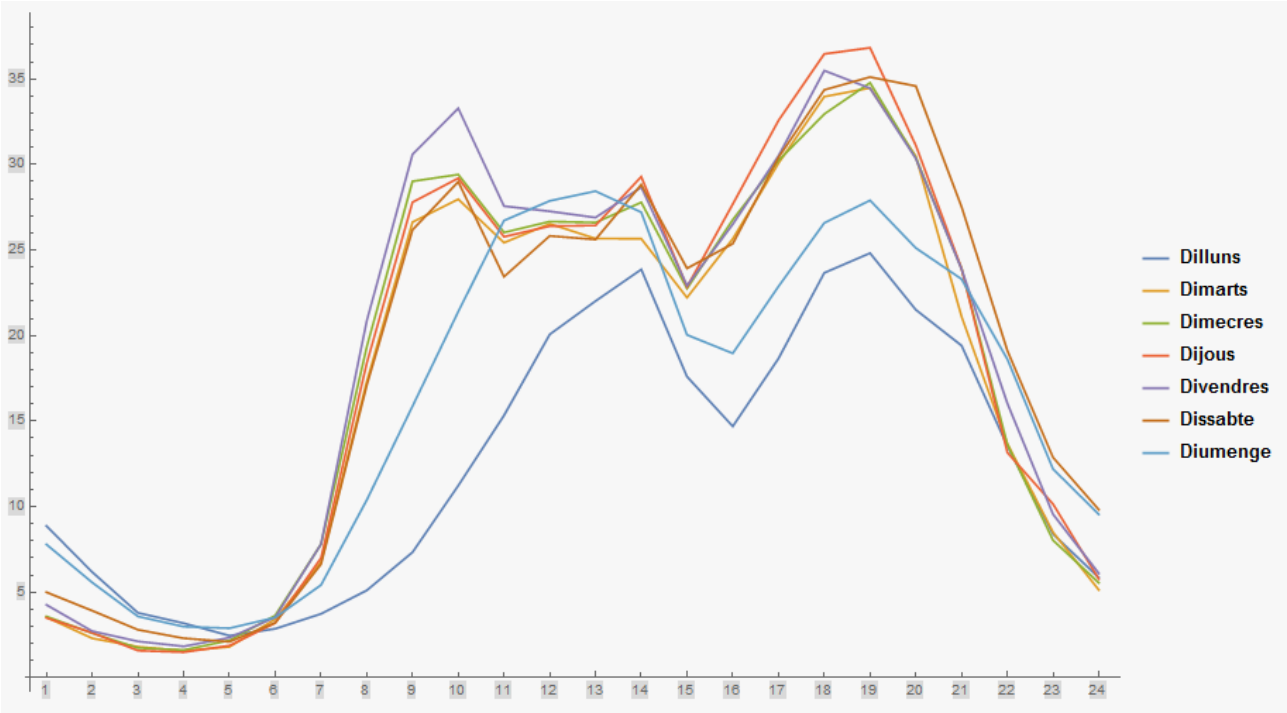

S'observa, com és d'esperar una similitud amb la gràfica de volum de vehicles, amb els dilluns per sota dels diumenges. I de forma similar la representació amb diagrames de discos:

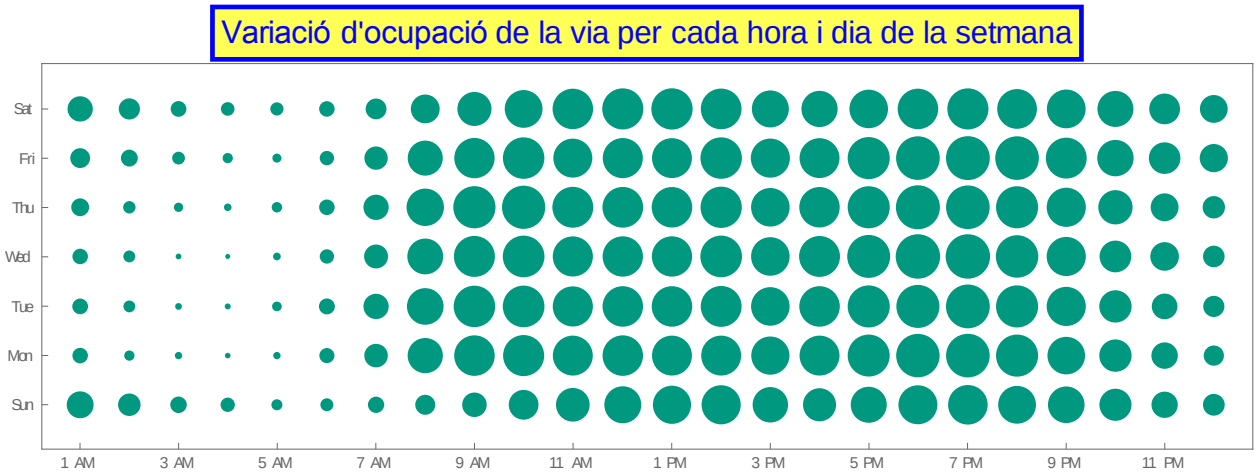

S'observa la similitud completa amb la gràfica del volum de vehicles essent la matinada quan hi ha poca ocupació de la calçada i el final de la tarda el contrari.

Si fem el mateix procés amb els valors de **velocitat mitjana** obtenim les gràfiques següents:

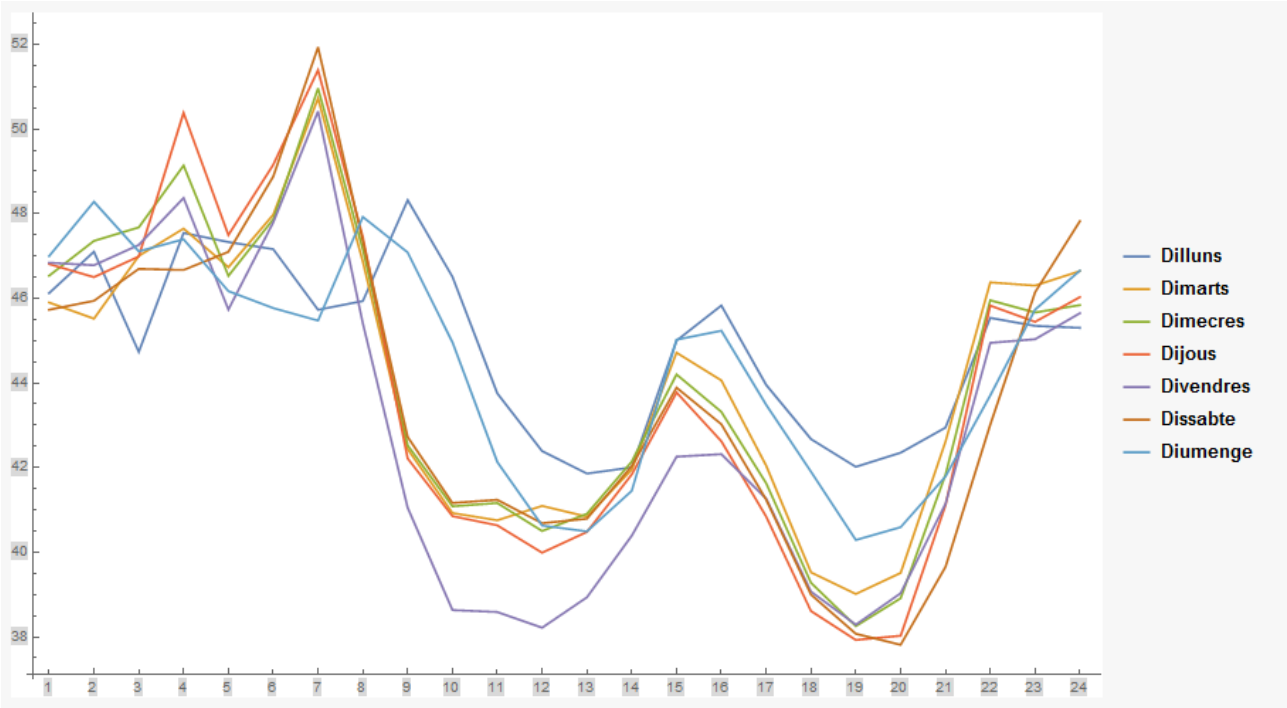

Una dada curiosa difícil de contractar és la poca velocitat mitjana del trànsit els divendres al matí. Sí que és previsible la velocitat alta durant les matinades ja que hi ha poc volum de trànsit i poca ocupació de la calçada. I amb el diagrama de discos s'observa la grandària dels discos a la inversa dels altres casos.

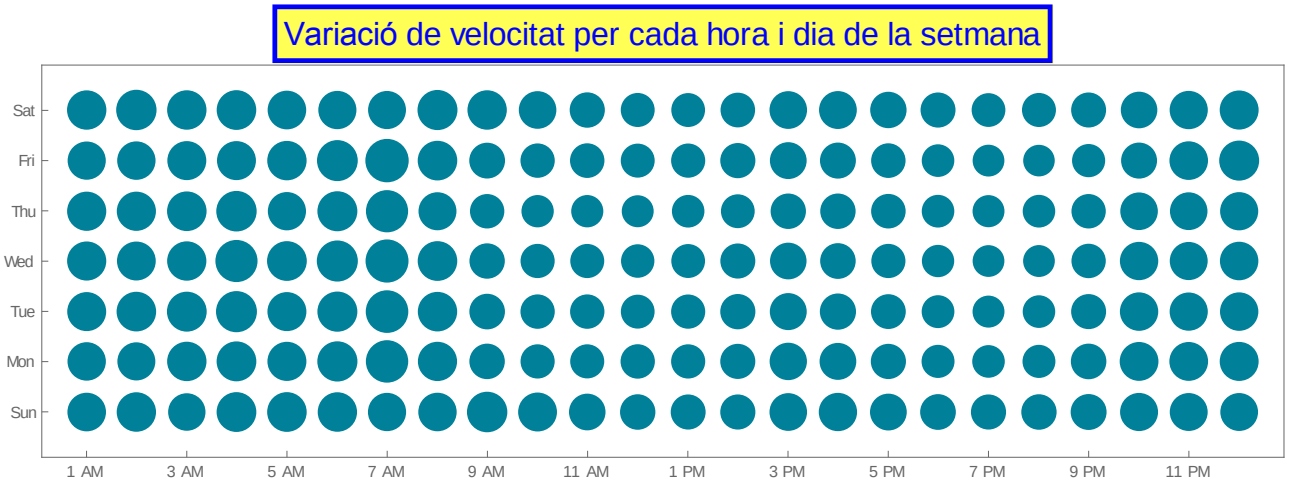

4.3 PREPARACIÓ DE LES DADES

Estudiarem els 10 sensors nomenats de carril que són els corresponents als sensors dobles i per tant amb possibilitat de mesurar velocitats mitjanes i altres paràmetres. La geolocalització d'aquest sensors figura al mapa següent:

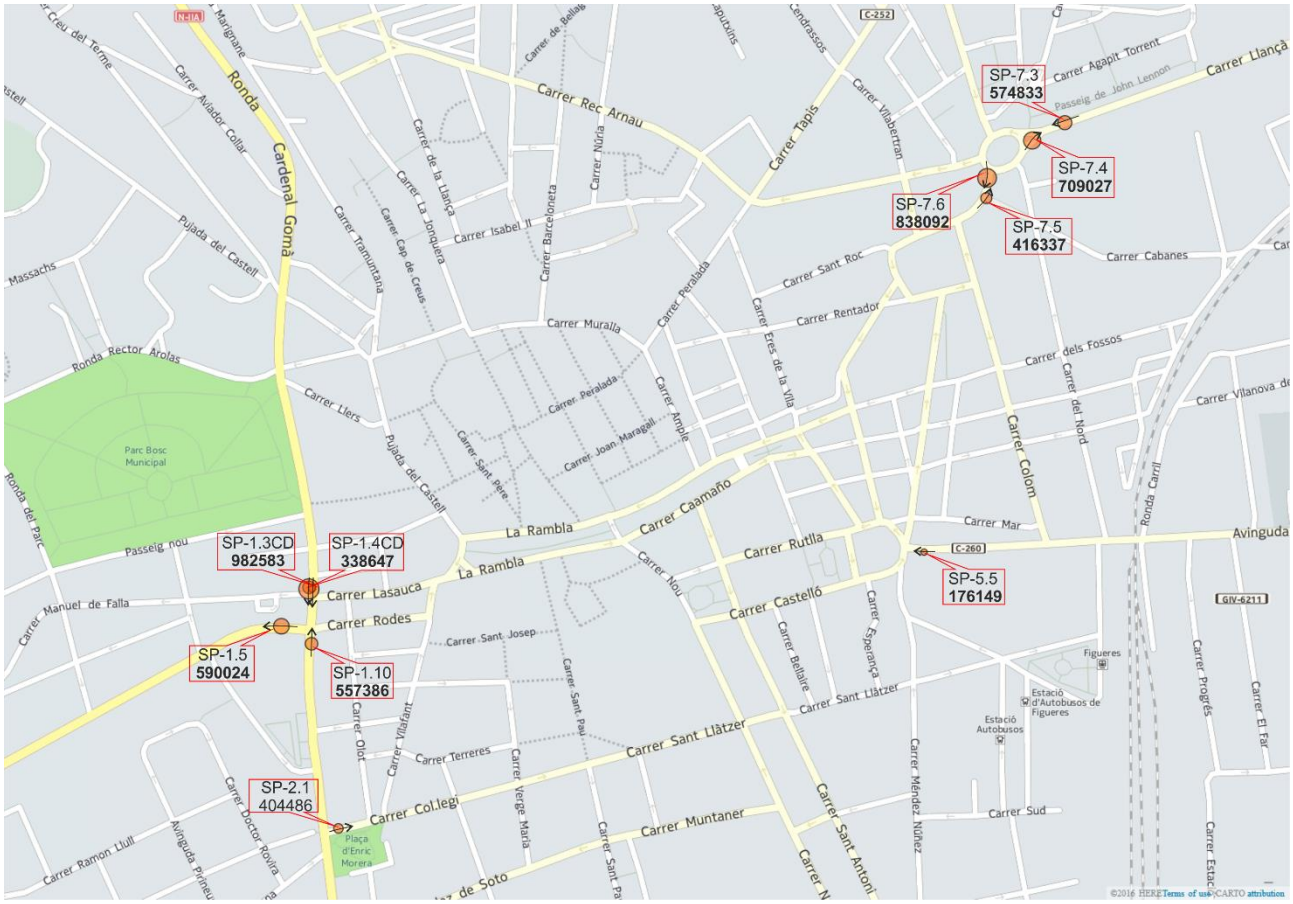

Mapa situació sensors carril. Elaboració pròpia

La zona 1 (sensors SP-1.x) disposa de 4 sensors virtuals d'aquest tipus, així com la zona 7 (sensors SP-7.x), i la zona 2 (sensors SP-2.x) i la zona 5 (sensors SP-5.x) només d'1 sensor virtual, SP-2.1 i SP-5.5 respectivament.

S'intenta preparar un conjunt de dades que abasti un any complet, els mesos més recents des de l'1 de juliol de 2015 fins el 30 de juny de 2016, i s'observa que també hi ha molta mancança de dades degut a circumstàncies diverses que ja es va comentar anteriorment. Finalment les dades disponibles més complets amb correlació de dates els tenim des de novembre de 2015 fins juny de 2016, o sigui 8 mesos.

Preparem per **cada sensor** un fitxer CSV delimitat per comes amb dues variables (volum i velocitat). Cada registre ha de tenir els següents condicionants: que cap valor sigui buit i que cada parella de valors correspongui a la mateixa data i hora. Es donarà el cas que quan en un interval de temps de 5 minuts no s'ha comptabilitzat cap vehicle (normalment durant la matinada) i la velocitat queda registrada amb un valor -1.

Els 10 fitxers estan disponibles en aquest enllaç:
https://drive.google.com/open?id=0B728doyg6XT-bU5BVGNFOTRwUlE

La captura de dades correspon a aquests paràmetres:

Sensors de carril	Interval (dates)	registres
SP-1.10 (Av.Salvador Dalí, direcció nord)	22.09.2015 10:50:00 - 30.06.2016 23:55:00	76680
SP-1.3 (Av.Salvador Dalí, direcció sud, carril lateral)	01.07.2015 01:00:00 - 30.06.2016 23:55:00	99545
SP-1.4 (Av.Salvador Dalí, direcció sud, carril central)	21.09.2015 10:30:00 - 30.06.2016 23:55:00	75406
SP-1.5 (Inici carretera cap a Besalú)	22.09.2015 10:20:00 - 30.06.2016 23:55:00	76239
SP-2.1 (entrada al carrer del Col·legi)	14.10.2015 08:40:00 - 30.06.2016 23:55:00	67098
SP-5.5 (entrada Av. Vilallonga)	21.10.2015 12:40:00 - 30.06.2016 23:55:00	64881
SP-7.3 (carretera Llançà – Plaça el·líptica)	28.09.2015 11:05:00 - 30.06.2016 23:55:00	70615
SP-7.4 (Plaça el·líptica – carreta Llançà)	28.09.2015 10:40:00 - 30.06.2016 23:55:00	70621
SP-7.5 (Plaça Josep Tarradellas – Plaça el·líptica)	28.09.2015 12:55:00 - 30.06.2016 23:55:00	68862
SP-7.6 (Plaça el·líptica – Plaça Josep Tarradellas)	28.09.2015 12:20:00 - 30.06.2016 23:55:00	70428

Es filtraran i esborraran els registres duplicats, que tenen la mateixa data i hora però no necessàriament el mateix valor. Si és el cas que no tinguin el mateix valor s'esborraran els registres amb el valor menys comuns.

També s'observa que hi ha valors atípics, com ara un volum de 1000 vehicles en 5 minuts o una velocitat de 200 km/h en un carrer. En aquest cas es fa per cada fitxer un filtre triat per raonament simple, el volum de vehicles es limita a un màxim de 600 i la velocitat es limita a un màxim de 100 km/h. Després d'aplicar aquests filtres s'observa que el nombre total de registres s'ha reduït en un percentatge molt petit del total. L'eina que fem servir per aplicar aquests filtres i posteriorment exportar a fitxers CSV delimitats per comes és l'Access de Microsoft, molt potent com a bases de dades relacionals.

4.4 ANÀLISI DE LES DADES

Primer es fa un resum del conjunt de dades per cada sensor amb les variables **volum i velocitat** aparellades. Les variables utilitzades en aquest resum són:

- *DiaHora:* Data en format complet (dia-mes-any-hora-minuts-segons)
- *VolSPxx:* Valor del volum de trànsit.
- *VelSPxx:* Valor de la velocitat mitjana en cada sensor.

A partir d'aquí farem servir l'eina R, descrita anteriorment. Amb R podem començar per fer un summary() o resum de les dades estadístiques fonamentals: mínim, 1r quartil, mediana, mitjana, 3r quartil, màxim, desviació estàndard, IQR (Interquartile range) i coeficient de variació (cv), així com la correlacions de Pearson i les seves representacions gràfiques.

Farem servir els fitxers CSV que hem preparat :
https://drive.google.com/open?id=0B728doyg6XT-bU5BVGNFOTRwUlE

Coeficient de correlació de Pearson

Permet saber si l'ajustament del núvols de punts a la recta de regressió obtinguda és l'adequat. És el quocient entre la covariància entre les dues variables i la desviació estàndard de les mateixes.

$$r = \frac{\sigma_{XY}}{\sigma_X \cdot \sigma_Y}$$

El resultat varia entre els valors -1 i +1

- Si r=1 hi ha correlació perfecta. Dependència total entre les dues variables.
- Si 0<r<1 hi ha correlació positiva.
- Si r=0 no hi ha relació lineal, però podria haver-hi relació no lineal.
- Si -1<r<0 hi ha correlació negativa
- Si r=-1 hi ha correlació negativa perfecta. La dependència té relació inversa.

- **Sensor SP-1.10**:

  Fem servir el conjunt de dades "VOLVELSP110.csv"

  Total de registres: **76680**

  Interval de temps: 22.09.2015 a les 10:50:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP110 <- read.table("VOLVELSP110.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP110)
```

```
              DiaHora          VolSP110         VelSP110
1/1/2016 00:00:00:     1   Min.   : 0.00   Min.   : -1.00
1/1/2016 00:05:00:     1   1st Qu.: 6.00   1st Qu.: 38.84
1/1/2016 00:10:00:     1   Median :21.00   Median : 47.00
1/1/2016 00:15:00:     1   Mean   :20.48   Mean   : 47.14
1/1/2016 00:20:00:     1   3rd Qu.:32.00   3rd Qu.: 57.00
1/1/2016 00:25:00:     1   Max.   :74.00   Max.   :100.00
(Other)           :76674
```

```
>numSummary(VOLVELSP110[,c("VelSP110","VolSP110")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
             mean       sd   se(mean)   IQR        cv 0%   25% 50% 75% 100%     n
VelSP110 47.13827 15.82682 0.05715480 18.16 0.3357532 -1 38.84  47  57  100 76680
VolSP110 20.47817 14.62104 0.05280042 26.00 0.7139820  0  6.00  21  32   74 76680
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP110[,c("VelSP110","VolSP110")])
```

Coeficient de Pearson: -0,08735161

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP110".

Al gràfic 1-110 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP110) %in% c("DiaHora")
> Nou.VOLVELSP110<-VOLVELSP110[!var.fora]
> pairs.panels(Nou.VOLVELSP110, pch=1,main="Sensor SP-1.10",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-110) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP110, pch=1,main="Sensor SP-1.10", show.points=FALSE, gap=0, method="pearson")
```

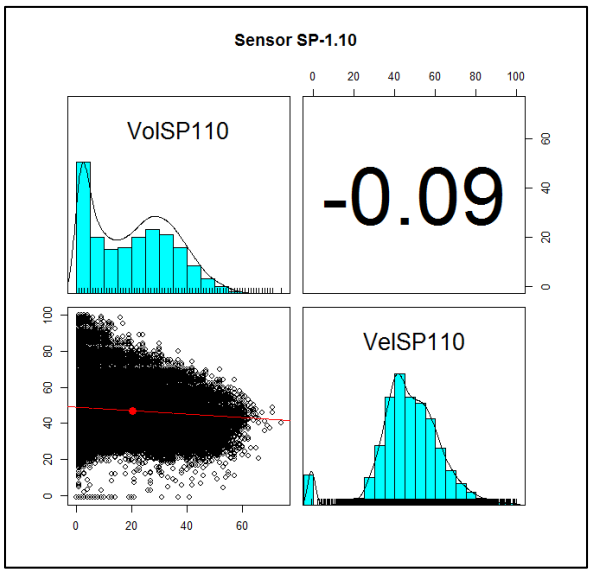

gràfic 1-110

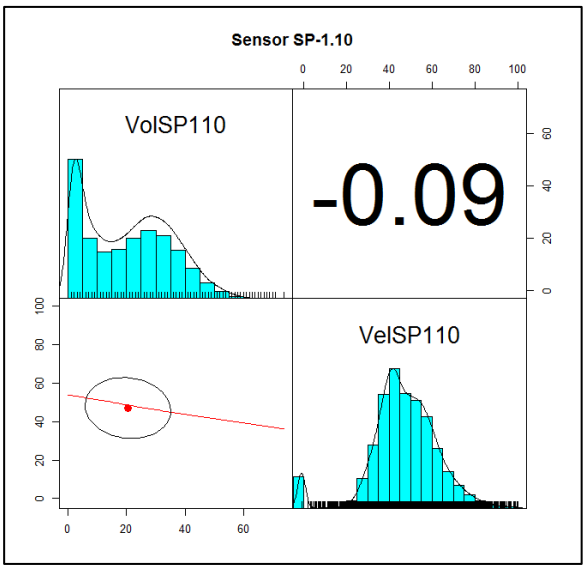

gràfic 2-110

- **Sensor SP-1.3:**

  Fem servir el conjunt de dades "VOLVELSP13.csv"

  Total de registres: **99545**

  Interval de temps: 01.07.2015 a les 01:00:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP13 <- read.table("VOLVELSP13.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP13)
```

```
              DiaHora          VolSP13          VelSP13
1/1/2016 00:25:00:     1   Min.   :  0.00   Min.   : -1.00
1/1/2016 00:30:00:     1   1st Qu.:  8.00   1st Qu.: 34.42
1/1/2016 00:35:00:     1   Median : 25.00   Median : 43.03
1/1/2016 00:40:00:     1   Mean   : 23.67   Mean   : 42.57
1/1/2016 00:45:00:     1   3rd Qu.: 37.00   3rd Qu.: 50.00
1/1/2016 00:50:00:     1   Max.   :148.00   Max.   :100.00
(Other)           :99539
```

```
> numSummary(VOLVELSP13[,c("VelSP13","VolSP13")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
            mean       sd   se(mean)    IQR        cv 0%   25%   50% 75% 100%     n
VelSP13 42.57335 12.20949 0.03869793 15.58 0.2867871 -1 34.42 43.03  50  100 99545
VolSP13 23.66673 15.99737 0.05070361 29.00 0.6759433  0  8.00 25.00  37  148 99545
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP13[,c("VelSP13","VolSP13")])
```

Coeficient de Pearson: -0,03274637

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP13".

Al gràfic 1-13 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP13) %in% c("DiaHora")
> Nou.VOLVELSP13<-VOLVELSP13[!var.fora]
> pairs.panels(Nou.VOLVELSP13, pch=1,main="Sensor SP-1.3",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-13) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP13, pch=1,main="Sensor SP-1.3", show.points=FALSE, gap=0, method="pearson")
```

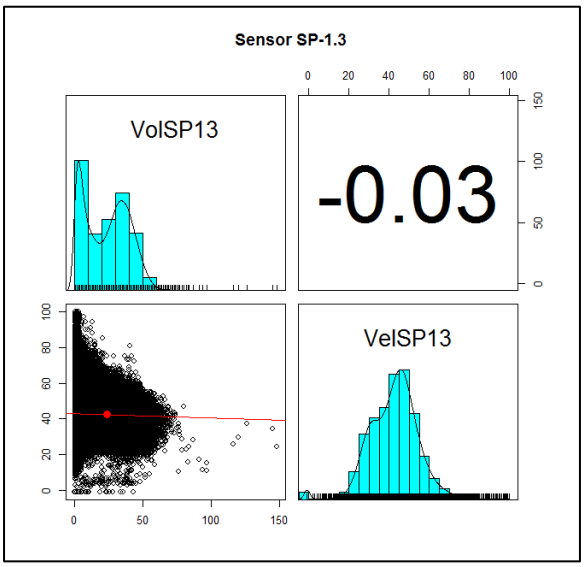

gràfic 1-13

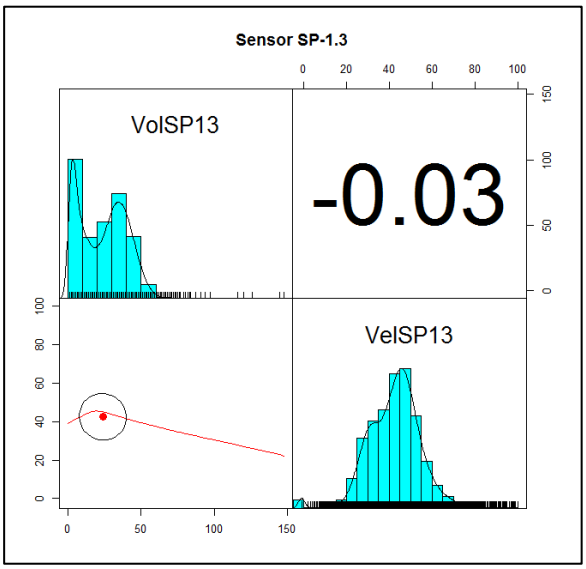

gràfic 2-13

- **Sensor SP-1.4:**

  Fem servir el conjunt de dades "VOLVELSP14.csv"

  Total de registres: **75406**

  Interval de temps: 21.09.2015 a les 10:30:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP14 <- read.table("VOLVELSP14.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP14)
```

```
              DiaHora          VolSP14          VelSP14
1/1/2016 00:00:00:     1   Min.   : 0.00   Min.   : -1.00
1/1/2016 00:10:00:     1   1st Qu.: 4.00   1st Qu.: 31.51
1/1/2016 00:15:00:     1   Median :13.00   Median : 36.62
1/1/2016 00:20:00:     1   Mean   :12.69   Mean   : 35.32
1/1/2016 00:25:00:     1   3rd Qu.:20.00   3rd Qu.: 41.00
1/1/2016 00:30:00:     1   Max.   :70.00   Max.   :100.00
(Other)           :75400
```

```
> numSummary(VOLVELSP14[,c("VelSP14","VolSP110")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
            mean        sd   se(mean)   IQR        cv 0%   25%   50% 75% 100%     n
VelSP14 35.31758 11.099398 0.04042002  9.49 0.3142740 -1 31.51 36.62  41  100 75406
VolSP14 12.69170  9.307502 0.03389457 16.00 0.7333537  0  4.00 13.00  20   70 75406
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP14[,c("VelSP14","VolSP14")])
```

Coeficient de Pearson: 0,1540516

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP14".

Al gràfic 1-14 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP14) %in% c("DiaHora")
> Nou.VOLVELSP14<-VOLVELSP14[!var.fora]
> pairs.panels(Nou.VOLVELSP14, pch=1,main="Sensor SP-1.4",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-14) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP14, pch=1,main="Sensor SP-1.4", show.points=FALSE, gap=0, method="pearson")
```

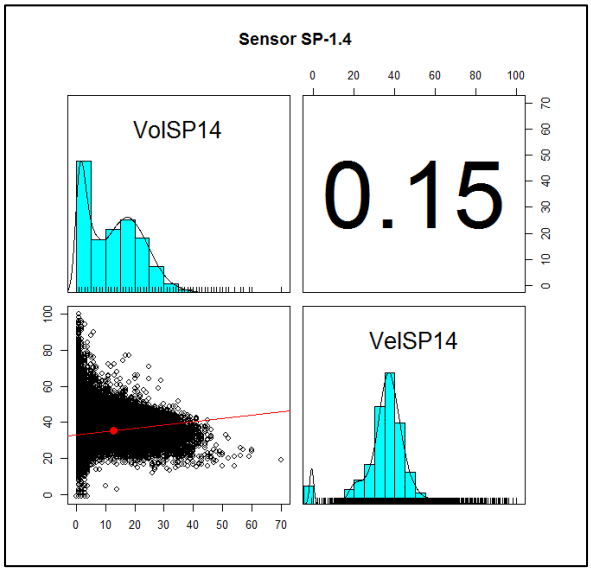

gràfic 1-14

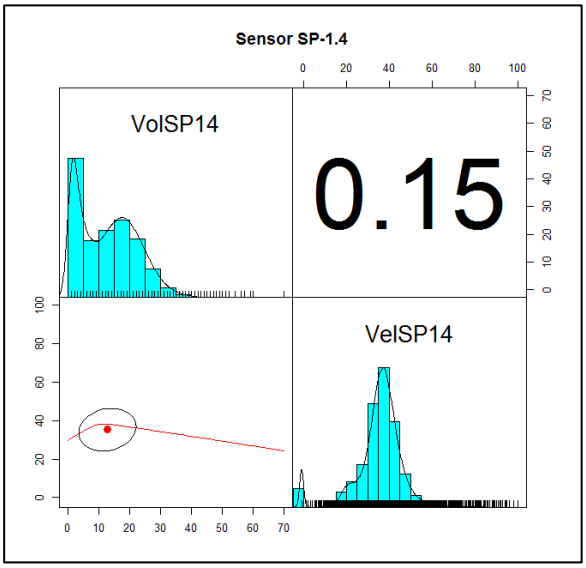

gràfic 2-14

- **Sensor SP-1.5:**

  Fem servir el conjunt de dades "VOLVELSP15.csv"

  Total de registres: **76239**

  Interval de temps: 22.09.2015 a les 10:20:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP15 <- read.table("VOLVELSP15.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP15)
```

```
              DiaHora          VolSP15          VelSP15
1/1/2016 00:00:00:     1   Min.   : 0.00   Min.   :-1.00
1/1/2016 00:05:00:     1   1st Qu.: 7.00   1st Qu.:29.00
1/1/2016 00:10:00:     1   Median :24.00   Median :30.59
1/1/2016 00:15:00:     1   Mean   :21.82   Mean   :30.22
1/1/2016 00:20:00:     1   3rd Qu.:34.00   3rd Qu.:32.00
1/1/2016 00:25:00:     1   Max.   :75.00   Max.   :71.00
(Other)           :76233
```

```
> numSummary(VOLVELSP15[,c("VelSP15","VolSP15")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
            mean        sd   se(mean) IQR        cv 0% 25%   50% 75% 100%     n
VelSP15 30.22370  5.667961 0.02052760   3 0.1875336 -1  29 30.59  32   71 76239
VolSP15 21.81604 15.007628 0.05435299  27 0.6879172  0   7 24.00  34   75 76239
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP15[,c("VelSP15","VolSP15")])
```

Coeficient de Pearson: -0.06530217

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP15".

Al gràfic 1-15 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP15) %in% c("DiaHora")
> Nou.VOLVELSP15<-VOLVELSP15[!var.fora]
> pairs.panels(Nou.VOLVELSP15, pch=1,main="Sensor SP-1.5",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-15) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP15, pch=1,main="Sensor SP-1.5", show.points=FALSE, gap=0, method="pearson")
```

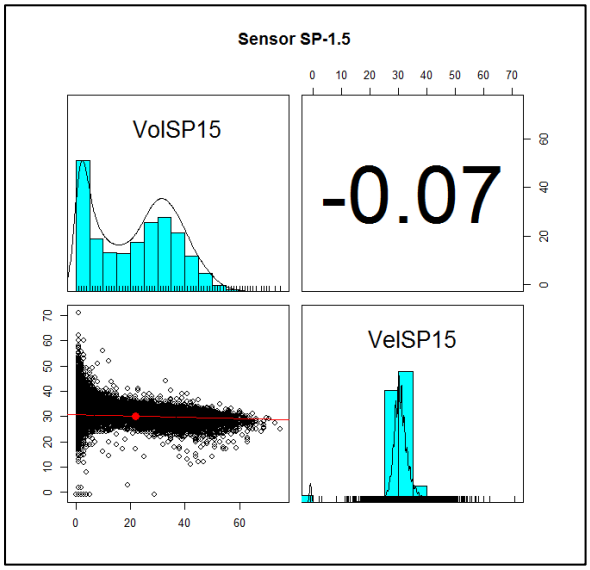

gràfic 1-15

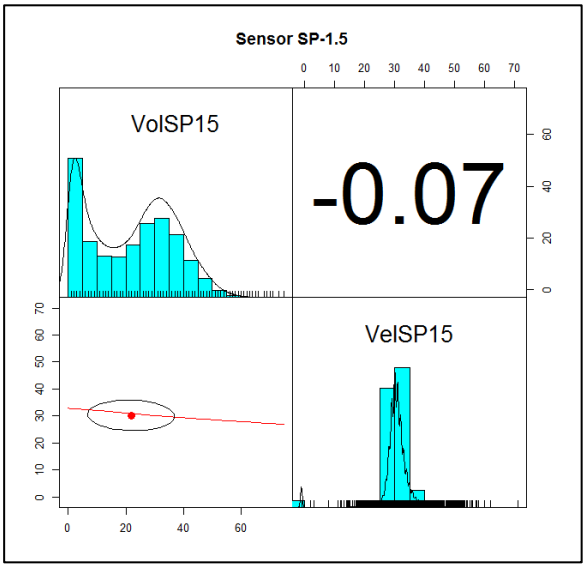

gràfic 2-15

- **Sensor SP-2.1:**

  Fem servir el conjunt de dades "VOLVELSP21.csv"

  Total de registres: **67098**

  Interval de temps: 14.10.2015 a les 08:40:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP21 <- read.table("VOLVELSP21.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP21)
```

```
                DiaHora          VolSP21          VelSP21
 1/1/2016 02:25:00 :     1   Min.   : 0.00   Min.   :-1.00
 1/1/2016 12:25:00 :     1   1st Qu.: 4.00   1st Qu.:28.00
 1/1/2016 17:45:00 :     1   Median :19.00   Median :32.00
 1/1/2016 22:40:00 :     1   Mean   :19.85   Mean   :30.35
 1/11/2015 00:00:00:     1   3rd Qu.:33.00   3rd Qu.:36.00
 1/11/2015 00:05:00:     1   Max.   :85.00   Max.   :84.00
 (Other)            :67092
```

```
> numSummary(VOLVELSP21[,c("VelSP110","VolSP21")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
             mean       sd   se(mean) IQR        cv 0% 25% 50% 75% 100%     n
VelSP21 30.34503 10.27629 0.03967177   8 0.3386482 -1  28  32  36   84 67098
VolSP21 19.84840 15.58738 0.06017533  29 0.7853220  0   4  19  33   85 67098
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP21[,c("VelSP21","VolSP21")])
```

Coeficient de Pearson: 0.004169519

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP21".

Al gràfic 1-21 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP21) %in% c("DiaHora")
> Nou.VOLVELSP21<-VOLVELSP21[!var.fora]
> pairs.panels(Nou.VOLVELSP21, pch=1,main="Sensor SP-2.1",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-21) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP21, pch=1,main="Sensor SP-2.1", show.points=FALSE, gap=0, method="pearson")
```

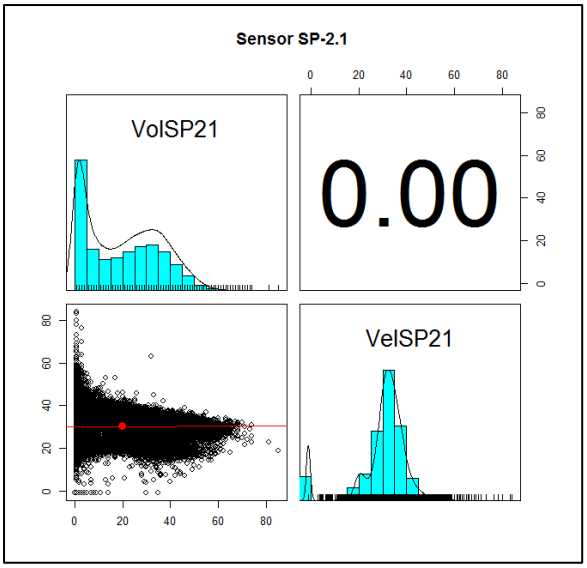

gràfic 1-21

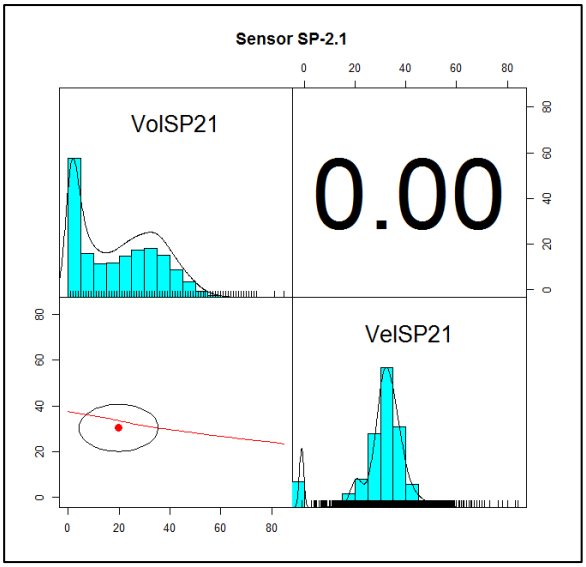

gràfic 2-21

- **Sensor SP-5.5:**

  Fem servir el conjunt de dades "VOLVELSP55.csv"

  Total de registres: **64881**

  Interval de temps: 21.10.2015 a les 12:40:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP55 <- read.table("VOLVELSP55.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP55)
```

```
             DiaHora          VolSP55          VelSP55
1/1/2016 00:05:00:     1   Min.   : 0.000   Min.   :-1.00
1/1/2016 00:15:00:     1   1st Qu.: 2.000   1st Qu.:27.81
1/1/2016 00:20:00:     1   Median : 7.000   Median :34.95
1/1/2016 00:25:00:     1   Mean   : 8.913   Mean   :31.03
1/1/2016 00:30:00:     1   3rd Qu.:14.000   3rd Qu.:39.00
1/1/2016 00:35:00:     1   Max.   :51.000   Max.   :95.00
(Other)           :64875
```

```
> numSummary(VOLVELSP55[,c("VelSP55","VolSP55")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
             mean        sd   se(mean)    IQR        cv 0%   25%   50% 75% 100%     n
VelSP55 31.029020 13.802091 0.05418588 11.19 0.4448124 -1 27.81 34.95  39   95 64881
VolSP55  8.913056  7.531349 0.02956746 12.00 0.8449794  0  2.00  7.00  14   51 64881
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP55[,c("VelSP55","VolSP55")])
```

Coeficient de Pearson: 0.2165775

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP55".

Al gràfic 1-55 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP55) %in% c("DiaHora")
> Nou.VOLVELSP55<-VOLVELSP55[!var.fora]
> pairs.panels(Nou.VOLVELSP55, pch=1,main="Sensor SP-5.5",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-55) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP55, pch=1,main="Sensor SP-5.5", show.points=FALSE, gap=0, method="pearson")
```

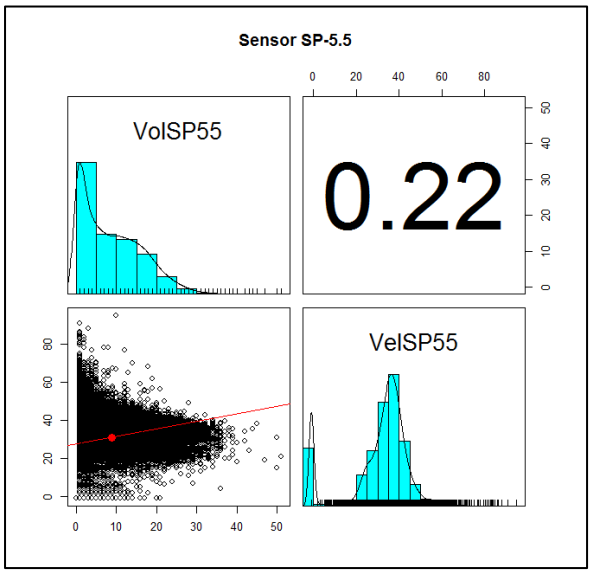

gràfic 1-55

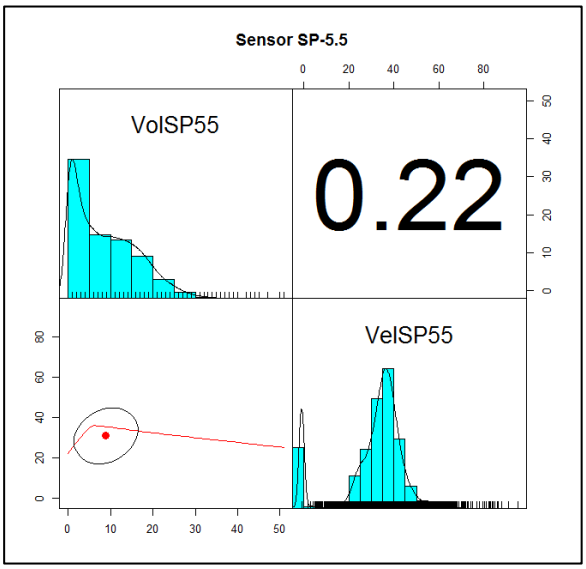

gràfic 2-55

- **Sensor SP-7.3:**

  Fem servir el conjunt de dades "VOLVELSP73.csv"

  Total de registres: **70615**

  Interval de temps: 28.09.2015 a les 11:05:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP73 <- read.table("VOLVELSP73.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP73)
```

```
              DiaHora          VolSP73          VelSP73
1/1/2016 00:00:00:     1   Min.   :  0.0   Min.   : -1.00
1/1/2016 00:10:00:     1   1st Qu.:  4.0   1st Qu.: 39.00
1/1/2016 00:15:00:     1   Median : 16.0   Median : 46.00
1/1/2016 00:20:00:     1   Mean   : 18.8   Mean   : 41.55
1/1/2016 00:25:00:     1   3rd Qu.: 31.0   3rd Qu.: 52.00
1/1/2016 00:30:00:     1   Max.   :218.0   Max.   :100.00
(Other)           :70609
```

```
> numSummary(VOLVELSP73[,c("VelSP73","VolSP73")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
            mean       sd   se(mean) IQR        cv 0% 25% 50% 75% 100%     n
VelSP73 41.54758 18.97616 0.07141013  13 0.4567332 -1  39  46  52  100 70615
VolSP73 18.79894 16.16156 0.06081838  27 0.8597060  0   4  16  31  218 70615
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP73[,c("VelSP73","VolSP73")])
```

Coeficient de Pearson: 0.1275201

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP73".

Al gràfic 1-73 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP73) %in% c("DiaHora")
> Nou.VOLVELSP73<-VOLVELSP73[!var.fora]
> pairs.panels(Nou.VOLVELSP73, pch=1,main="Sensor SP-7.3",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-73) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP73, pch=1,main="Sensor SP-7.3", show.points=FALSE, gap=0, method="pearson")
```

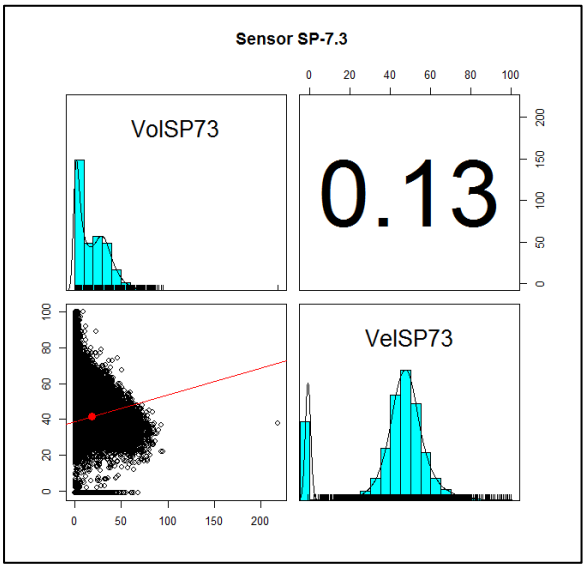

gràfic 1-73

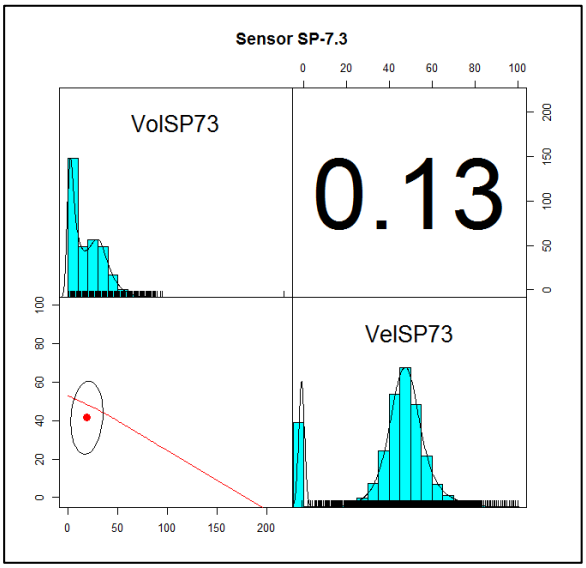

gràfic 2-73

- **Sensor SP-7.4:**

  Fem servir el conjunt de dades "VOLVELSP74.csv"

  Total de registres: **70621**

  Interval de temps: 28.09.2015 a les 10:40:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP74 <- read.table("VOLVELSP74.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP74)
```

```
                DiaHora          VolSP74          VelSP74
1/1/2016 00:00:00:    1   Min.   :  0.00   Min.   : -1.00
1/1/2016 00:10:00:    1   1st Qu.:  5.00   1st Qu.: 49.00
1/1/2016 00:15:00:    1   Median : 20.00   Median : 59.00
1/1/2016 00:20:00:    1   Mean   : 22.72   Mean   : 50.66
1/1/2016 00:25:00:    1   3rd Qu.: 38.00   3rd Qu.: 65.70
1/1/2016 00:30:00:    1   Max.   :108.00   Max.   :100.00
(Other)           :70615
```

```
> numSummary(VOLVELSP74[,c("VelSP74","VolSP74")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
             mean       sd   se(mean)  IQR        cv 0% 25% 50%  75% 100%     n
VelSP74 50.65647 25.35594 0.09541415 16.7 0.5005469 -1  49  59 65.7  100 70621
VolSP74 22.72420 19.14791 0.07205339 33.0 0.8426217  0   5  20 38.0  108 70621
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP74[,c("VelSP74","VolSP74")])
```

Coeficient de Pearson: 0.3082884

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP74".

Al gràfic 1-74 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP74) %in% c("DiaHora")
> Nou.VOLVELSP74<-VOLVELSP74[!var.fora]
> pairs.panels(Nou.VOLVELSP74, pch=1,main="Sensor SP-7.4",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-74) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP74, pch=1,main="Sensor SP-7.4", show.points=FALSE, gap=0, method="pearson")
```

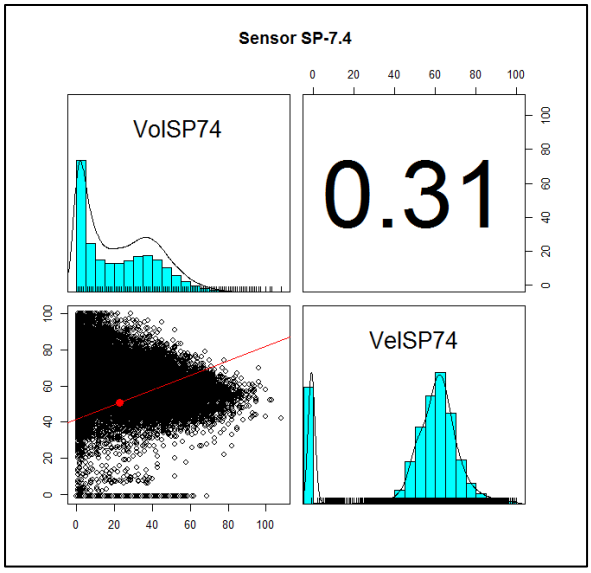

gràfic 1-74

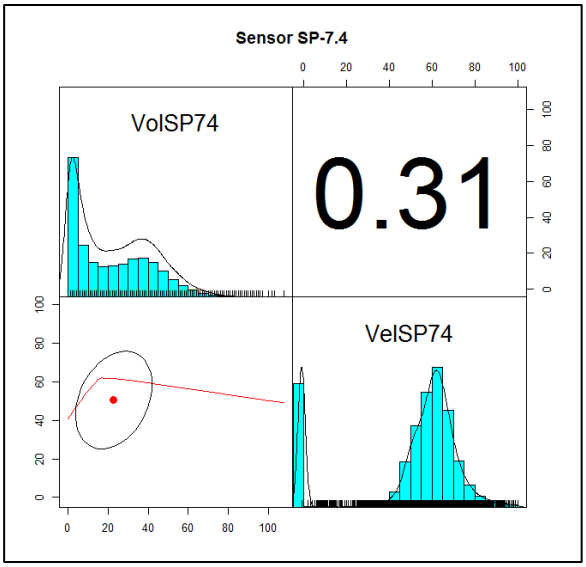

gràfic 2-74

- **Sensor SP-7.5:**

  Fem servir el conjunt de dades "VOLVELSP75.csv"

  Total de registres: **68862**

  Interval de temps: 28.09.2015 a les 12:55:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP75 <- read.table("VOLVELSP75.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP75)
```

```
                DiaHora          VolSP75          VelSP75
1/1/2016 00:00:00:     1   Min.   :  0.00   Min.   :-1.00
1/1/2016 00:05:00:     1   1st Qu.:  3.00   1st Qu.:36.00
1/1/2016 00:10:00:     1   Median : 12.00   Median :40.00
1/1/2016 00:15:00:     1   Mean   : 14.41   Mean   :37.23
1/1/2016 00:20:00:     1   3rd Qu.: 24.00   3rd Qu.:44.00
1/1/2016 00:25:00:     1   Max.   :159.00   Max.   :99.74
(Other)           :68856
```

```
> numSummary(VOLVELSP75[,c("VelSP75","VolSP75")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
            mean       sd   se(mean) IQR        cv 0% 25% 50% 75%   100%     n
VelSP75 37.23293 14.21123 0.05415542   8 0.3816845 -1  36  40  44  99.74 68862
VolSP75 14.41203 12.21768 0.04655848  21 0.8477417  0   3  12  24 159.00 68862
Warning message:
In cv(X) : not all values are positive
```

Correlació lineal de Pearson:

```
> cor(VOLVELSP75[,c("VelSP75","VolSP75")])
```

Coeficient de Pearson: 0.1123119

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP75".

Al gràfic 1-75 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP75) %in% c("DiaHora")
> Nou.VOLVELSP75<-VOLVELSP75[!var.fora]
> pairs.panels(Nou.VOLVELSP75, pch=1,main="Sensor SP-7.5",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-75) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP75, pch=1,main="Sensor SP-7.5", show.points=FALSE, gap=0, method="pearson")
```

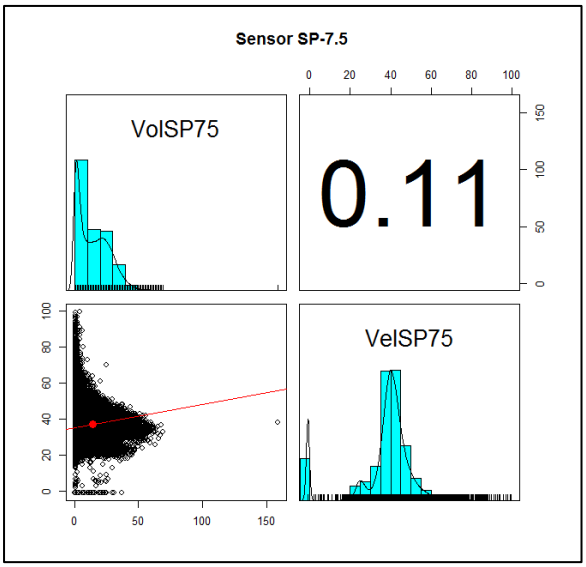

gràfic 1-75

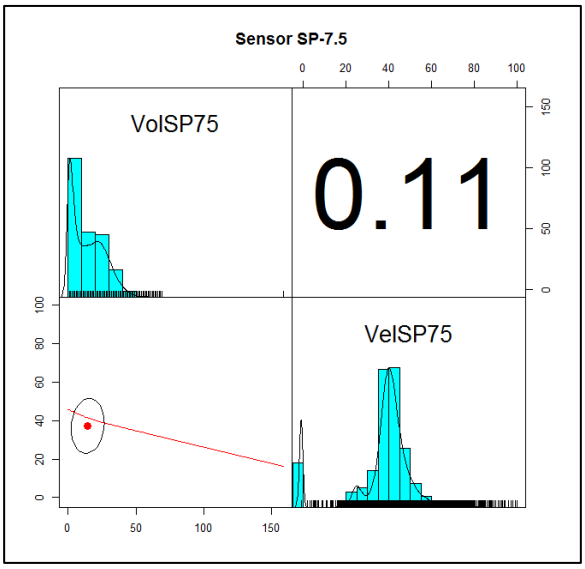

gràfic 2-75

- **Sensor SP-7.6:**

  Fem servir el conjunt de dades "VOLVELSP76.csv"

  Total de registres: **70428**

  Interval de temps: 28.09.2015 a les 12:20:00 fins 30.06.2016 a les 23:55:00

```
> VOLVELSP76 <- read.table("VOLVELSP76.csv", header=TRUE, sep=",", dec=".", strip.white=TRUE)
> summary(VOLVELSP76)
```

```
              DiaHora          VolSP76          VelSP76
 1/1/2016 00:00:00:    1   Min.   :  0.00   Min.   : -1.00
 1/1/2016 00:05:00:    1   1st Qu.:  4.00   1st Qu.: 44.00
 1/1/2016 00:10:00:    1   Median : 16.00   Median : 50.00
 1/1/2016 00:15:00:    1   Mean   : 18.53   Mean   : 46.02
 1/1/2016 00:20:00:    1   3rd Qu.: 28.00   3rd Qu.: 55.00
 1/1/2016 00:25:00:    1   Max.   :599.00   Max.   :100.00
 (Other)           :70422
```

```
> numSummary(VOLVELSP76[,c("VelSP76","VolSP76")],statistics=c("mean","sd","se(mean)","IQR","quantiles","cv"),
quantiles=c(0,.25,.5,.75,1))
```

```
             mean       sd   se(mean) IQR        cv 0% 25% 50% 75% 100%     n
VelSP76 46.02315 17.00614 0.06408157  11 0.3695128 -1  44  50  55  100 70428
VolSP76 18.52533 26.07232 0.09824420  24 1.4073873  0   4  16  28  599 70428
Warning message:
In cv(X) : not all values are positive
```

Correlació linear de Pearson:

```
> cor(VOLVELSP76[,c("VelSP76","VolSP76")])
```

Coeficient de Pearson: -0.07105468

Representació gràfica:

Excloem la variable "DiaHora" de la taula i fem servir una nova taula "Nou.VOLVELSP76".

Al gràfic 1-76 tenim la distribució de dades de Volum i de Velocitat, la correlació de Pearson i el núvol de punts amb la seva tendència (lm=TRUE).

```
> var.fora<-names(VOLVELSP76) %in% c("DiaHora")
> Nou.VOLVELSP76<-VOLVELSP76[!var.fora]
> pairs.panels(Nou.VOLVELSP76, pch=1,main="Sensor SP-7.6",method="pearson",lm=TRUE)
```

Si volem amagar els punts i veure l'el·lipse de concentració i la línia de punts suavitzada (gràfic 2-76) donarem l'ordre R

```
> pairs.panels(Nou.VOLVELSP76, pch=1,main="Sensor SP-7.6", show.points=FALSE, gap=0, method="pearson")
```

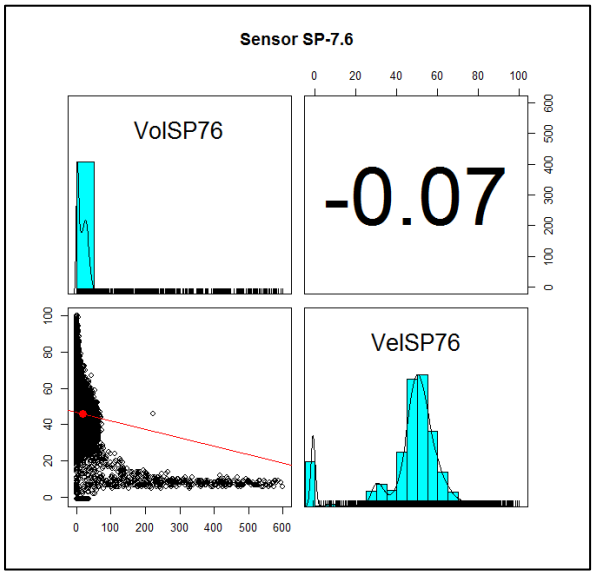

gràfic 1-76

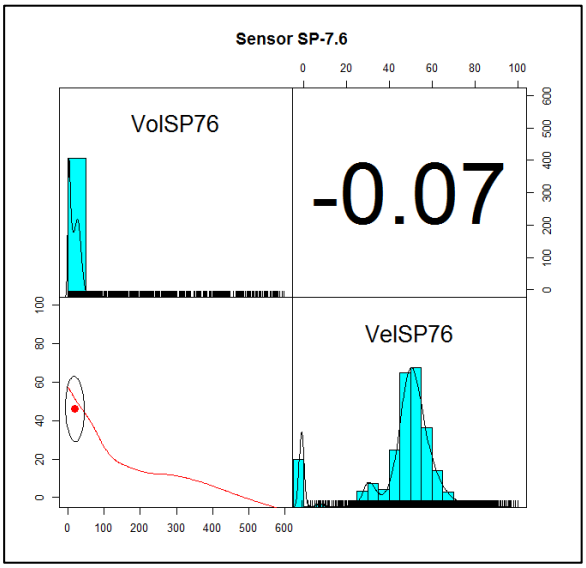

gràfic 2-76

Podem concloure amb aquesta informació que:

- La distribució de dades és molt semblant en tots els punts (sensors), llevat del sensors SP-7.6 de la Plaça El·líptica, que per alguna raó té molts valors de volum de trànsit anormals. També els sensors SP-1.3, SP-7.3 i SP-7.5 tenen alguns valors atípics fora del rang normal.
- El coeficient de correlació de Pearson en tots els casos dona valors al voltant del zero i per tant hi ha realment poca o nul·la correlació lineal entre el volum de trànsit i la velocitat mitjana en períodes de 5 minuts. De vegades hi ha una petita correlació positiva i de vegades una petita correlació negativa.

4.5 EL PHF (PEAK HOUR FACTOR)

Per tenir una idea del volum de trànsit mitjà durant una hora en cada punt o sensor aplicarem el coeficient PHF segons el "*Highway Capacity Manual*[49]" però en aquest cas farem servir períodes de 5 minuts. La fórmula a aplicar: $PHF = \frac{V_{av}^{60}}{\frac{60}{n} \cdot V_{av}^{n}}$ on V_{av}^{60} és el volum mitjà de trànsit en un període pic de 60 minuts, n és el període a considerar, en aquest cas 5 minuts, i V_{av}^{n} és el pic en n minuts, en aquest cas en 5 minuts.

SP-1.10

Dia	Hora	VolSP110	
10/06/2016	07:00:00	18	Suma
10/06/2016	07:05:00	24	350
10/06/2016	07:10:00	21	
10/06/2016	07:15:00	18	PHF
10/06/2016	07:20:00	14	0,39
10/06/2016	07:25:00	13	
10/06/2016	07:30:00	16	MaxH
10/06/2016	07:35:00	25	888
10/06/2016	07:40:00	42	
10/06/2016	07:45:00	34	
10/06/2016	07:50:00	51	
10/06/2016	07:55:00	74	

SP-1.3

Dia	Hora	VolSP13	
21/03/2016	14:00:00	31	Suma
21/03/2016	14:05:00	20	536
21/03/2016	14:10:00	42	
21/03/2016	14:15:00	23	PHF
21/03/2016	14:20:00	26	0,30
21/03/2016	14:25:00	30	
21/03/2016	14:30:00	33	MaxH
21/03/2016	14:35:00	69	1776
21/03/2016	14:40:00	148	
21/03/2016	14:45:00	38	
21/03/2016	14:50:00	43	
21/03/2016	14:55:00	33	

SP-1.4

Dia	Hora	VolSP14	
01/10/2015	15:00:00	35	Suma
01/10/2015	15:05:00	42	447
01/10/2015	15:10:00	45	
01/10/2015	15:15:00	36	PHF
01/10/2015	15:20:00	70	0,53
01/10/2015	15:25:00	42	
01/10/2015	15:30:00	28	MaxH
01/10/2015	15:35:00	27	840
01/10/2015	15:40:00	16	
01/10/2015	15:45:00	39	
01/10/2015	15:50:00	15	
01/10/2015	15:55:00	52	

SP-1.5

Dia	Hora	VolSP15	
29/10/2015	13:00:00	41	Suma
29/10/2015	13:05:00	35	548
29/10/2015	13:10:00	50	
29/10/2015	13:15:00	75	PHF
29/10/2015	13:20:00	49	0,61
29/10/2015	13:25:00	50	
29/10/2015	13:30:00	45	MaxH
29/10/2015	13:35:00	40	900
29/10/2015	13:40:00	42	
29/10/2015	13:45:00	40	
29/10/2015	13:50:00	51	
29/10/2015	13:55:00	30	

SP-2.1

Dia	Hora	VolSP21	
26/10/2015	17:00:00	22	Suma
26/10/2015	17:05:00	68	468
26/10/2015	17:10:00	2	
26/10/2015	17:15:00	8	PHF
26/10/2015	17:20:00	20	0,46
26/10/2015	17:25:00	35	
26/10/2015	17:30:00	22	MaxH
26/10/2015	17:35:00	66	1020
26/10/2015	17:40:00	48	
26/10/2015	17:45:00	54	
26/10/2015	17:50:00	38	
26/10/2015	17:55:00	85	

SP-5.5

Dia	Hora	VolSP55	
30/11/2015	10:00:00	11	Suma
30/11/2015	10:05:00	33	359
30/11/2015	10:10:00	31	
30/11/2015	10:15:00	9	PHF
30/11/2015	10:20:00	31	0,59
30/11/2015	10:25:00	51	
30/11/2015	10:30:00	50	MaxH
30/11/2015	10:35:00	34	612
30/11/2015	10:40:00	29	
30/11/2015	10:45:00	25	
30/11/2015	10:50:00	27	
30/11/2015	10:55:00	28	

SP-7.3

Dia	Hora	VolSP73	
27/11/2015	13:00:00	15	Suma
27/11/2015	13:05:00	64	528
27/11/2015	13:10:00	48	
27/11/2015	13:15:00	95	PHF
27/11/2015	13:20:00	57	0,46
27/11/2015	13:25:00	46	
27/11/2015	13:30:00	47	MaxH
27/11/2015	13:35:00	27	1140
27/11/2015	13:40:00	30	
27/11/2015	13:45:00	30	
27/11/2015	13:50:00	28	
27/11/2015	13:55:00	41	

SP-7.4

Dia	Hora	VolSP74	
24/11/2015	15:00:00	108	Suma
24/11/2015	15:05:00	66	721
24/11/2015	15:10:00	66	
24/11/2015	15:15:00	42	PHF
24/11/2015	15:20:00	62	0,56
24/11/2015	15:25:00	52	
24/11/2015	15:30:00	65	MaxH
24/11/2015	15:35:00	57	1296
24/11/2015	15:40:00	53	
24/11/2015	15:45:00	52	
24/11/2015	15:50:00	47	
24/11/2015	15:55:00	51	

SP-7.5

Dia	Hora	VolSP75	
23/12/2015	19:00:00	61	Suma
23/12/2015	19:05:00	39	508
23/12/2015	19:10:00	33	
23/12/2015	19:15:00	44	PHF
23/12/2015	19:20:00	44	0,61
23/12/2015	19:25:00	29	
23/12/2015	19:30:00	49	MaxH
23/12/2015	19:35:00	24	828
23/12/2015	19:40:00	69	
23/12/2015	19:45:00	37	
23/12/2015	19:50:00	40	
23/12/2015	19:55:00	39	

SP-7.6

Dia	Hora	VolSP76	
03/02/2016	07:00:00	1068	Suma
03/02/2016	07:05:00	812	10362
03/02/2016	07:10:00	1051	
03/02/2016	07:15:00	950	PHF
03/02/2016	07:20:00	854	0,81
03/02/2016	07:25:00	728	
03/02/2016	07:30:00	883	MaxH
03/02/2016	07:35:00	871	12816
03/02/2016	07:40:00	915	
03/02/2016	07:45:00	942	
03/02/2016	07:50:00	709	
03/02/2016	07:55:00	579	

Taula d'elaboració pròpia

Conceptes:

- Suma: és la suma de tots els períodes de 5 minuts durant una hora on consta el període de volum de trànsit pic (color groc).
- PHF: Factor d'hora pic calculat segons la fórmula. Si no es pot calcular, el "Highway Capacity Manual" recomana un valor de 0,92 per a àrees urbanes.
- MaxH: valor màxim d'aquest conjunt de períodes de 5 minuts amb el factor pic.

[49] http://www.gsweventcenter.com/Draft_SEIR_References%5C2000_TRB.pdf

4.6 PREDICCIÓ DEL VOLUM DE TRÀNSIT

Si fem l'anàlisi del volum de **trànsit acumulat diàriament** des de l'1 de novembre de 2015 fins el 27 de juny de 2016 per cada sensor dels 10 de tipus "carril" ens dona un total de 240 dies, que si es fa una divisió de 30 dies per període tindrem 8 períodes virtuals de la mateixa mida.

Això és un sistema estocàstic de variables aleatòries $\{X_t, amb\ t \in T\}$ ordenades segons el subíndex t temporal, i ja que T va saltant en observacions diàries podem considerar que és un procés estocàstic de paràmetre discret.

A partir de les dades disponibles d'aquests sensors cada 5 minuts entre les dades indicades es fa un **acumulat diari** i s'observa que hi ha valors atípics, normalment baixos, degut a errors tècnics. Es decideix fer una imputació amb la mitjana de tots els valors.

Sabent que totes les dades són valors diaris acumulats entre les dates 01/11/2015 i 27/06/2016 ininterrompudament eliminem la variable data i ens quedarà per cada sensor un fitxer amb un llistat de valors del volum de trànsit corresponent a cada dia i ordenats per dates.

Farem servir els fitxers .dat que hem preparat :
https://drive.google.com/open?id=0B728doyg6XT-Y3NtSGcxcnRjZXc

L'objectiu que perseguim és fer una **predicció diària** del flux de trànsit en cada punt (sensor) estudiat partint de la base que disposem de 8 mesos de dades força fiables. Aquestes dades són sèries temporals (Time Series) i farem servir, per cada sensor, representacions gràfiques, descomposició, suavitzat i diverses funcions que ens proporciona l'entorn R.

- **Sensor SP-1.10** (fitxer SP110diari.dat)

Amb la gràfica BoxPlot tenim una primera observació de les dades d'aquest sensor.

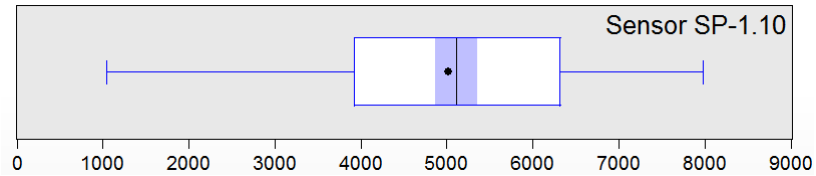

Amb els valor disponibles es fa una primera aproximació estadística d'aquestes dades. Un histograma amb tots els valors observats per cada grup de volum de vehicles (agrupacions de 250).

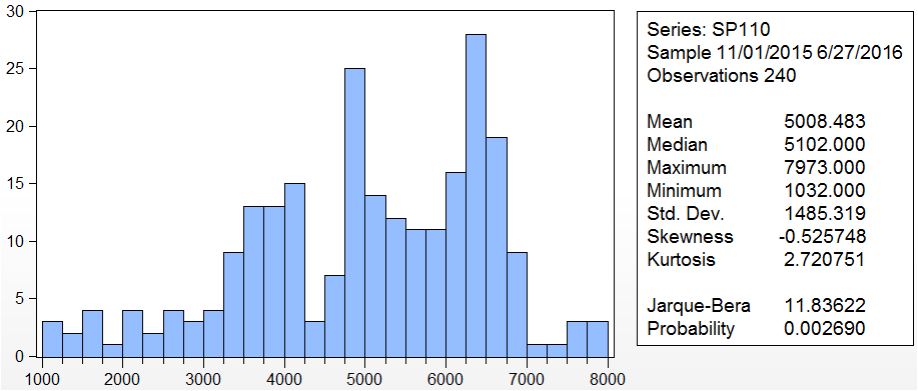

Es fa la lectura del fitxer de dades i es converteix en sèrie de temps (Time Series) amb la funció ts(). Seguidament es fa la representació gràfica de les dades originals i de la sèrie temporal.

```
> diari110 <- scan("SP110diari.dat")
Read 240 items
> diari110ts <- ts(diari110)
> diari110ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 3327 5582 5705 5490 6100 5886 4891 3633 5517 5970 5826 4299 6031 3789 3612 4965 5552 5496 5741
 [20] 5953 4145 3243 3761 3717 4900 2797 4605 3761 3254 1032 2232 1733 1970 2587 2843 2629 4058 2707
 [39] 5252 3718 3610 1575 1177 2161 2173 4960 5261 6287 5011 3760 5538 3490 5715 5104 3516 3664 3238
 [58] 4856 4948 4761 4761 4761 4761 4761 2194 3033 3325 5420 5854 3828 3278 5010 5618 4204 5032 5725
 [77] 4351 3360 3809 2848 5471 4762 4544 4097 3415 5049 4658 5841 3567 4761 1562 3706 4224 4845 4761
 [96] 4761 6007 4671 3453 5043 5150 3973 4761 4761 4761 4761 4761 6523 7632 7894 7973 6555 4857 7761
[115] 7727 7594 6890 6556 4782 3801 6069 6311 6159 6827 6802 5137 3903 6091 6392 6177 6622 6635 5089
[134] 3894 5992 6334 6148 6598 6440 5706 3659 5752 5858 5961 6249 4248 4707 4002 3866 6426 6314 6741
[153] 6656 5024 4057 6155 6682 6311 6803 6586 5296 3920 6099 6434 6383 6679 6599 5100 4103 6113 6263
[172] 6311 6700 6623 5550 4074 6435 6477 6512 7136 6399 5466 4975 5351 4205 6432 3663 6672 5799 4608
[191] 1479 6440 6205 2737 6284 5156 4375 1302 6214 6027 2294 6417 5304 3905 2369 6739 6325 1712 6307
[210] 5115 3575 3008 6344 6392 1093 6426 5137 3558 3326 6605 6329 4761 6795 5404 4082 6672 6835 6812
[229] 7355 6869 5406 4085 6313 6464 6338 6837 4078 4745 4125 6083
> plot(diari110, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 27/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-1.10",cex.main=1.5, font.main=2)
> plot.ts(diari110ts, xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-1.10",cex.main=1.5, font.main=2)
```

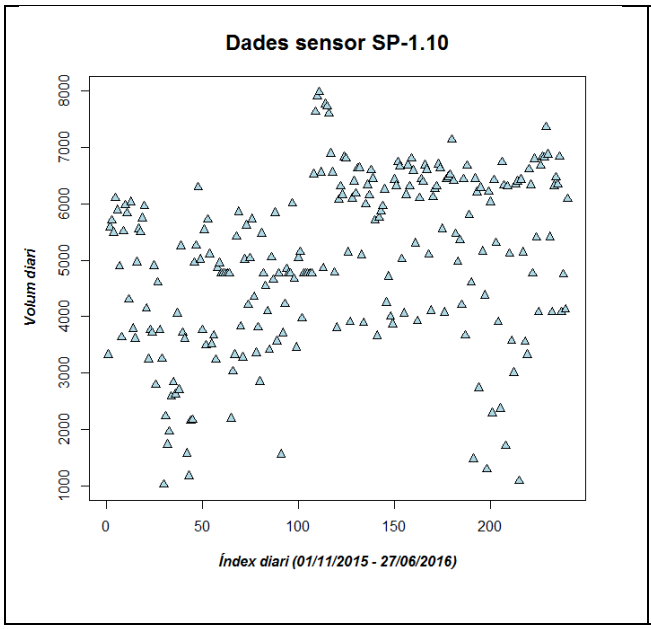

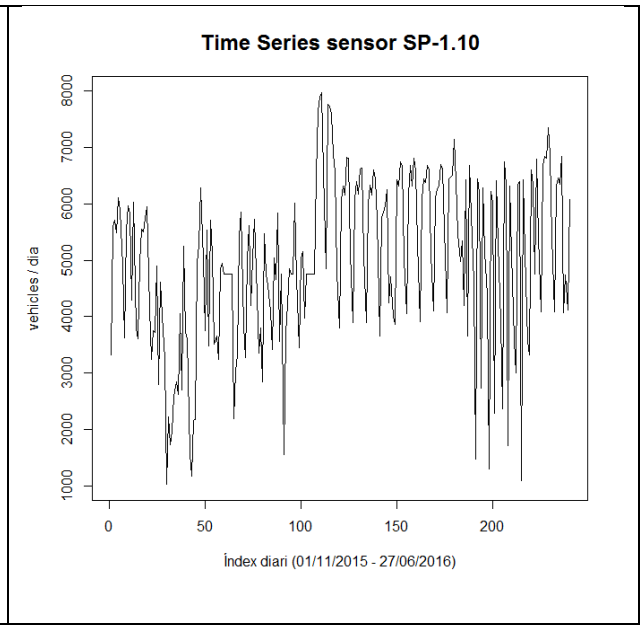

Una primera estimació de la tendència d'aquesta sèrie de temps la podem visualitzar suavitzant amb una mitjana mòbil simple d'ordre 10 (ordre que s'ha estimat per tanteig).

```
> diari110SMA<-SMA(diari110ts, n=10)
> plot.ts(diari110ts, xlim=c(0,250), ylim=c(0,8000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-1.10 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari110SMA, col="red", xlim=c(0,250), ylim=c(0,8000), xlab="", ylab="", lty=1, lwd=3)
```

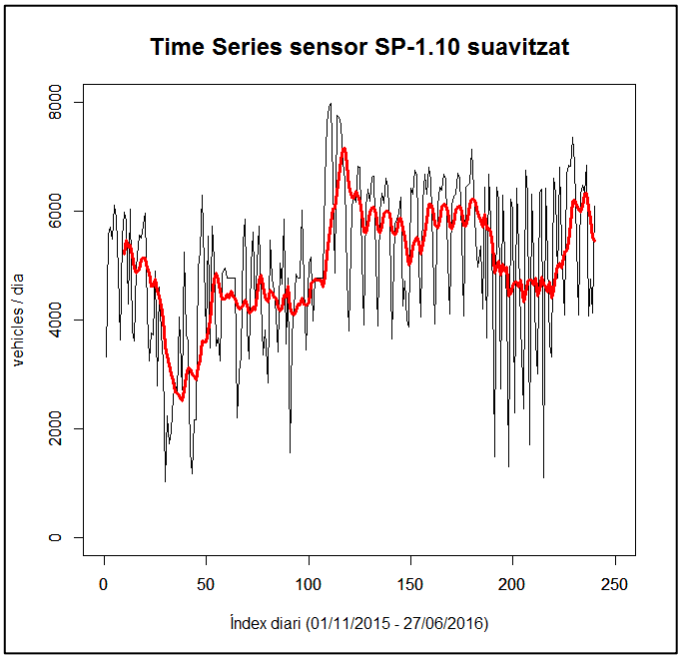

La línia vermella suavitzada de mitjana mòbil ens dona una visió clara de la tendència. El valor més comú és de l'ordre de 4000 a 6000 vehicles diaris.

Descomposició de les dades estacionals:

La sèrie de temps estacionals té tres components: component de tendència (**trend component**), component estacional (**seasonal component**) i component aleatori o irregular (**irregular component**).

Podem fer servir un model additiu per estimar aquests tres components a partir de la funció decompose() de R (mètode STL) i es crearan tres variables, "trend", "seasonal" i "random" que ens permetrà crear la gràfica dels seus valors. Disposem de dades des de l'1 de novembre de 2015 fins el 27 de juny de 2016 (8 mesos) i per tant podem separar totes les dades en grups de mesos virtuals de 30 dies (frequency = 30).

```
> diari110ts <- ts(diari110, frequency=30)
> diaricompo110<-decompose(diari110ts)
> plot(diaricompo110, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

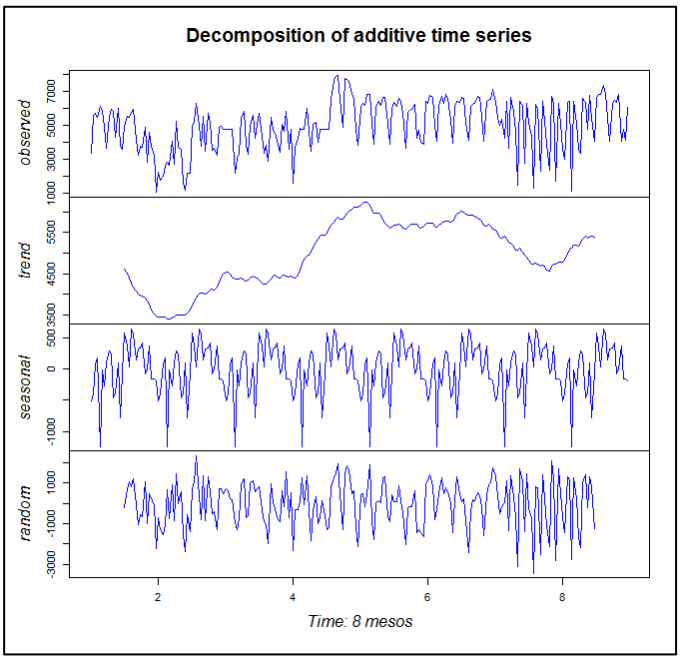

Funció HoltWinters()

Model de suavitzat exponencial que s'adapta fàcilment a canvis i tendències i a patrons estacionals.

Les previsions es fan sobre el mateix període de temps observat.

El valor d'alpha ha d'estar entre 0 i 1. Si el valor d'alpha s'acosta a 0 vol dir que els valors més grans observats tenen un major pes i si el valor d'alpha s'acosta a 1 vol dir que l'últim valor té més pes. Si alpha és NULL significa que la funció ha de trobar el valor òptim d'alpha.

El valor beta suavitza el component de tendència. S'omet si és FALS.

El valor gamma suavitza el component estacional. S'omet si és FALS.

Apliquem el model **Holt-Winters** de suavitzat exponencial.

```
> diari110tsforecast<-HoltWinters(diari110ts, beta=FALSE, gamma=FALSE)
> diari110tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari110ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.19082
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 5457.26
```

Podem observar que alpha = 0.19082 (més a prop del 0 que de l'1) i per tant els valors més grans tenen més pes que observacions més recents.

Ajustem aquests valors amb la variable "fitted".

```
> diari110tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(9, 3)
Frequency = 30
                xhat     level
1.033333 3327.000 3327.000
1.066667 3757.299 3757.299
1.100000 4128.959 4128.959
1.133333 4388.673 4388.673
1.166667 4715.228 4715.228
1.200000 4938.635 4938.635
1.233333 4929.545 4929.545
1.266667 4682.139 4682.139
...
8.733333 5743.134 5743.134
8.766667 5851.876 5851.876
8.800000 5968.682 5968.682
8.833333 6039.155 6039.155
8.866667 6191.400 6191.400
8.900000 5788.121 5788.121
8.933333 5589.073 5589.073
8.966667 5309.698 5309.698
```

I ara fem el gràfic de les dades originals i les previsions.

```
> plot(diari110tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-1.10)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

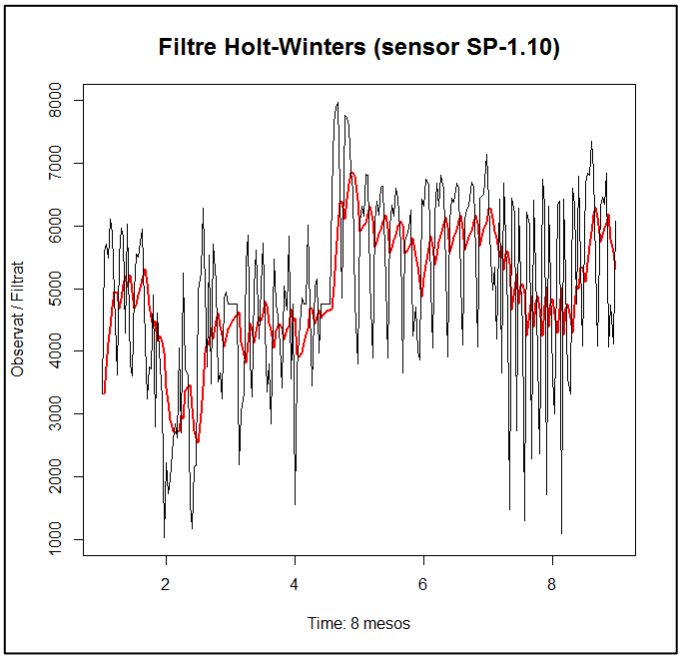

La sèrie de temps original es mostra en negre i les previsions en vermell. S'observa que aquestes són més suaus que les originals.

Ja hem comentat que la funció HoltWinters() dona per defecte la predicció pel període de temps dels valors originals observats. Si volem fer prediccions fora d'aquest període farem servir la funció forecast().

De les nostres dades originals tenim 8 períodes de 30 dies. Si volem fer una predicció d'un altre període de 30 dies utilitzarem el paràmetres h=30 i observem tots els valors generats.

```
> diari110tsforecast2<-forecast.HoltWinters(diari110tsforecast, h=30)
> diari110tsforecast2
     Point    Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000     5457.26 3763.897 7150.622 2867.486 8047.034
9.033333     5457.26 3733.343 7181.176 2820.757 8093.762
9.066667     5457.26 3703.322 7211.198 2774.843 8139.676
9.100000     5457.26 3673.805 7240.714 2729.701 8184.818
9.133333     5457.26 3644.769 7269.750 2685.295 8229.224
9.166667     5457.26 3616.191 7298.328 2641.589 8272.931
9.200000     5457.26 3588.050 7326.469 2598.551 8315.969
9.233333     5457.26 3560.327 7354.193 2556.151 8358.368
9.266667     5457.26 3533.002 7381.517 2514.362 8400.157
9.300000     5457.26 3506.061 7408.459 2473.158 8441.361
9.333333     5457.26 3479.486 7435.033 2432.516 8482.004
9.366667     5457.26 3453.264 7461.256 2392.412 8522.107
9.400000     5457.26 3427.380 7487.139 2352.827 8561.693
9.433333     5457.26 3401.822 7512.697 2313.739 8600.780
9.466667     5457.26 3376.578 7537.941 2275.132 8639.387
9.500000     5457.26 3351.637 7562.882 2236.988 8677.531
9.533333     5457.26 3326.988 7587.531 2199.291 8715.229
9.566667     5457.26 3302.621 7611.898 2162.024 8752.495
9.600000     5457.26 3278.526 7635.993 2125.174 8789.345
9.633333     5457.26 3254.695 7659.824 2088.728 8825.791
9.666667     5457.26 3231.119 7683.400 2052.671 8861.848
9.700000     5457.26 3207.790 7706.729 2016.993 8897.526
9.733333     5457.26 3184.701 7729.819 1981.681 8932.839
9.766667     5457.26 3161.843 7752.676 1946.723 8967.796
9.800000     5457.26 3139.212 7775.308 1912.111 9002.408
9.833333     5457.26 3116.798 7797.721 1877.833 9036.686
9.866667     5457.26 3094.598 7819.921 1843.881 9070.639
9.900000     5457.26 3072.604 7841.915 1810.244 9104.275
9.933333     5457.26 3050.812 7863.708 1776.915 9137.604
9.966667     5457.26 3029.214 7885.305 1743.885 9170.634
> plot.forecast(diari110tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-1.10)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

La predicció es dona amb un interval del 80 % (gris fosc) i un 95 % (gris suau).

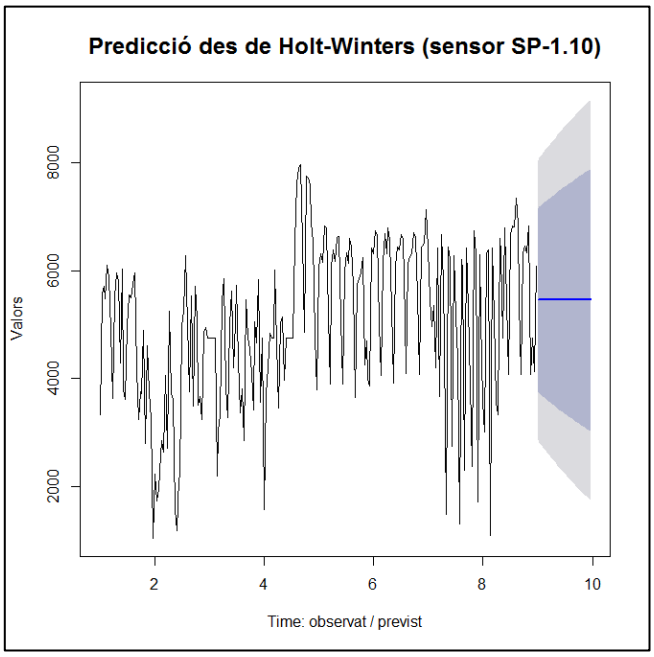

Els errors de predicció (*"forecast errors"*) es calculen amb la diferència dels valors observats i els valors previstos. Aquests errors s'acumulen a la variable "residuals" tornada per la funció forecast.HoltWinters().

Podem obtenir el **correlograma** d'errors de predicció fent servir la funció d'autocorrelació acf() per a retards d'ordre 30.

```
> acf(diari110tsforecast2$residuals, lag.max=30)
```

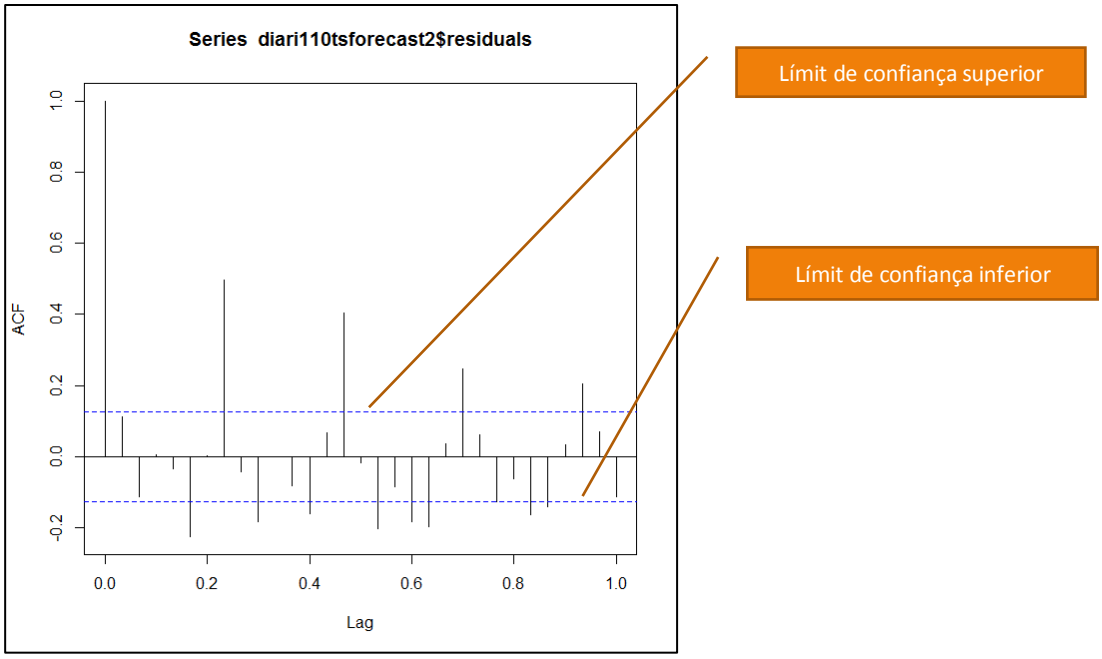

Per poder provar si hi ha evidència significativa de correlacions no nul·les en aquests retards podem fer servir el test de Ljung-Box amb la funció de R Box.test().

```
> Box.test(diari110tsforecast2$residuals, lag=30, type="Ljung-Box")
      Box-Ljung test
data:  diari110tsforecast2$residuals
X-squared = 222.42, df = 30, p-value < 2.2e-16
```

Veiem que el test Ljung-Box dona 222,42 i que el p-value és un valor molt petit. Això ens indica poca evidència d'autocorrelacions no nul·les amb els erros de pronòstic amb aquesta mostra.

Encara podem fer un test per comprovar si els errors de pronòstic es distribueixen normalment amb mitjana zero i variància constant. Per fer això fem la gràfica dels residus.

```
> plot.ts(diari110tsforecast2$residuals)
```

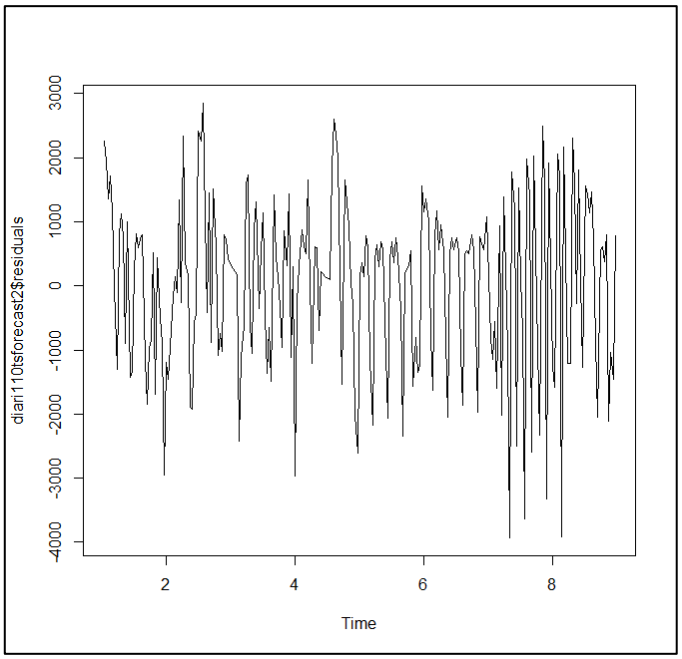

En aquesta gràfica podem observar que els errors de pronòstic semblen tenir variància més o menys constant en el temps encara que al voltant del mes 8 hi ha més fluctuació.

I la última comprovació, es tracta de comprovar si els errors de pronòstic es distribueixen normalment amb mitjana zero fent servir un histograma i superposant una corba normal que té mitjana zero i la mateixa desviació estàndard com la distribució d'errors de predicció. Per fer aquesta comprovació podem elaborar una funció que podem cridar amb les dades de residus.

```
> plotForecastErrors <- function(forecasterrors)
  {
     # make a histogram of the forecast errors:
     mybinsize <- IQR(forecasterrors)/4
     mysd   <- sd(forecasterrors)
     mymin  <- min(forecasterrors) - mysd*5
     mymax  <- max(forecasterrors) + mysd*3
     # generate normally distributed data with mean 0 and standard deviation mysd
     mynorm <- rnorm(10000, mean=0, sd=mysd)
     mymin2 <- min(mynorm)
     mymax2 <- max(mynorm)
     if (mymin2 < mymin) { mymin <- mymin2 }
     if (mymax2 > mymax) { mymax <- mymax2 }
     # make a red histogram of the forecast errors, with the normally distributed
data overlaid:
     mybins <- seq(mymin, mymax, mybinsize)
     hist(forecasterrors, col="red", freq=FALSE, breaks=mybins)
     # freq=FALSE ensures the area under the histogram = 1
     # generate normally distributed data with mean 0 and standard deviation mysd
     myhist <- hist(mynorm, plot=FALSE, breaks=mybins)
     # plot the normal curve as a blue line on top of the histogram of forecast
errors:
     points(myhist$mids, myhist$density, type="l", col="blue", lwd=2)
  }
```

Cridem la funció per construir la gràfica:

```
> plotForecastErrors(diari110tsforecast2$residuals)
```

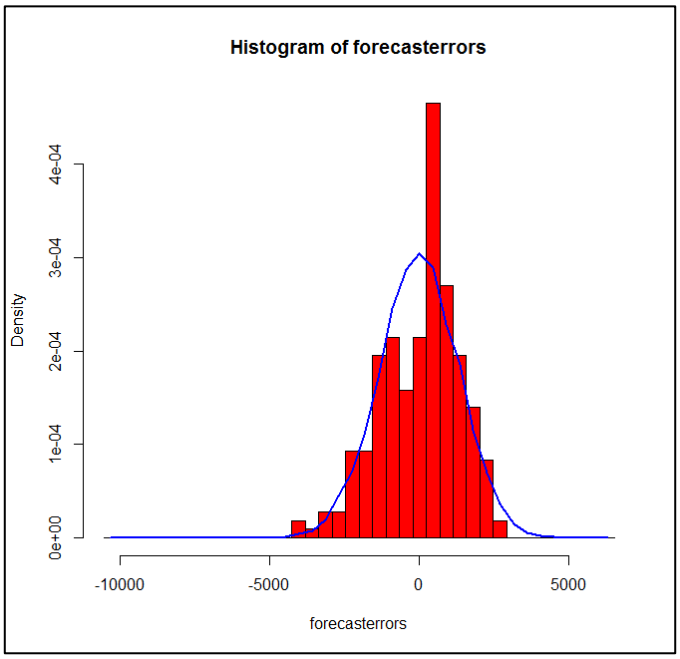

Podem observar que la distribució dels errors de pronòstic està aproximadament centrada en zero i s'assembla a una distribució normal encara que amb petites variacions.

Amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

A partir d'aquí farem l'anàlisi gràfica de la resta dels sensors i estalviarem els comentaris que seran semblants als d'aquest sensor.

- **Sensor SP-1.3** (fitxer SP13diari.dat)

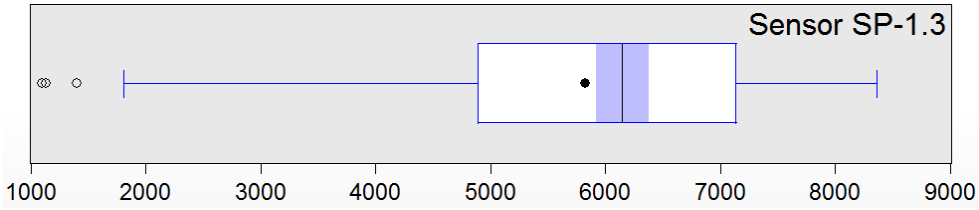

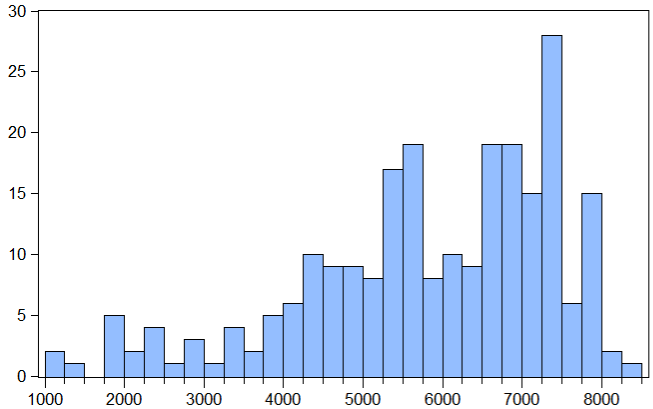

Series: SP13
Sample 11/01/2015 6/27/2016
Observations 240

Mean	5821.717
Median	6144.500
Maximum	8362.000
Minimum	1099.000
Std. Dev.	1598.245
Skewness	-0.846852
Kurtosis	3.211103
Jarque-Bera	29.13198
Probability	0.000000

```
> diari13 <- scan("SP13diari.dat")
Read 243 items
> diari13ts<-ts(diari13)
> diari13ts
Time Series:
Start = 1
End = 243
Frequency = 1
  [1] 4373 6113 6557 6532 7017 6672 6100 4616 6196 6520 6609 4925 6814 4970 4576 5649 6456 6239 6501
 [20] 6967 5456 4426 4465 4114 5544 2929 5456 5006 4452 1133 2343 1920 2152 2927 3749 3401 4785 3453
 [39] 5942 3923 3948 1953 1397 2080 2294 5396 5709 7035 6333 5200 6302 3777 6833 6138 4264 4729 4207
 [58] 5857 6031  624  183   58   61   27 2512 3476 4135 6195 6425 4710 4296 5349 5865 4748 5240 6406
 [77] 5295 4272 3968 2965 5915 5099 5078 4896 4440 5391 4876 6218 3963  917 1849 4523 4526 5076  210
 [96]  799 6618 5845 4355 5387 5363 4103   65   71   88    0  170 5857 6985 7091 7288 6253 4860 6681
[115] 6827 6933 7376 7370 5874 4698 6695 6925 6757 7246 7454 6309 4842 6598 6851 6856 7140 7305 6338
[134] 5012 6588 6867 6768 6977 7393 6232 4793 6650 6807 7067 7257 6282 6916 5677 5134 7168 7312 7716
[153] 7816 6528 5456 7199 7318 7381 7860 7954 6911 5357 7106 7417 7378 7880 7875 6828 5337 7112 7334
[172] 7465 7996 7975 7437 5392 7145 7418 7394 7934 7790 6786 6676 6574 5405 7633 4094 7865 7297 5472
[191] 1807 7443 7289 3029 7608 6948 5793 2274 7437 7027 2430 7802 6667 5274 3276 7391 7427 1809 7876
[210] 6589 4642 3609 7406 7416 1099 7960 6580 4351 4162 7707 7312  541 8022 7173 5312 7549 7721 7765
[229] 8362 8017 6615 5316 7247 7349 7300 7992 4985 6151 5552 7237 7382 5470 7996
> plot(diari13, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-1.3",cex.main=1.5, font.main=2)
> plot.ts(diari13ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-1.3",cex.main=1.5, font.main=2)
```

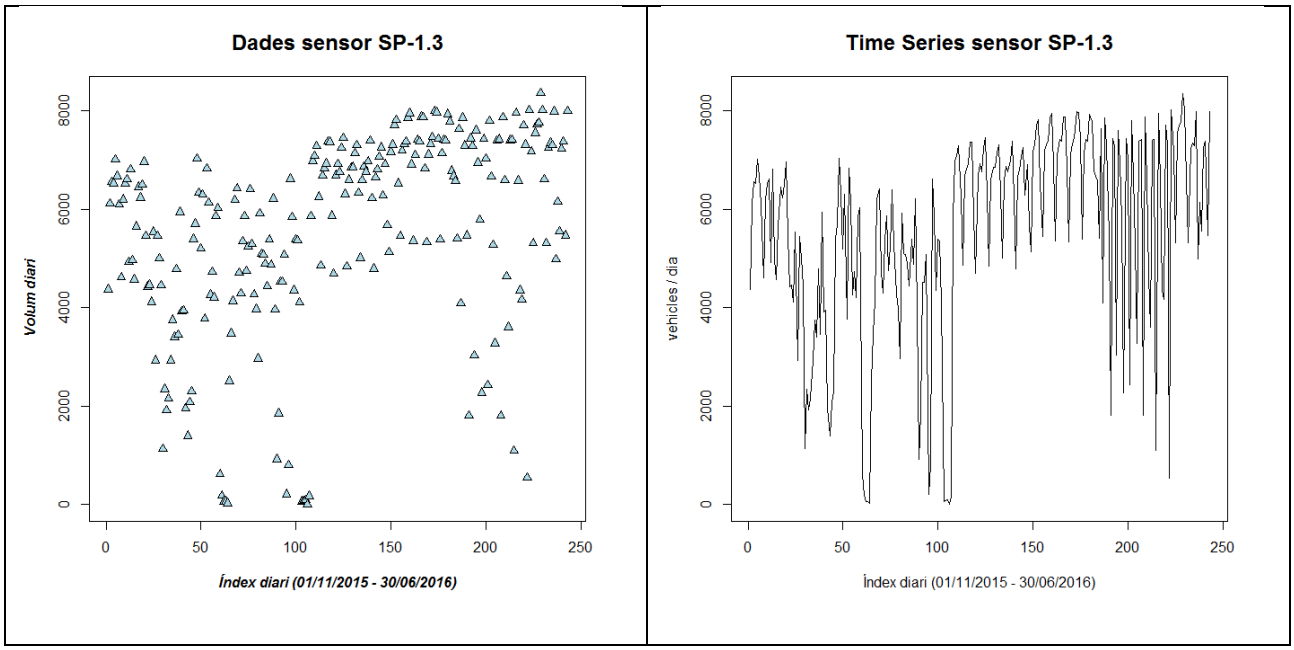


```
> diari13SMA<-SMA(diari13ts, n=10)
> plot.ts(diari13ts, xlim=c(0,250), ylim=c(0,8000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-1.3 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari13SMA, col="red", xlim=c(0,250), ylim=c(0,8000), xlab="", ylab="", lty=1, lwd=3)
```

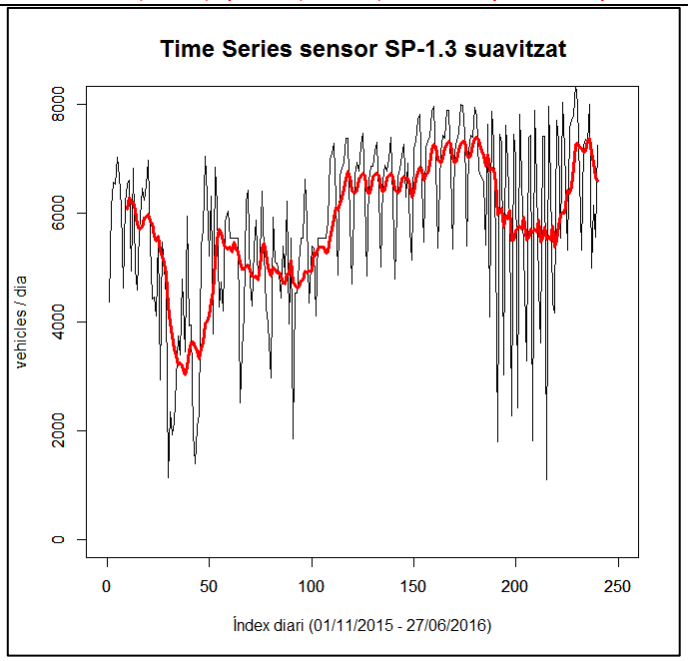


```
> diari13ts <- ts(diari13, frequency=30)
> diaricompo13<-decompose(diari13ts)
> plot(diaricompo13, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

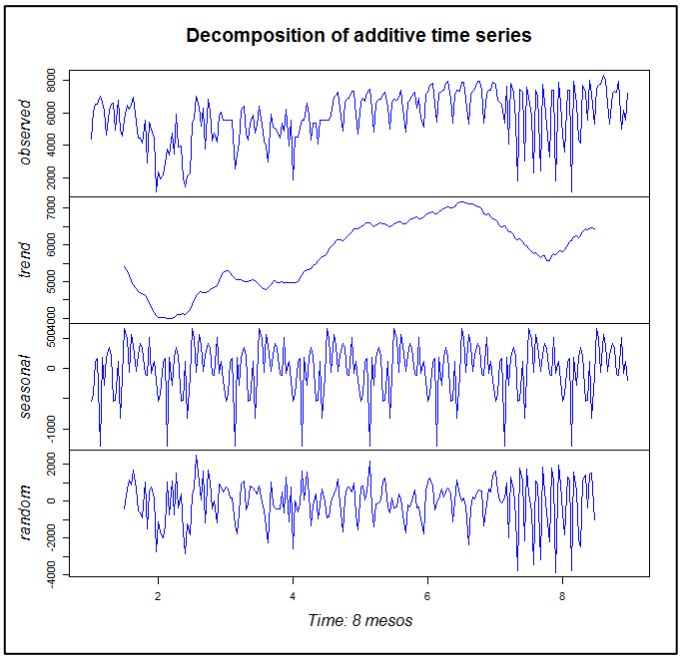


```
> diari13tsforecast<-HoltWinters(diari13ts, beta=FALSE, gamma=FALSE)
> diari13tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari13ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.1719094
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 6634.607
```

```
> diari13tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
                xhat     level
1.033333 4373.000 4373.000
1.066667 4672.122 4672.122
1.100000 4996.151 4996.151
1.133333 5260.177 5260.177
1.166667 5562.192 5562.192
1.200000 5752.978 5752.978
1.233333 5812.635 5812.635
1.266667 5606.922 5606.922
...
8.733333 6845.444 6845.444
8.766667 6914.475 6914.475
8.800000 6989.174 6989.174
8.833333 7042.608 7042.608
8.866667 7205.817 7205.817
8.900000 6824.038 6824.038
8.933333 6708.337 6708.337
8.966667 6509.551 6509.551
```

```
> plot(diari13tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-1.3)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

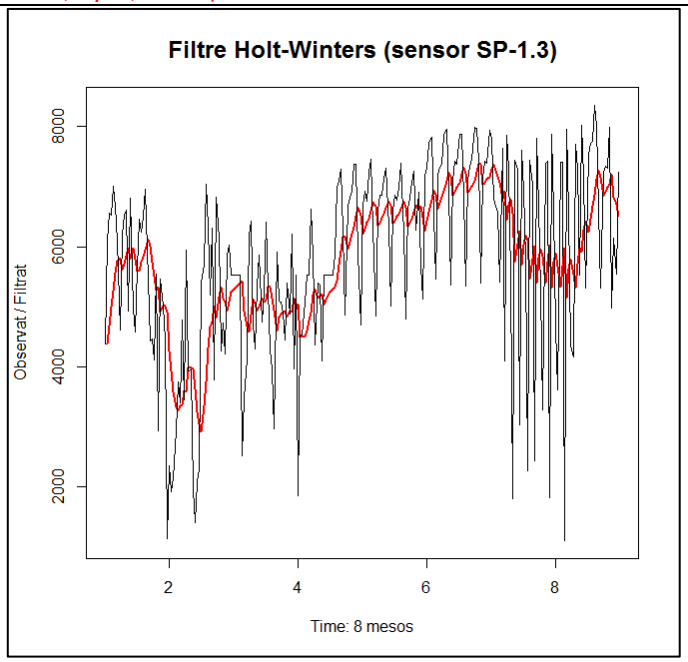


```
> diari13tsforecast2<-forecast.HoltWinters(diari13tsforecast, h=30)
> diari13tsforecast2
         Point Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000       6634.607 4872.501 8396.712 3939.699  9329.514
9.033333       6634.607 4846.653 8422.560 3900.168  9369.046
9.066667       6634.607 4821.174 8448.040 3861.200  9408.013
9.100000       6634.607 4796.047 8473.166 3822.772  9446.441
9.133333       6634.607 4771.259 8497.954 3784.863  9484.351
9.166667       6634.607 4746.797 8522.416 3747.451  9521.763
9.200000       6634.607 4722.647 8546.566 3710.517  9558.696
9.233333       6634.607 4698.799 8570.414 3674.045  9595.168
9.266667       6634.607 4675.241 8593.972 3638.016  9631.197
9.300000       6634.607 4651.963 8617.250 3602.416  9666.798
9.333333       6634.607 4628.956 8640.258 3567.228  9701.985
9.366667       6634.607 4606.209 8663.005 3532.440  9736.774
9.400000       6634.607 4583.714 8685.499 3498.037  9771.176
9.433333       6634.607 4561.464 8707.750 3464.008  9805.205
9.466667       6634.607 4539.449 8729.764 3430.340  9838.873
9.500000       6634.607 4517.664 8751.549 3397.022  9872.191
9.533333       6634.607 4496.101 8773.113 3364.044  9905.169
9.566667       6634.607 4474.752 8794.461 3331.395  9937.819
9.600000       6634.607 4453.613 8815.600 3299.065  9970.148
9.633333       6634.607 4432.677 8836.536 3267.046 10002.167
9.666667       6634.607 4411.938 8857.275 3235.328 10033.885
9.700000       6634.607 4391.391 8877.823 3203.904 10065.310
9.733333       6634.607 4371.030 8898.184 3172.765 10096.449
9.766667       6634.607 4350.850 8918.363 3141.903 10127.310
9.800000       6634.607 4330.848 8938.365 3111.312 10157.902
9.833333       6634.607 4311.018 8958.196 3080.984 10188.230
9.866667       6634.607 4291.355 8977.858 3050.912 10218.301
9.900000       6634.607 4271.856 8997.357 3021.091 10248.122
9.933333       6634.607 4252.517 9016.697 2991.514 10277.699
9.966667       6634.607 4233.333 9035.880 2962.176 10307.038
```

```
> plot.forecast(diari13tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-1.3)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

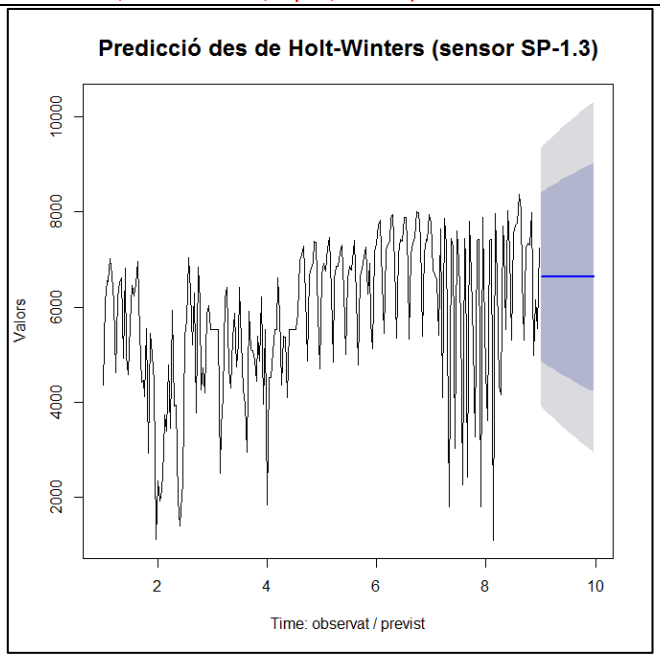


```
> acf(diari13tsforecast2$residuals, lag.max=30)
```

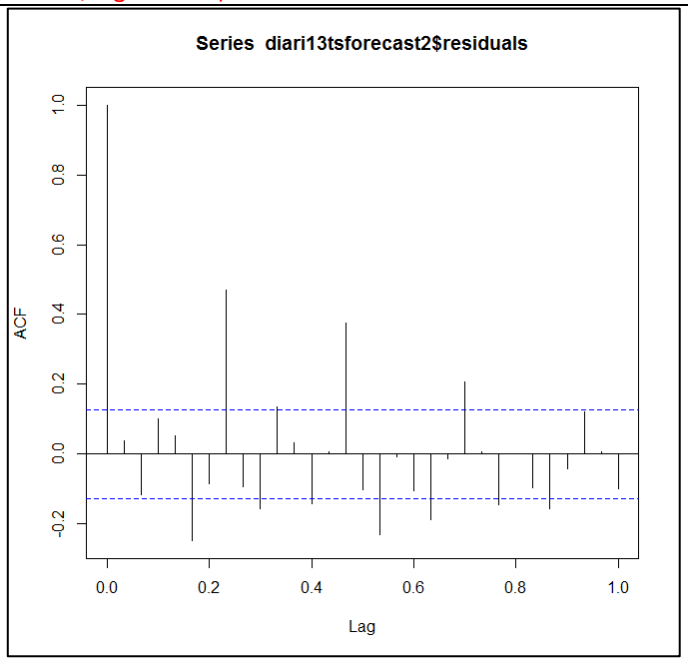


```
> Box.test(diari13tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari13tsforecast2$residuals
X-squared = 195.11, df = 30, p-value < 2.2e-16
```

```
> plot.ts(diari13tsforecast2$residuals)
```

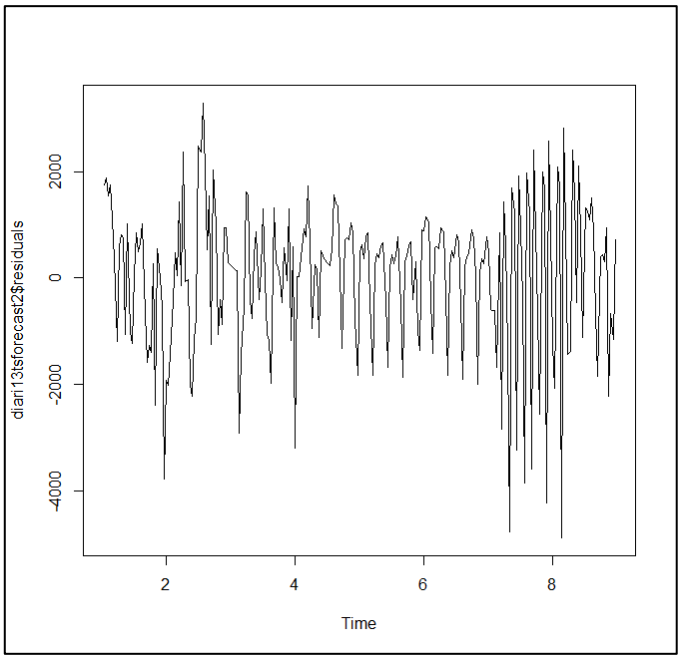


```
> plotForecastErrors(diari13tsforecast2$residuals)
```

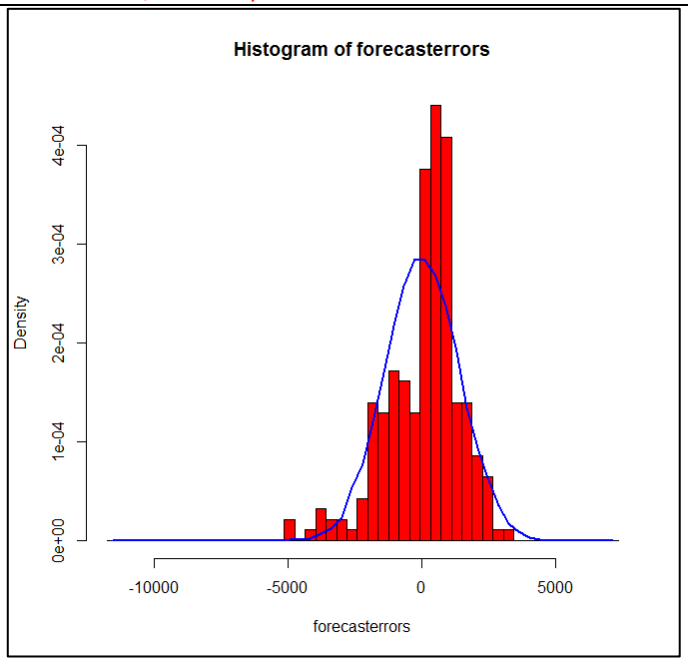

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

- **Sensor SP-1.4** (fitxer SP14diari.dat)

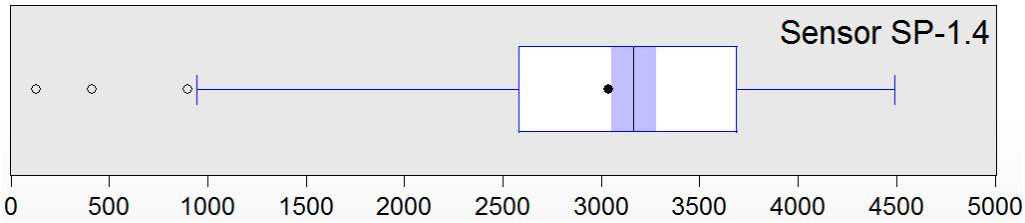

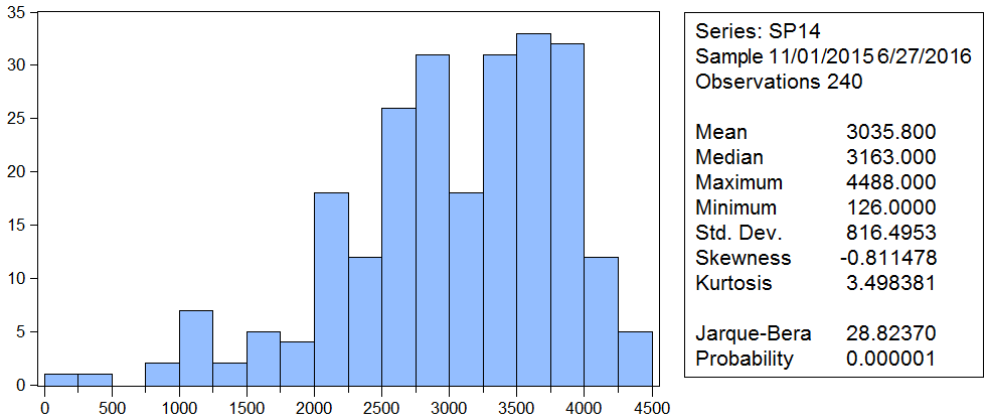


```
> diari14 <- scan("SP14diari.dat")
Read 240 items
> diari14ts<-ts(diari14)
> diari14ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 2224 3234 3606 3557 4143 3699 3447 2507 3318 3564 3845 2846 3787 2577 2401 2974 3457 3262 3746
 [20] 3705 2846 2275 2368 2180 2997 1676 2901 2597 2316 2871 1283 1007 1222 1575 1945 1819 2549 1758
 [39] 3151 2244 2114 1009 2871 1057 1234 2825 3295 3825 3359 2658 3428 2139 3800 3467 2102 2672 2284
 [58] 3195 3321 2871 2871 2871 2871 2871 1377 1785 2115 3367 3568 2612 2224 2882 3173 2595 2932 3412
 [77] 3021 2195 2036 1613 3153 2939 2676 2700 2182 2822 2505 3100 2036 2871 2871 2289 2193 2615  126
 [96]  412 3443 3089 2116 2691 2555 2052 2871 2871 2871 2871 2871 2842 3197 3393 3482 3043 2286 3059
[115] 3138 3083 3807 3696 2921 2320 3288 3546 3459 3924 3793 3288 2390 3146 3547 3468 3933 3792 3299
[134] 2503 3324 3470 3407 3853 3835 3181 2420 3285 3492 3542 3966 2804 3492 2878 2479 3667 3682 4205
[153] 4070 3326 2601 3489 3901 3666 4248 3966 3581 2646 3580 3833 3801 4244 4062 3546 2701 3690 3664
[172] 3685 4312 3976 3716 2602 3598 3800 3752 4392 3936 3572 3215 3251 2651 4058 2583 4398 3906 2891
[191]  897 3863 3684 1659 3939 3531 3095 1129 3792 3614 1247 3908 3309 2574 1617 3669 3761  943 4052
[210] 3366 2310 2009 3900 3945 2871 4241 3539 2103 2217 3999 3704 2871 4167 3681 2612 3816 4028 3937
[229] 4488 4058 3490 2670 3612 3917 3682 4300 2567 3199 2641 3648
> plot(diari14, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-1.4",cex.main=1.5, font.main=2)
> plot.ts(diari14ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-1.4",cex.main=1.5, font.main=2)
```

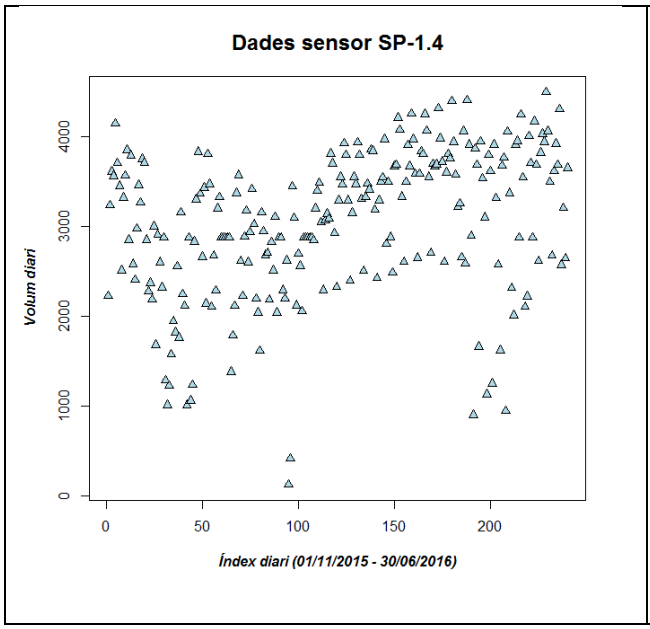

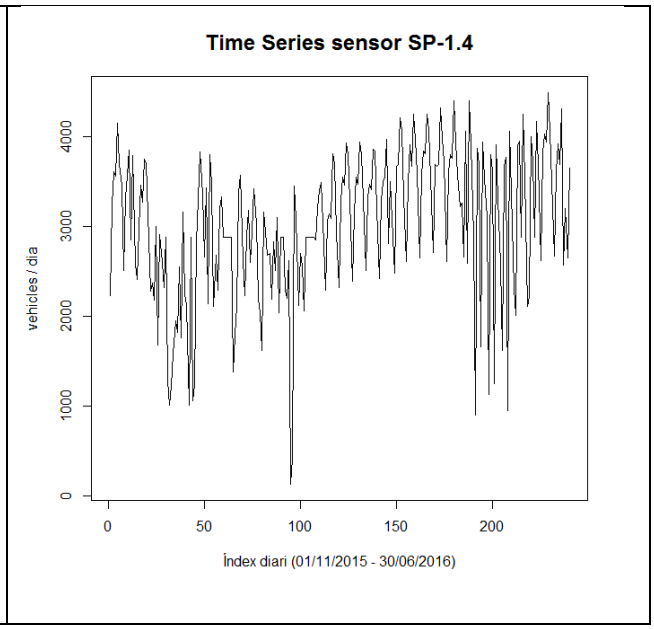


```
> diari14SMA<-SMA(diari14ts, n=10)
> plot.ts(diari14ts, xlim=c(0,250), ylim=c(0,5000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-1.4 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari14SMA, col="red", xlim=c(0,250), ylim=c(0,5000), xlab="", ylab="", lty=1, lwd=3)
```

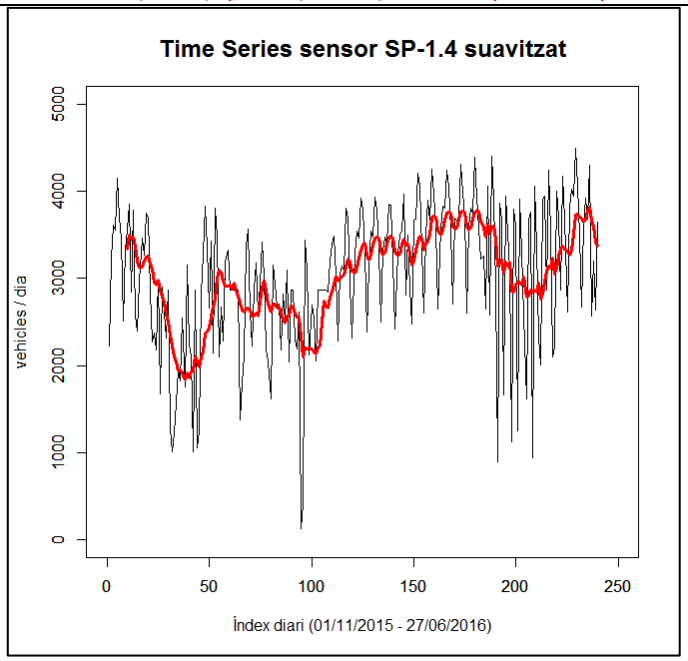


```
> diari14ts <- ts(diari14, frequency=30)
> diaricompo14<-decompose(diari14ts)
> plot(diaricompo14, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

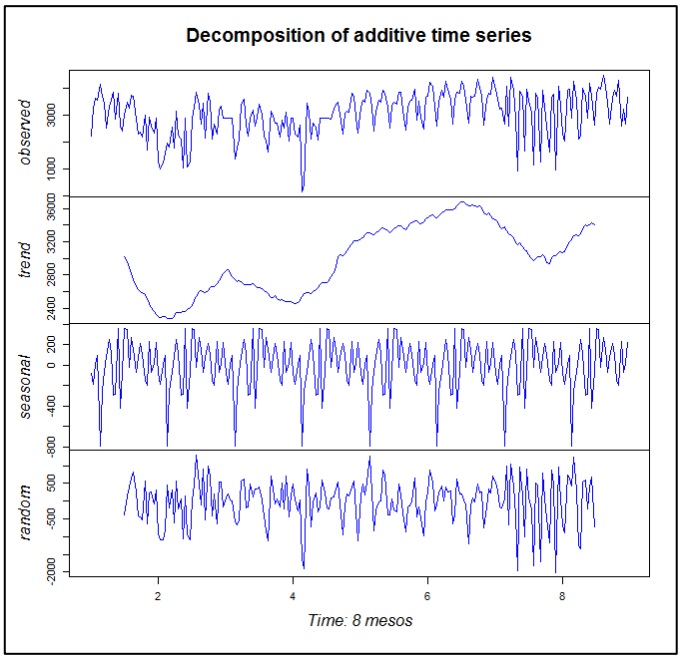


```
> diari14tsforecast<-HoltWinters(diari14ts, beta=FALSE, gamma=FALSE)
> diari14tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari14ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.1665029
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 3395.312
```

```
> diari14tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
                xhat      level
1.033333 2224.000 2224.000
1.066667 2392.168 2392.168
1.100000 2594.274 2594.274
1.133333 2754.571 2754.571
1.166667 2985.748 2985.748
1.200000 3104.507 3104.507
1.233333 3161.533 3161.533
1.266667 3052.551 3052.551
...
8.733333 3541.568 3541.568
8.766667 3553.295 3553.295
8.800000 3613.853 3613.853
8.833333 3625.200 3625.200
8.866667 3737.556 3737.556
8.900000 3542.655 3542.655
8.933333 3485.435 3485.435
8.966667 3344.835 3344.835
```

```
> plot(diari14tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-1.4)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

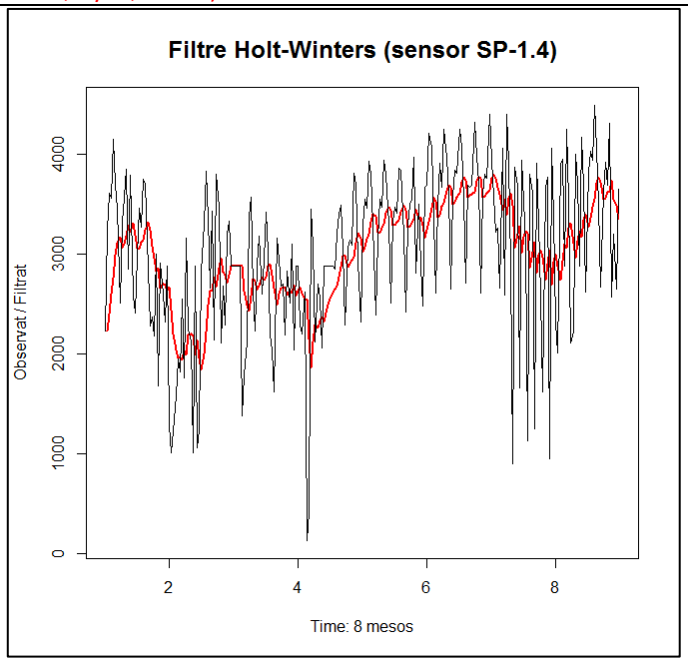


```
> diari14tsforecast2<-forecast.HoltWinters(diari14tsforecast, h=30)
> diari14tsforecast2
         Point Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000       3395.312 2446.078 4344.547 1943.584 4847.041
9.033333       3395.312 2433.010 4357.614 1923.598 4867.026
9.066667       3395.312 2420.118 4370.507 1903.881 4886.744
9.100000       3395.312 2407.393 4383.232 1884.420 4906.205
9.133333       3395.312 2394.830 4395.795 1865.207 4925.418
9.166667       3395.312 2382.423 4408.202 1846.232 4944.393
9.200000       3395.312 2370.166 4420.459 1827.487 4963.138
9.233333       3395.312 2358.054 4432.571 1808.963 4981.662
9.266667       3395.312 2346.082 4444.543 1790.653 4999.972
9.300000       3395.312 2334.245 4456.380 1772.550 5018.075
9.333333       3395.312 2322.538 4468.086 1754.646 5035.979
9.366667       3395.312 2310.958 4479.667 1736.936 5053.689
9.400000       3395.312 2299.500 4491.124 1719.413 5071.212
9.433333       3395.312 2288.161 4502.464 1702.071 5088.554
9.466667       3395.312 2276.937 4513.688 1684.905 5105.720
9.500000       3395.312 2265.824 4524.801 1667.909 5122.715
9.533333       3395.312 2254.820 4535.805 1651.080 5139.545
9.566667       3395.312 2243.921 4546.704 1634.411 5156.214
9.600000       3395.312 2233.124 4557.501 1617.898 5172.727
9.633333       3395.312 2222.426 4568.199 1601.537 5189.088
9.666667       3395.312 2211.825 4578.800 1585.324 5205.300
9.700000       3395.312 2201.318 4589.307 1569.256 5221.369
9.733333       3395.312 2190.903 4599.722 1553.327 5237.298
9.766667       3395.312 2180.577 4610.048 1537.535 5253.090
9.800000       3395.312 2170.338 4620.287 1521.876 5268.749
9.833333       3395.312 2160.184 4630.441 1506.347 5284.278
9.866667       3395.312 2150.113 4640.512 1490.944 5299.681
9.900000       3395.312 2140.122 4650.502 1475.665 5314.960
9.933333       3395.312 2130.211 4660.414 1460.507 5330.118
9.966667       3395.312 2120.377 4670.248 1445.466 5345.159
```

```
> plot.forecast(diari14tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-1.4)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

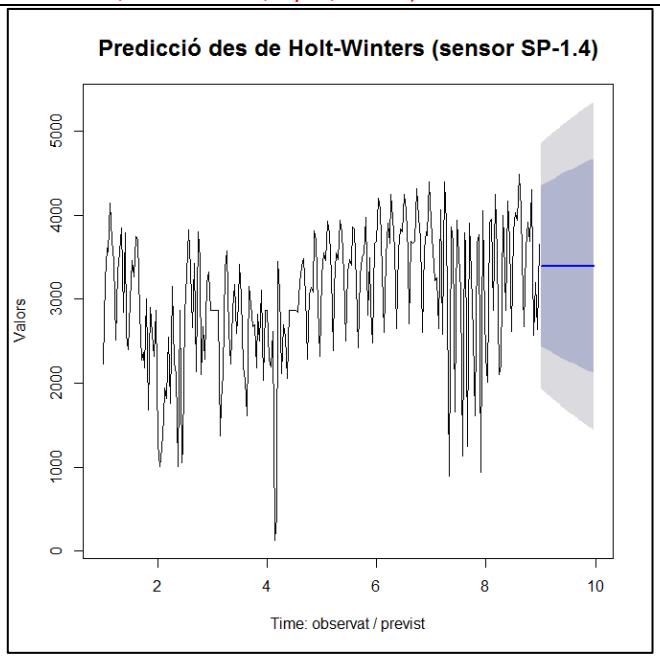


```
> acf(diari14tsforecast2$residuals, lag.max=30)
```

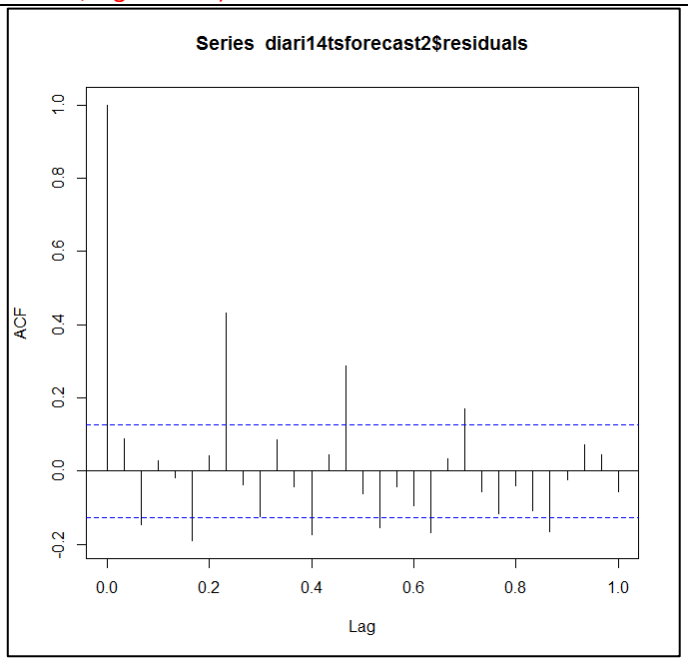


```
> Box.test(diari14tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari14tsforecast2$residuals
X-squared = 142.56, df = 30, p-value < 2.2e-16
```

```
> plot.ts(diari14tsforecast2$residuals)
```

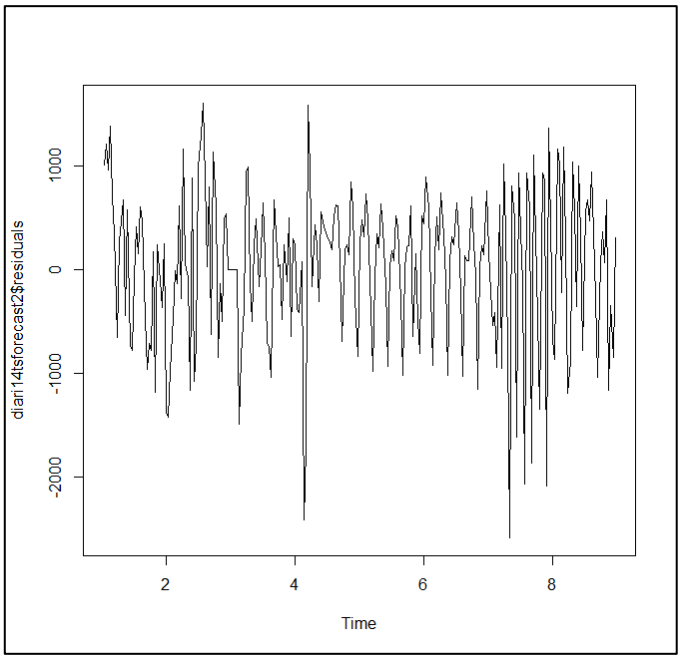


```
> plotForecastErrors(diari14tsforecast2$residuals)
```

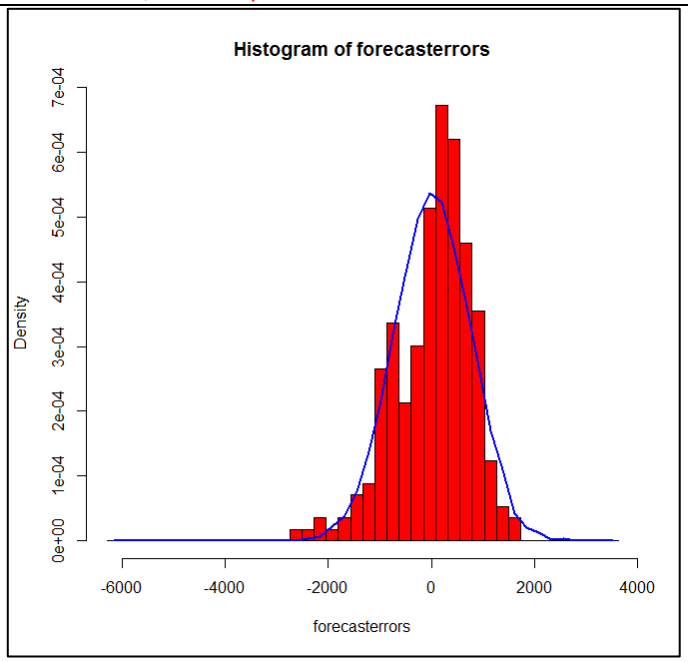

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

- **Sensor SP-1.5** (fitxer SP15diari.dat)

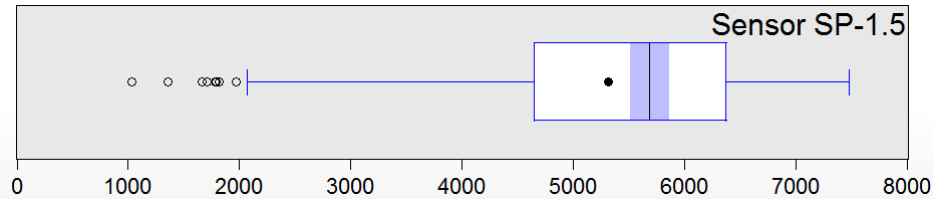

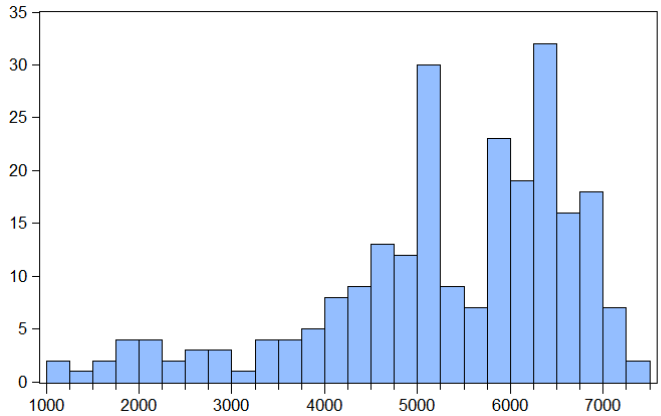

Series: SP15
Sample 11/01/2015 6/27/2016
Observations 240

Mean	5315.558
Median	5681.500
Maximum	7477.000
Minimum	1025.000
Std. Dev.	1376.645
Skewness	-1.055084
Kurtosis	3.698194
Jarque-Bera	49.40286
Probability	0.000000

```
> diari15 <- scan("SP15diari.dat")
Read 240 items
> diari15ts<-ts(diari15)
> diari15ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 4495 5769 6035 5930 6766 6338 5766 4634 5939 6123 6080 4628 6525 4609 4668 5339 6102 5960 6427
 [20] 6616 5223 4368 4177 3801 5047 2713 5066 4733 4613 1029 2146 1781 2090 2671 3458 3307 4452 3292
 [39] 5390 3971 3522 1811 1352 1966 2063 5036 5559 6575 5863 4822 5976 3407 6162 6148 4102 4187 4179
 [58] 5226 5424 5050 5050 5050 5050 5050 2371 2897 3937 5756 5920 4302 4168 5011 5462 4408 4983 6004
 [77] 4932 4199 3710 2675 5630 5130 4682 4525 4517 5035 4430 6073 3664 5050 1784 4508 4232 4676 5050
 [96] 5050 6195 5475 4059 5100 5058 3841 5050 5050 5050 5050 5050 5447 6359 6744 7075 5884 4933 6345
[115] 6440 6519 6892 6772 5568 4522 6179 6425 6287 6886 6933 5849 4873 6185 6451 6440 6737 6772 5913
[134] 4857 6123 6276 6309 6698 6879 5667 4427 5873 6101 6234 6928 4863 5784 5212 5041 6404 6482 6902
[153] 6975 5747 5312 6310 6357 6397 6873 7028 5955 4924 6380 6335 6441 7089 7038 6024 4940 6195 6284
[172] 6513 6857 6808 5341 4924 6265 6381 6431 7074 6827 5969 5108 5745 4650 6775 3794 6657 6042 5032
[191] 1662 6407 6305 2790 6620 6106 5228 2262 6422 5989 2206 6827 5922 4824 2804 6302 6465 1708 6766
[210] 5810 4337 3184 6343 6308 1025 6965 5783 4297 3637 6598 6432 5050 7160 5847 5330 6564 6689 6629
[229] 7427 7037 5696 5150 6472 6530 6501 7477 4988 5981 5968 6161
> plot(diari15, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-1.5",cex.main=1.5, font.main=2)
> plot.ts(diari15ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-1.5",cex.main=1.5, font.main=2)
```

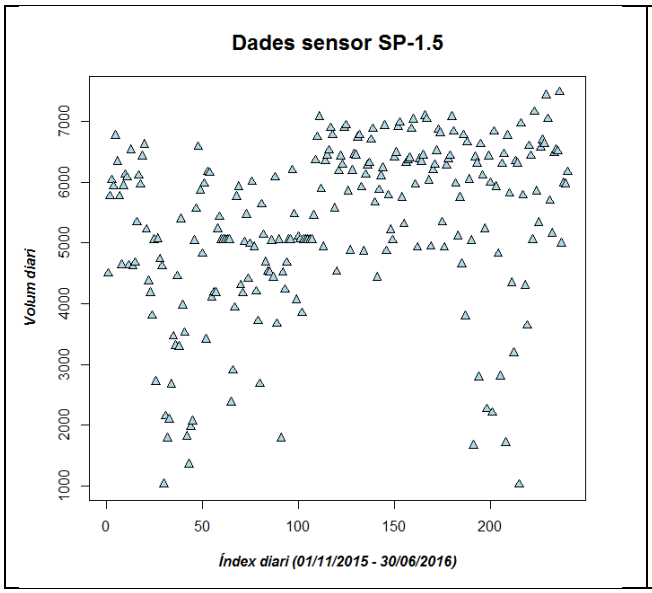

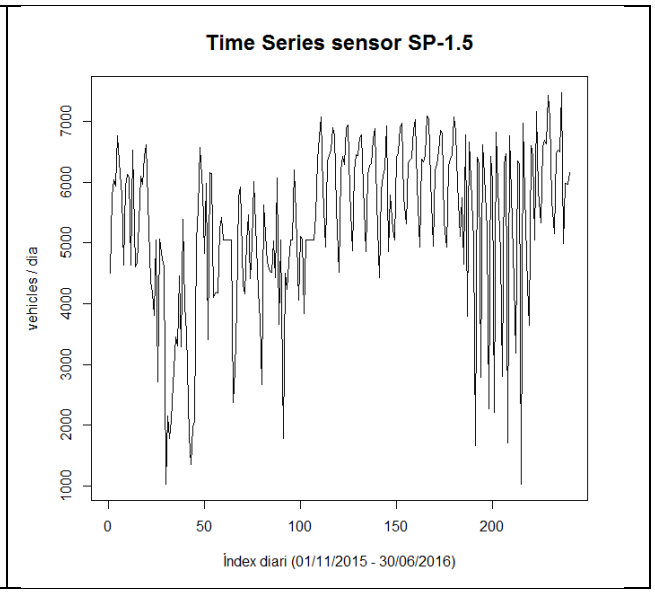


```
> diari15SMA<-SMA(diari15ts, n=10)
> plot.ts(diari15ts, xlim=c(0,250), ylim=c(0,7500), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-1.5 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari15SMA, col="red", xlim=c(0,250), ylim=c(0,7500), xlab="", ylab="", lty=1, lwd=3)
```

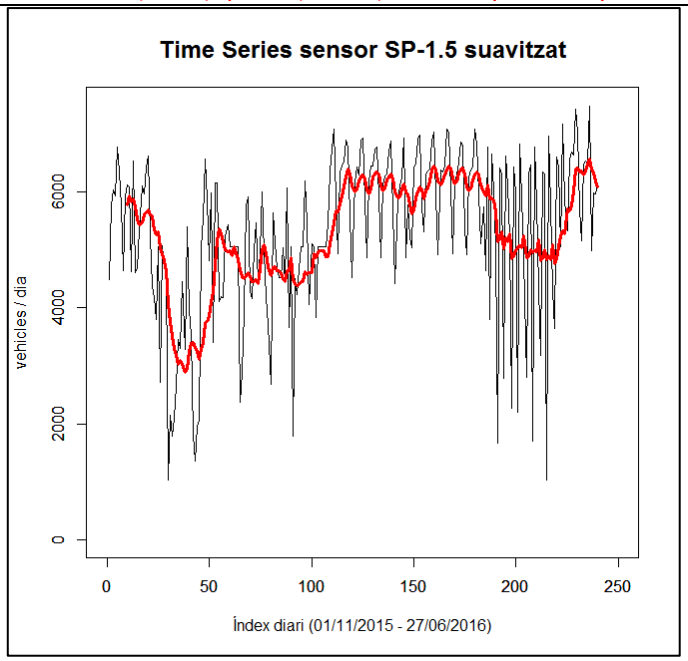


```
> diari15ts <- ts(diari15, frequency=30)
> diaricompo15<-decompose(diari15ts)
> plot(diaricompo15, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

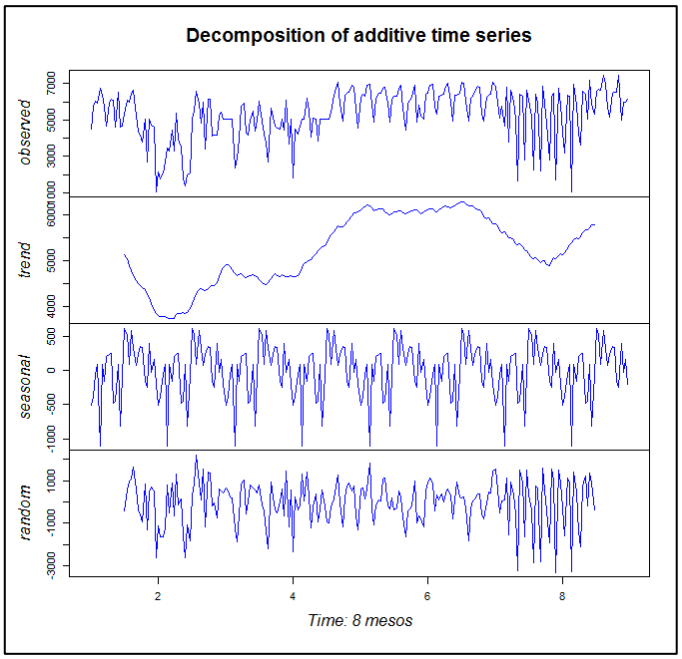


```
> diari15tsforecast<-HoltWinters(diari15ts, beta=FALSE, gamma=FALSE)
> diari15tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari15ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.1858433
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 6143.612
```

```
> diari15tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
                xhat     level
1.033333 4495.000 4495.000
1.066667 4731.764 4731.764
1.100000 4973.962 4973.962
1.133333 5151.635 5151.635
1.166667 5451.654 5451.654
1.200000 5616.376 5616.376
1.233333 5644.182 5644.182
1.266667 5456.447 5456.447
...
8.733333 6098.296 6098.296
8.766667 6167.746 6167.746
8.800000 6235.069 6235.069
8.833333 6284.490 6284.490
8.866667 6506.110 6506.110
8.900000 6223.980 6223.980
8.933333 6178.823 6178.823
8.966667 6139.643 6139.643
```

```
> plot(diari15tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-1.5)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

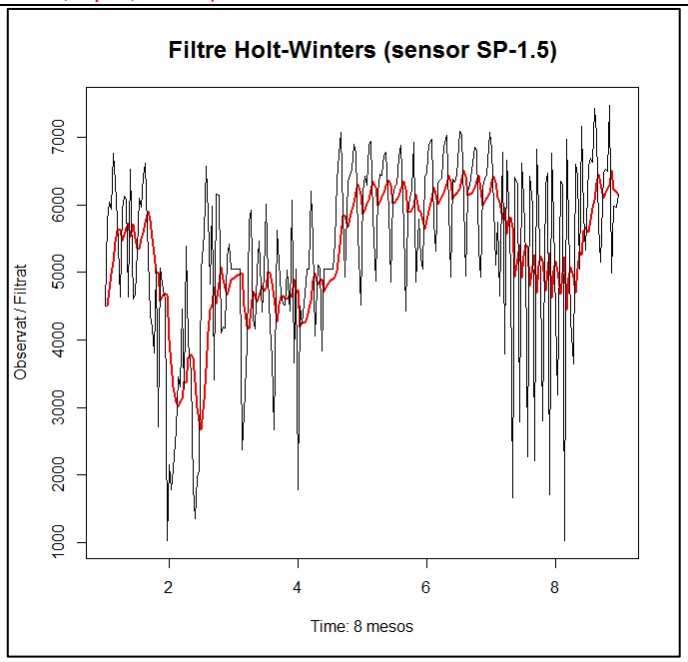


```
> diari15tsforecast2<-forecast.HoltWinters(diari15tsforecast, h=30)
> diari15tsforecast2
         Point Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000       6143.612 4607.935 7679.290 3794.996 8492.228
9.033333       6143.612 4581.641 7705.584 3754.783 8532.442
9.066667       6143.612 4555.782 7731.443 3715.235 8571.990
9.100000       6143.612 4530.337 7756.888 3676.321 8610.904
9.133333       6143.612 4505.288 7781.937 3638.011 8649.214
9.166667       6143.612 4480.616 7806.609 3600.278 8686.946
9.200000       6143.612 4456.304 7830.920 3563.097 8724.127
9.233333       6143.612 4432.338 7854.887 3526.444 8760.780
9.266667       6143.612 4408.703 7878.522 3490.298 8796.927
9.300000       6143.612 4385.386 7901.839 3454.637 8832.588
9.333333       6143.612 4362.374 7924.851 3419.443 8867.782
9.366667       6143.612 4339.655 7947.570 3384.698 8902.527
9.400000       6143.612 4317.219 7970.006 3350.385 8936.840
9.433333       6143.612 4295.055 7992.169 3316.488 8970.736
9.466667       6143.612 4273.154 8014.070 3282.994 9004.231
9.500000       6143.612 4251.507 8035.718 3249.886 9037.338
9.533333       6143.612 4230.104 8057.121 3217.154 9070.071
9.566667       6143.612 4208.938 8078.287 3184.783 9102.441
9.600000       6143.612 4188.001 8099.224 3152.763 9134.462
9.633333       6143.612 4167.286 8119.939 3121.082 9166.143
9.666667       6143.612 4146.786 8140.439 3089.730 9197.495
9.700000       6143.612 4126.494 8160.731 3058.696 9228.529
9.733333       6143.612 4106.404 8180.821 3027.971 9259.254
9.766667       6143.612 4086.510 8200.714 2997.546 9289.678
9.800000       6143.612 4066.807 8220.417 2967.413 9319.811
9.833333       6143.612 4047.289 8239.935 2937.563 9349.661
9.866667       6143.612 4027.952 8259.273 2907.989 9379.236
9.900000       6143.612 4008.789 8278.436 2878.682 9408.543
9.933333       6143.612 3989.797 8297.428 2849.636 9437.589
9.966667       6143.612 3970.971 8316.254 2820.844 9466.381
```

```
> plot.forecast(diari15tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-1.5)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

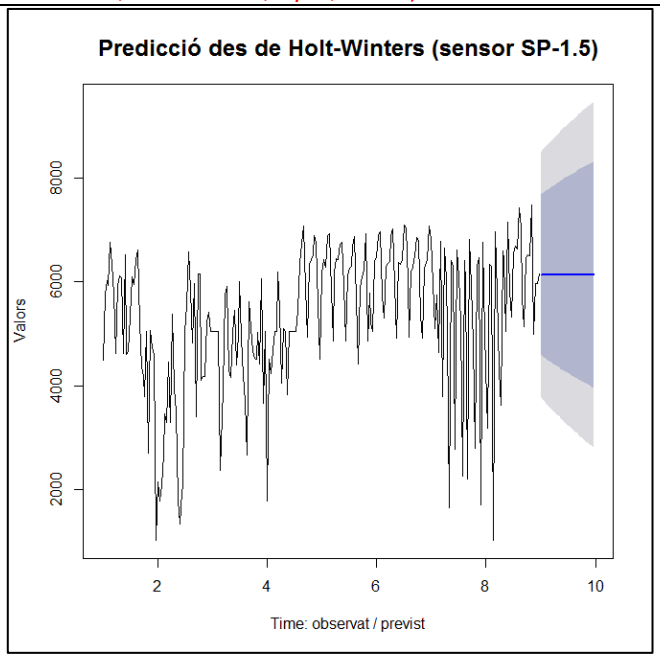


```
> acf(diari15tsforecast2$residuals, lag.max=30)
```

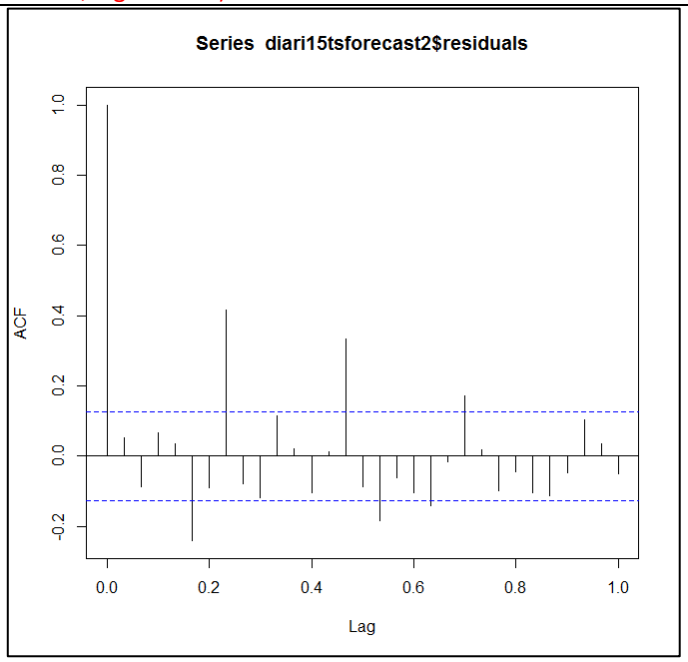


```
> Box.test(diari15tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari15tsforecast2$residuals
X-squared = 145.01, df = 30, p-value < 2.2e-16
```

```
> plot.ts(diari15tsforecast2$residuals)
```

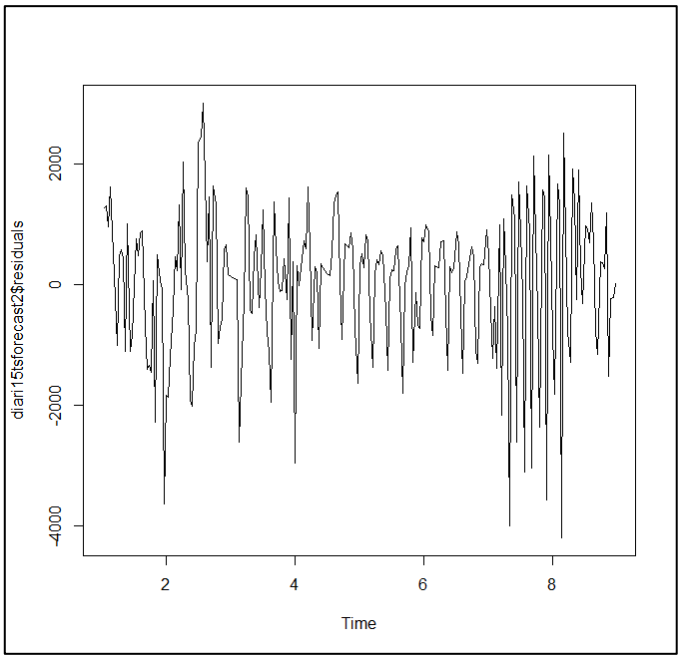


```
> plotForecastErrors(diari15tsforecast2$residuals)
```

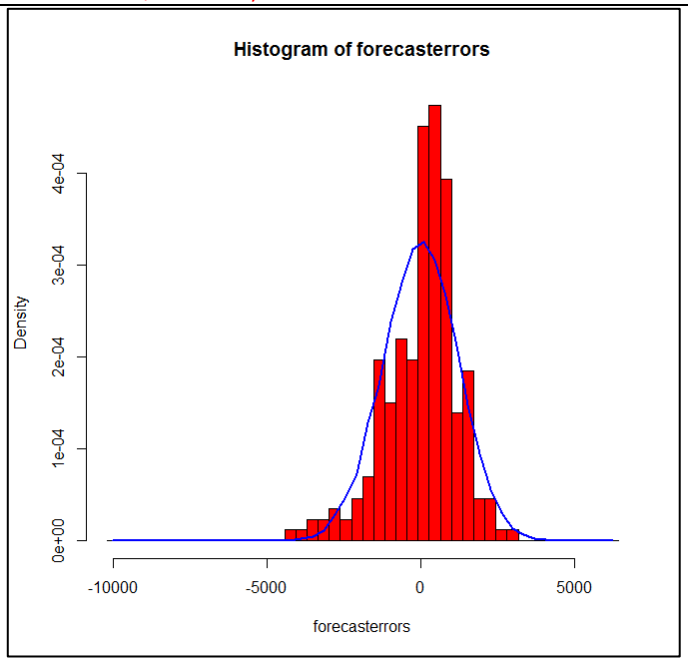

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

- **Sensor SP-2.1** (fitxer SP21diari.dat)

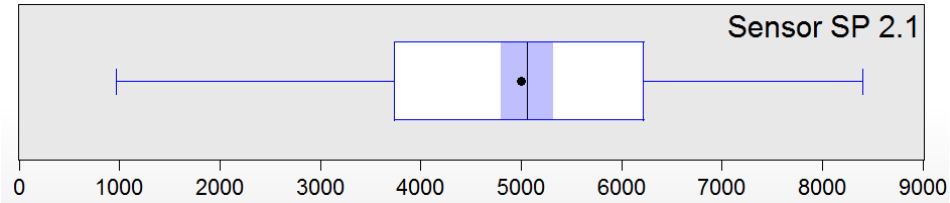

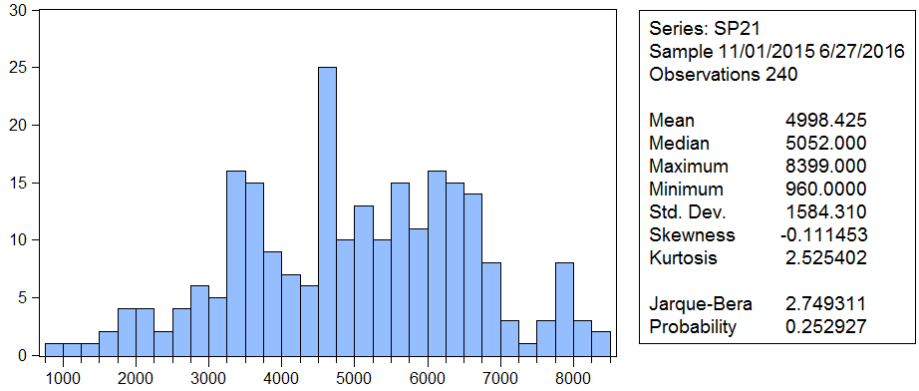


```
> diari21 <- scan("SP21diari.dat")
Read 240 items
> diari21ts<-ts(diari21)
> diari21ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 3319 5963 6337 6071 6590 6213 5152 3590 5862 6191 6034 4398 6272 4014 3519 5674 6718 6215 6611
 [20] 6852 5113 3741 4258 3787 5131 2777 4453 4013 3513  960 2213 1753 1992 2508 3015 2584 4059 2744
 [39] 5435 3491 3643 1704 1067 1979 2078 4828 5166 6343 5459 4293 5734 3405 6069 5713 3502 3724 3245
 [58] 5008 5129 4565 4565 4565 4565 4565 2239 3128 3215 5443 5792 3918 3358 5474 6322 4850 5403 6354
 [77] 5128 3469 3908 2989 5771 4803 4741 4192 3200 4962 4187 4823 2826 4565 1359 2919 3600 3850 4565
 [96] 4565 4831 3894 2494 3441 3788 2642 4565 4565 4565 4565 4565 4565 4565 4565 4565 4565 4565 4565
[115] 4565 4565 3649 5072 4418 3282 5904 6175 5401 5923 5672 4834 3478 5658 5784 5506 6025 6131 5032
[134] 3329 5537 5882 5794 6363 6225 4841 3441 5201 5545 5534 6114 3751 4951 3552 3483 6503 7060 7552
[153] 7741 5482 4054 7425 7907 7705 8086 8169 6992 5284 7862 7946 7925 8399 7984 6206 4298 6911 6837
[172] 6824 7246 6937 6216 3722 6290 6329 6251 6792 6599 5645 5194 5239 3848 6555 3440 6844 5572 4168
[191] 1935 7903 7995 3372 8327 7016 5738 2205 8198 7871 2496 6504 5635 3705 2758 6272 6281 1569 6527
[210] 5279 3461 3480 6605 6472 4565 6724 5380 2916 3427 6273 6087 4565 6690 5544 3856 6180 6419 6328
[229] 6618 6540 5242 3707 5907 6039 5984 6663 3558 4992 3681 5640
> plot(diari21, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-2.1",cex.main=1.5, font.main=2)
> plot.ts(diari21ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-2.1",cex.main=1.5, font.main=2)
```

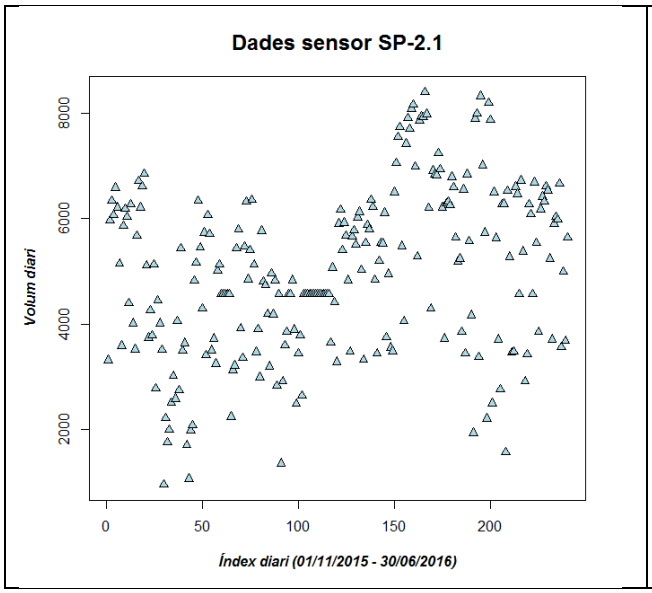

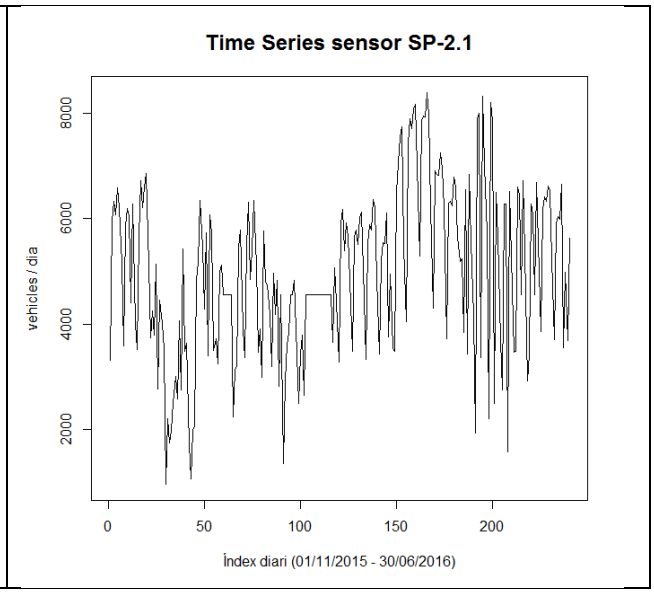


```
> diari21SMA<-SMA(diari21ts, n=10)
> plot.ts(diari21ts, xlim=c(0,250), ylim=c(0,8000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-2.1 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari21SMA, col="red", xlim=c(0,250), ylim=c(0,8000), xlab="", ylab="", lty=1, lwd=3)
```

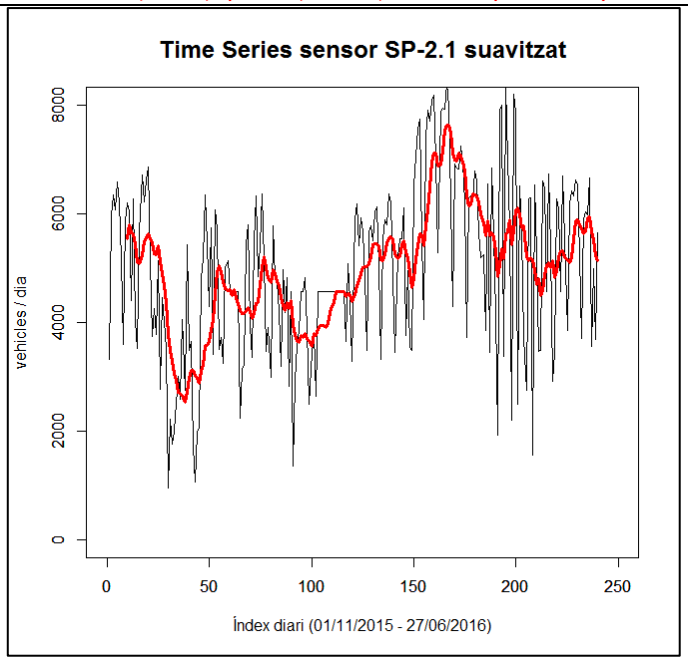


```
> diari21ts <- ts(diari21, frequency=30)
> diaricompo21<-decompose(diari21ts)
> plot(diaricompo21, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

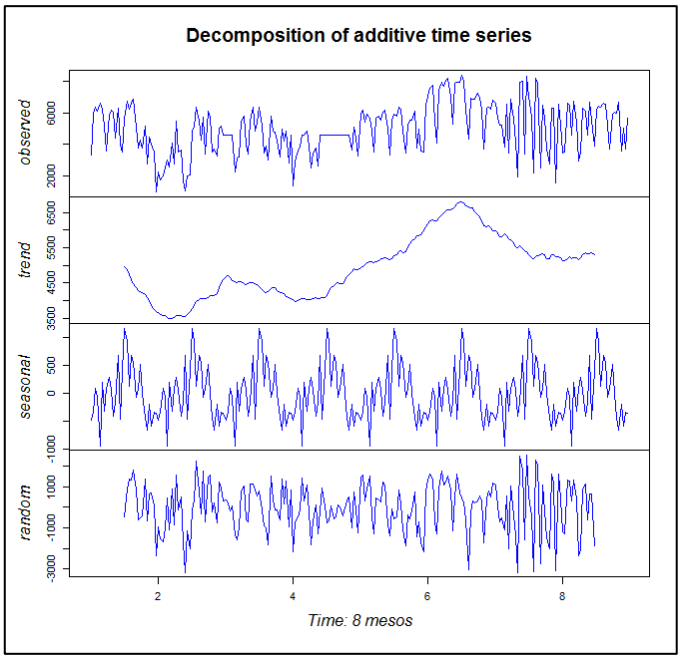


```
> diari21tsforecast<-HoltWinters(diari21ts, beta=FALSE, gamma=FALSE)
> diari21tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari21ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.215665
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 5109.207
```

```
> diari21tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
                xhat     level
1.033333 3319.000 3319.000
1.066667 3889.218 3889.218
1.100000 4417.119 4417.119
1.133333 4773.803 4773.803
1.166667 5165.494 5165.494
1.200000 5391.404 5391.404
1.233333 5339.773 5339.773
1.266667 4962.408 4962.408
...
8.733333 5410.558 5410.558
8.766667 5517.623 5517.623
8.800000 5630.066 5630.066
8.833333 5706.397 5706.397
8.866667 5912.703 5912.703
8.900000 5404.876 5404.876
8.933333 5315.833 5315.833
8.966667 4963.257 4963.257
```

```
> plot(diari21tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-2.1)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

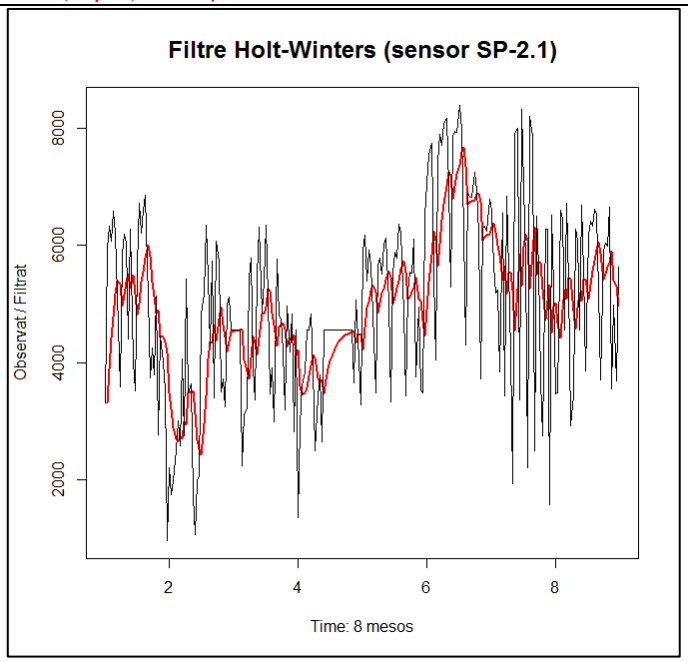


```
> diari21tsforecast2<-forecast.HoltWinters(diari21tsforecast, h=30)
> diari21tsforecast2
         Point Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000       5109.207 3323.427 6894.987 2378.0918 7840.321
9.033333       5109.207 3282.369 6936.044 2315.2997 7903.114
9.066667       5109.207 3242.214 6976.199 2253.8881 7964.525
9.100000       5109.207 3202.905 7015.508 2193.7698 8024.643
9.133333       5109.207 3164.390 7054.023 2134.8663 8083.547
9.166667       5109.207 3126.623 7091.790 2077.1070 8141.306
9.200000       5109.207 3089.563 7128.851 2020.4276 8197.986
9.233333       5109.207 3053.170 7165.243 1964.7696 8253.644
9.266667       5109.207 3017.410 7201.003 1910.0799 8308.333
9.300000       5109.207 2982.251 7236.162 1856.3095 8362.104
9.333333       5109.207 2947.665 7270.748 1803.4135 8415.000
9.366667       5109.207 2913.623 7304.790 1751.3508 8467.062
9.400000       5109.207 2880.100 7338.313 1700.0830 8518.330
9.433333       5109.207 2847.075 7371.338 1649.5749 8568.838
9.466667       5109.207 2814.525 7403.888 1599.7936 8618.620
9.500000       5109.207 2782.430 7435.983 1550.7086 8667.705
9.533333       5109.207 2750.772 7467.642 1502.2916 8716.122
9.566667       5109.207 2719.533 7498.880 1454.5160 8763.897
9.600000       5109.207 2688.697 7529.716 1407.3568 8811.056
9.633333       5109.207 2658.249 7560.164 1360.7910 8857.622
9.666667       5109.207 2628.175 7590.238 1314.7966 8903.617
9.700000       5109.207 2598.461 7619.952 1269.3530 8949.060
9.733333       5109.207 2569.095 7649.318 1224.4410 8993.972
9.766667       5109.207 2540.064 7678.349 1180.0424 9038.371
9.800000       5109.207 2511.358 7707.055 1136.1398 9082.273
9.833333       5109.207 2482.965 7735.448 1092.7172 9125.696
9.866667       5109.207 2454.876 7763.537 1049.7589 9168.654
9.900000       5109.207 2427.082 7791.331 1007.2505 9211.163
9.933333       5109.207 2399.572 7818.841  965.1782 9253.235
9.966667       5109.207 2372.339 7846.074  923.5287 9294.884
```

```
> plot.forecast(diari21tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-2.1)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

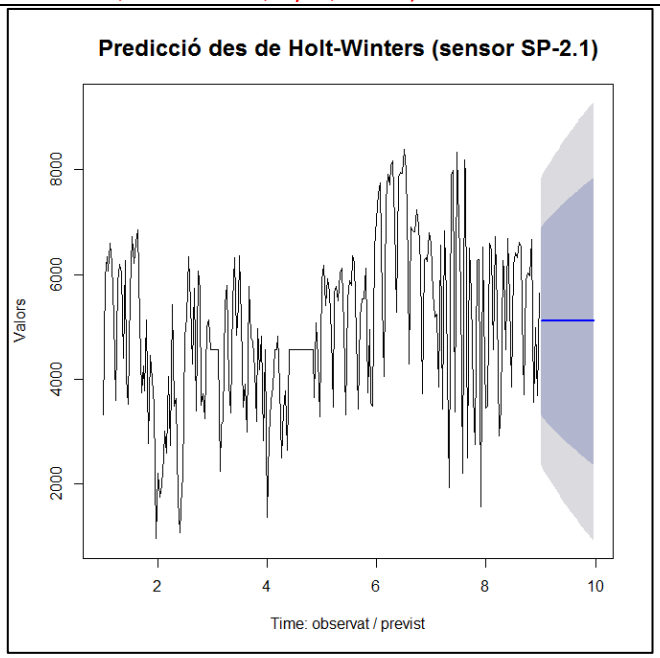


```
> acf(diari21tsforecast2$residuals, lag.max=30)
```

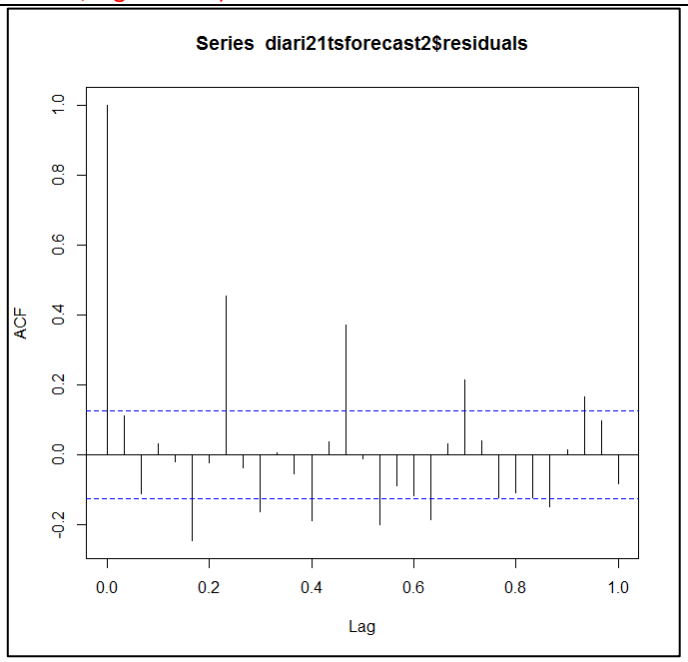


```
> Box.test(diari21tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari21tsforecast2$residuals
X-squared = 191.9, df = 30, p-value < 2.2e-16
```

```
> plot.ts(diari21tsforecast2$residuals)
```

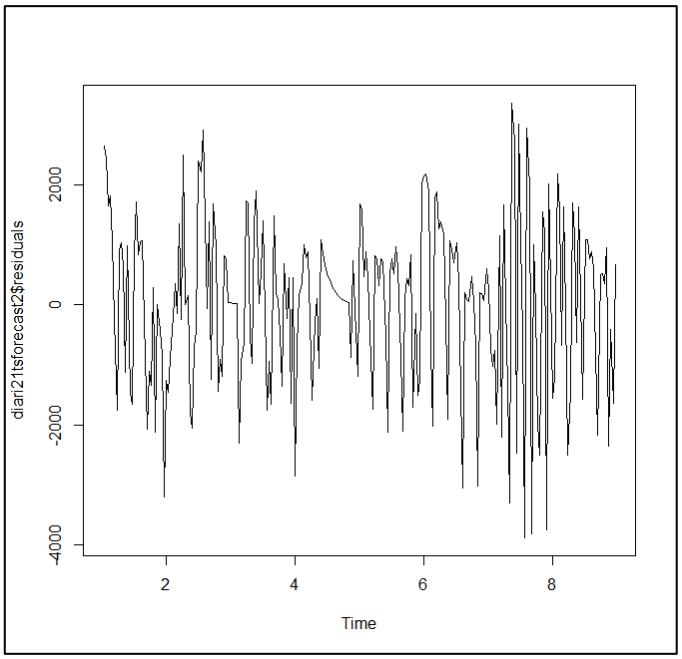


```
> plotForecastErrors(diari21tsforecast2$residuals)
```

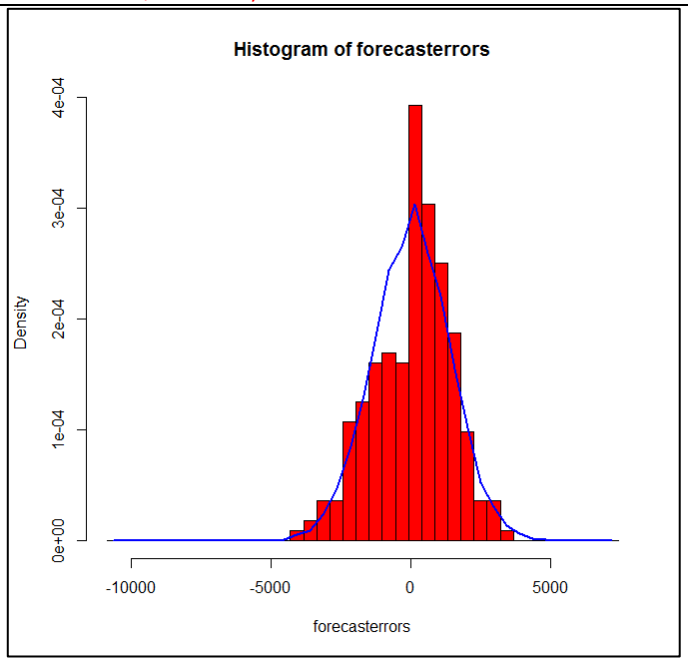

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

- **Sensor SP-5.5** (fitxer SP55diari.dat)

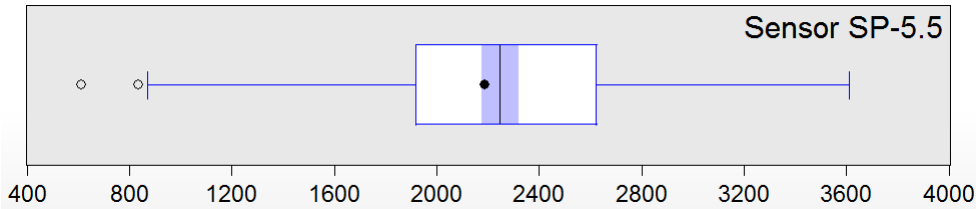

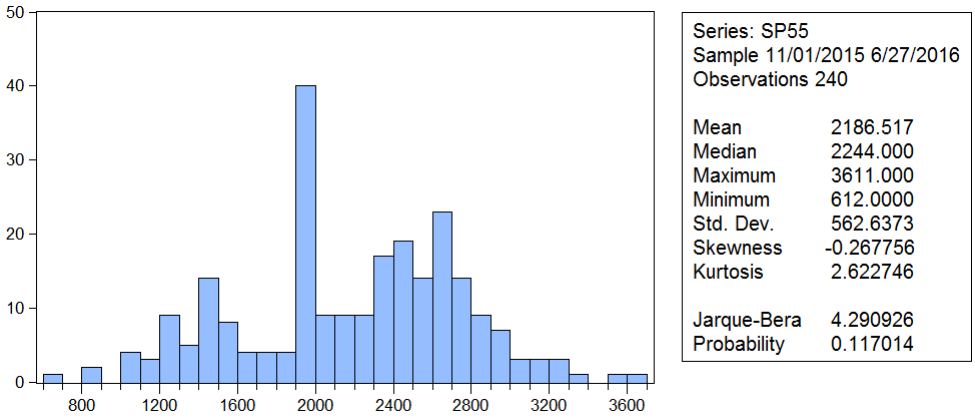


```
> diari55 <- scan("SP55diari.dat")
Read 240 items
> diari55ts<-ts(diari55)
> diari55ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 1433 2410 2643 2434 2816 2416 2652 1325 2381 2665 2733 1888 2755 2193 1400 2062 2608 2319 2539
 [20] 2665 2420 1266 1787 1588 2049 1202 2243 2375 1425 1962 1169 1962 1962 1962 1525 1287 2183 1392
 [39] 2204 1352 1022 1962 1962 1962 1962 2020 2320 2677 2787 1797 2743 1521 2904 2451 1407 1698 1414
 [58] 2661 2836 1962 1962 1962 1962 1962 1297 1259 1270 2671 2480 2059 1424 1999 2389 1891 1988 2345
 [77] 2385 1274 2069 1726 3304 2711 2544 3233 2187 3010 2578 3241 1824 1962 1057 2247 1906 2165 1962
 [96] 1962 2485 2547 1370 2092 2195 1603 1962 1962 1962 1962 1962 2088 2647 2620 2643 2602 1619 2365
[115] 2430 2221 2922 3094 2623 1482 2379 2294 2450 2943 3270 2224 1553 2980 2491 2676 2701 2416 2567
[134] 1438 2189 2536 2321 2606 2556 2834 1499 2391 2582 2489 3063 1962 1962 1962 1962 1962 1962 1962
[153] 1156 2651 1546 2476 2435 2387 2613 2411 2667 1456 2466 2631 2384 2689 2430 2731 1454 2552 2659
[172] 1949 2527 2287 2717 1441 2142 2529 2360 2666 3172 3569 1673 2551 2089 2717 1002 2897 3611 2245
[191] 1962 2116 2358 1034 2077 2387 1807 1962 2117 1955  833 1986 1921 1313  870 1916 1762  612 2416
[210] 2519 1404 1130 2319 2277 1962 2720 2818 1275 1282 2418 2725 1962 2812 2799 1539 2776 2905 2667
[229] 3135 2826 2846 1516 2553 2934 2719 3147 1583 2963 1430 2834
> plot(diari55, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-5.5",cex.main=1.5, font.main=2)
> plot.ts(diari55ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-5.5",cex.main=1.5, font.main=2)
```

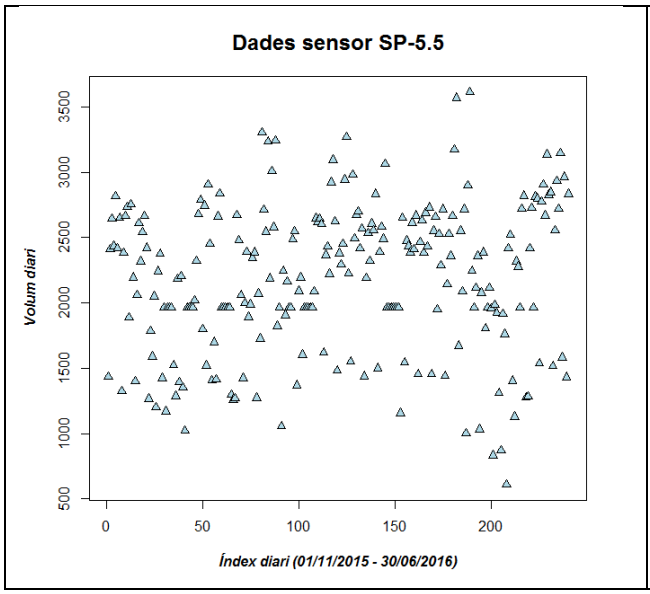

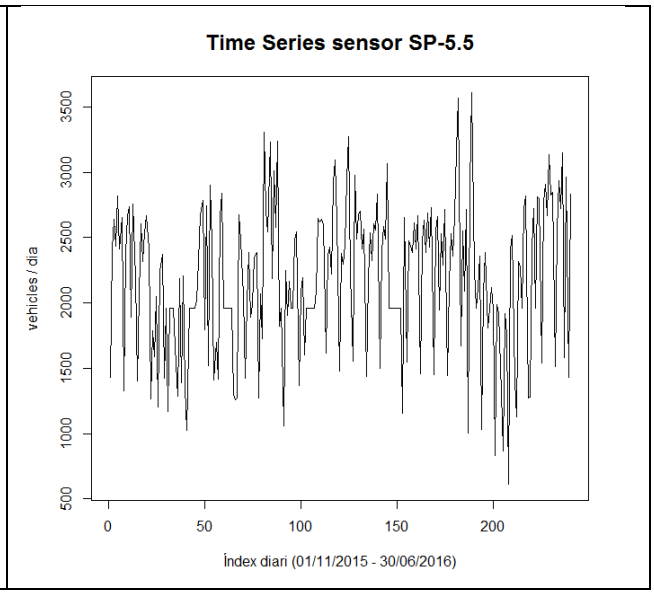


```
> diari55SMA<-SMA(diari55ts, n=10)
> plot.ts(diari55ts, xlim=c(0,250), ylim=c(0,4000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-5.5 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari55SMA, col="red", xlim=c(0,250), ylim=c(0,4000), xlab="", ylab="", lty=1, lwd=3)
```

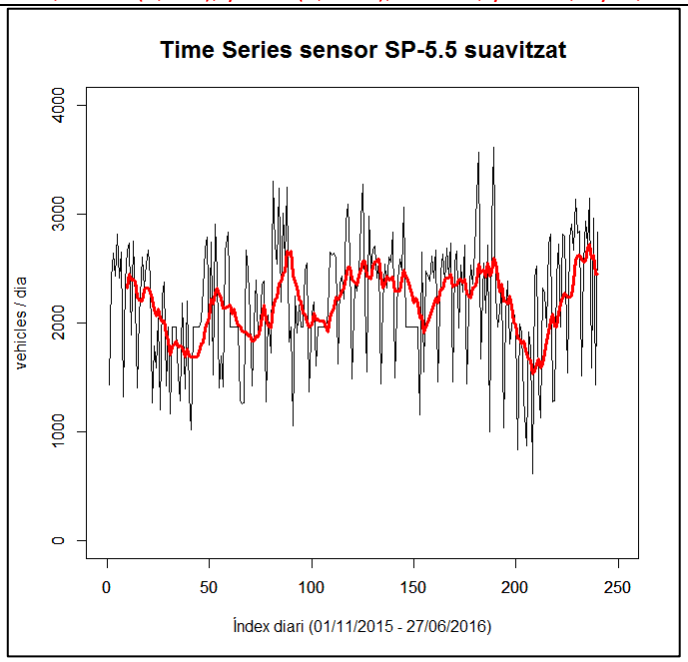


```
> diari55ts <- ts(diari55, frequency=30)
> diaricompo55<-decompose(diari55ts)
> plot(diaricompo55, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

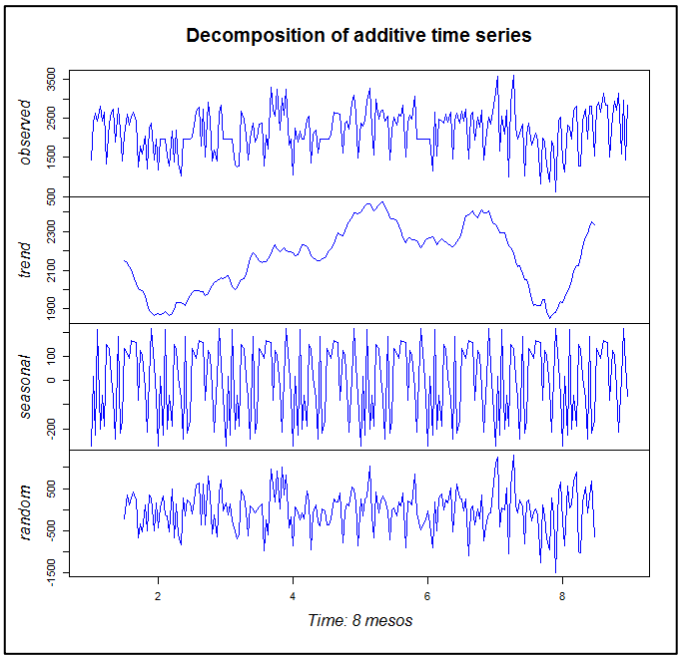


```
> diari55tsforecast<-HoltWinters(diari55ts, beta=FALSE, gamma=FALSE)
> diari55tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari55ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.1662724
 beta : FALSE
 gamma: FALSE
Coefficients:
    [,1]
a 2453.22
```

```
> diari55tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
          xhat    level
1.033333 1433.000 1433.000
1.066667 1595.448 1595.448
1.100000 1769.627 1769.627
1.133333 1880.094 1880.094
1.166667 2035.709 2035.709
1.200000 2098.941 2098.941
1.233333 2190.899 2190.899
1.266667 2046.924 2046.924
...
8.733333 2446.516 2446.516
8.766667 2464.221 2464.221
8.800000 2542.332 2542.332
8.833333 2571.707 2571.707
8.866667 2667.362 2667.362
8.900000 2487.063 2487.063
8.933333 2566.198 2566.198
8.966667 2377.280 2377.280
```

```
> plot(diari55tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-5.5)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

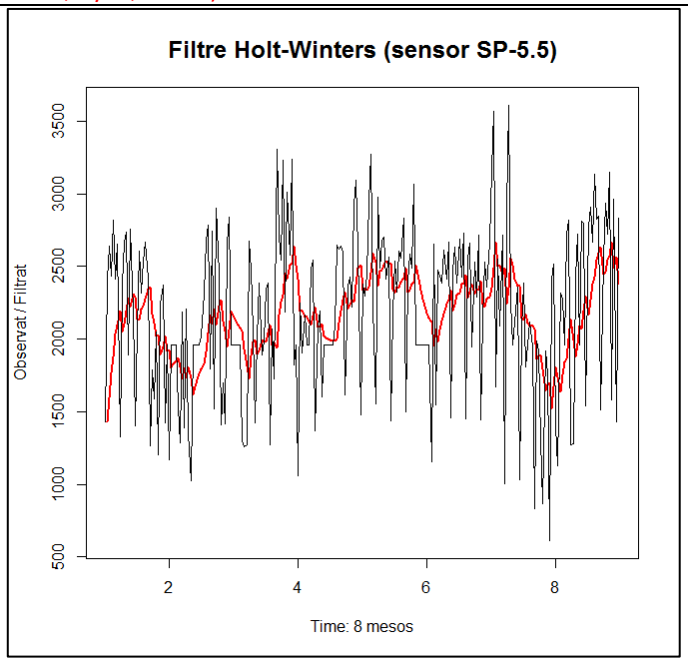


```
> diari55tsforecast2<-forecast.HoltWinters(diari55tsforecast, h=30)
> diari55tsforecast2
         Point Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000       2453.22 1732.743 3173.697 1351.3456 3555.094
9.033333       2453.22 1722.852 3183.588 1336.2179 3570.222
9.066667       2453.22 1713.092 3193.347 1321.2925 3585.147
9.100000       2453.22 1703.460 3202.979 1306.5612 3599.878
9.133333       2453.22 1693.950 3212.489 1292.0169 3614.423
9.166667       2453.22 1684.558 3221.882 1277.6525 3628.787
9.200000       2453.22 1675.279 3231.161 1263.4615 3642.978
9.233333       2453.22 1666.109 3240.330 1249.4377 3657.002
9.266667       2453.22 1657.045 3249.395 1235.5755 3670.864
9.300000       2453.22 1648.083 3258.357 1221.8693 3684.570
9.333333       2453.22 1639.220 3267.220 1208.3140 3698.125
9.366667       2453.22 1630.452 3275.988 1194.9048 3711.535
9.400000       2453.22 1621.776 3284.663 1181.6369 3724.803
9.433333       2453.22 1613.191 3293.249 1168.5061 3737.933
9.466667       2453.22 1604.692 3301.748 1155.5081 3750.931
9.500000       2453.22 1596.277 3310.162 1142.6390 3763.801
9.533333       2453.22 1587.944 3318.495 1129.8950 3776.544
9.566667       2453.22 1579.691 3326.749 1117.2726 3789.167
9.600000       2453.22 1571.515 3334.925 1104.7684 3801.671
9.633333       2453.22 1563.414 3343.026 1092.3791 3814.060
9.666667       2453.22 1555.386 3351.054 1080.1015 3826.338
9.700000       2453.22 1547.429 3359.010 1067.9327 3838.507
9.733333       2453.22 1539.542 3366.898 1055.8700 3850.570
9.766667       2453.22 1531.722 3374.718 1043.9104 3862.529
9.800000       2453.22 1523.968 3382.472 1032.0515 3874.388
9.833333       2453.22 1516.278 3390.162 1020.2907 3886.149
9.866667       2453.22 1508.650 3397.789 1008.6257 3897.814
9.900000       2453.22 1501.084 3405.355  997.0542 3909.385
9.933333       2453.22 1493.578 3412.862  985.5738 3920.866
9.966667       2453.22 1486.129 3420.310  974.1826 3932.257
```

```
> plot.forecast(diari55tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-5.5)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

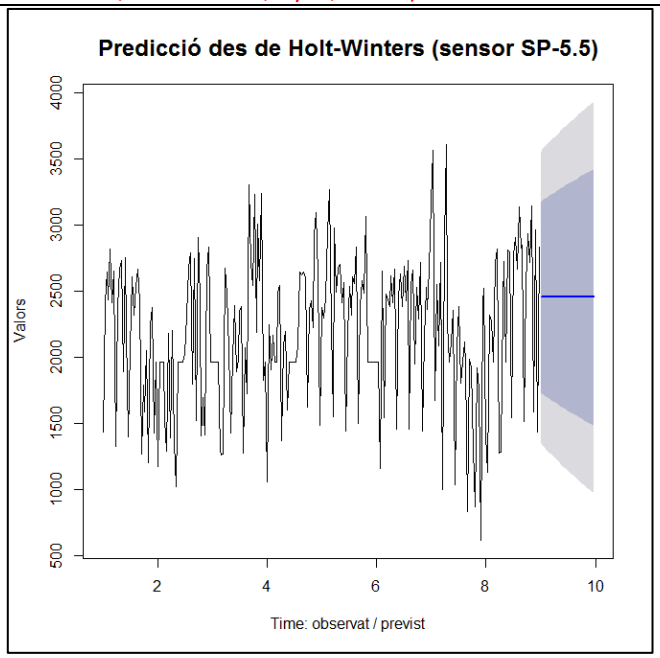


```
> acf(diari55tsforecast2$residuals, lag.max=30)
```

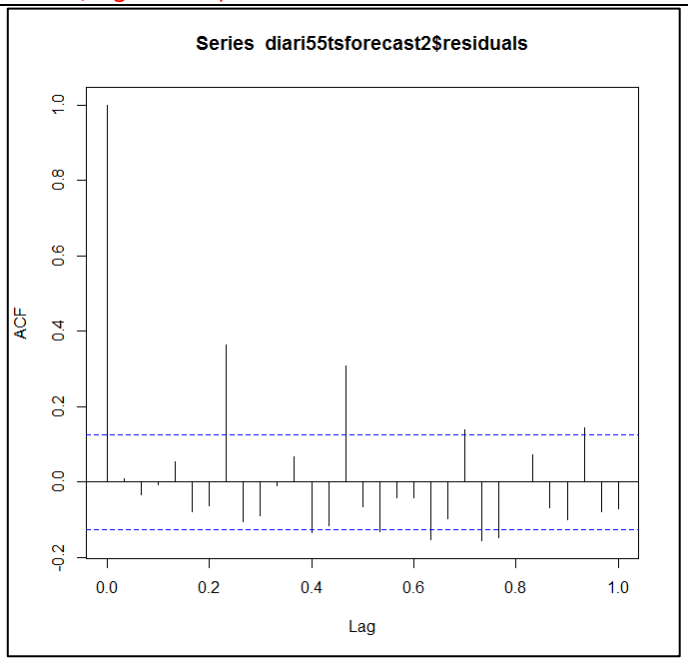


```
> Box.test(diari55tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari55tsforecast2$residuals
X-squared = 120.92, df = 30, p-value = 7.139e-13
```

```
> plot.ts(diari55tsforecast2$residuals)
```

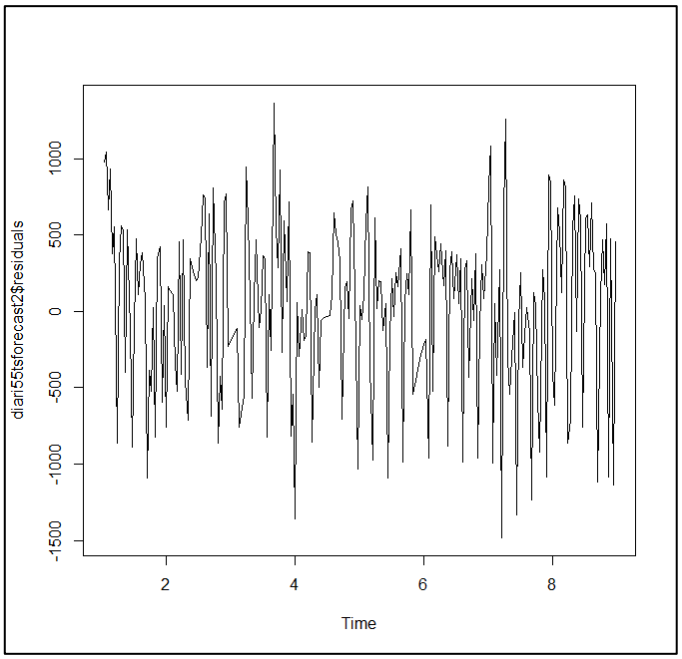


```
> plotForecastErrors(diari55tsforecast2$residuals)
```

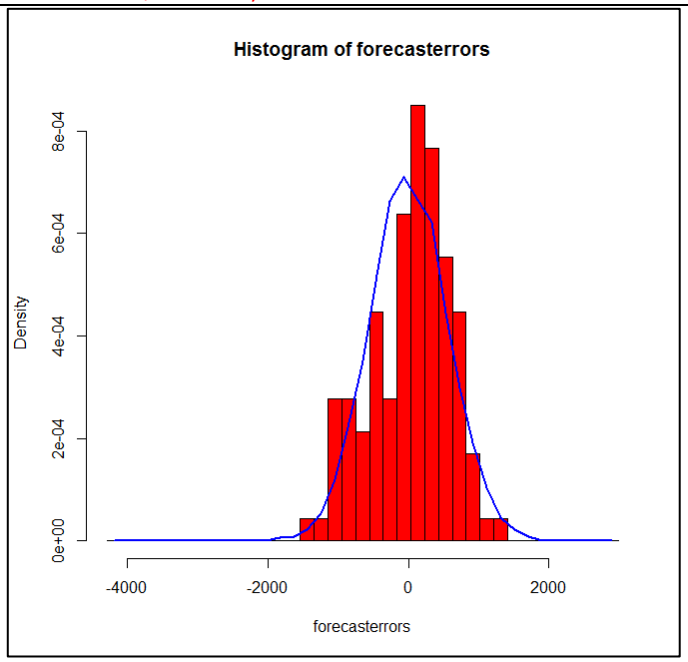

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

- **Sensor SP-7.3** (fitxer SP73diari.dat)

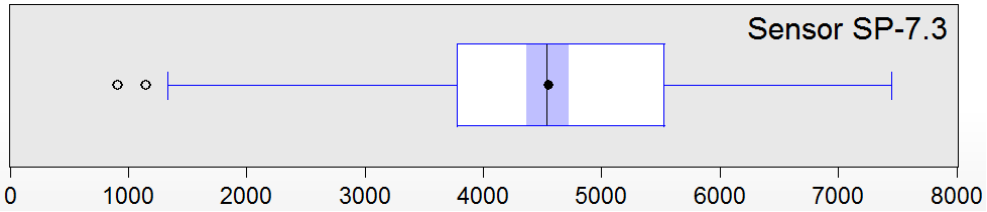

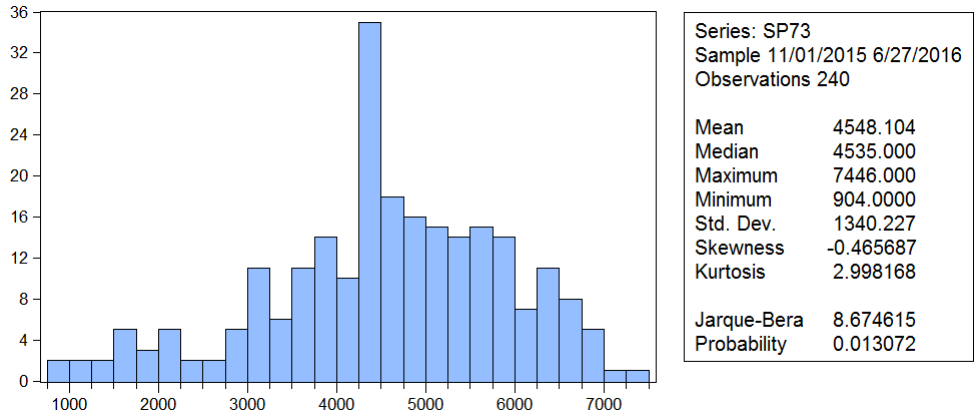


```
> diari73 <- scan("SP73diari.dat")
Read 240 items
> diari73ts<-ts(diari73)
> diari73ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 3692 6412 6449 6897 7087 6592 5575 3490 6446 6802 6312 4669 6710 4380 3772 5778 6446 6337 6671
 [20] 6755 4842 3332 4713 3760 4804 2629 5688 4466 3528 4259 1828 1646 1667 2797 2824 2755 4351 2751
 [39] 6121 3878 3629 1768 1151 2137 2249 5693 5809 7446 5521 4249 6668 3742 6979 5892 3235 3304 3445
 [58] 5853 5913 4259 4259 4259 4259 4259 2720 3109 2940 6037 6374 4340 3541 5397 5971 4883 4891 6567
 [77] 4703 3158 3723 2467 5685 4483 4347 4305 3240 4967 4523 6172 3181 4259 1327 3622 4521 5359 4259
 [96] 4259 6469 4937 3020 4517 5311 3764 4259 4259 4259 4259 4259 5172 4920 5518 4992 5299 3763 5027
[115] 6336 6793 4766 5127 4416 3221 3950 5516 4865 4640 3135 4504 3084 4177 5847 4707 5252 5881 4369
[134] 3362 5235 5717 5812 5684 6013 5142 3693 6167 5832 5599 5354 3944 5124 4121 3903 4574 6538 3695
[153] 5213 4824 4088 5482 5932 4606 3976 4931 5377 4158 5450 5349 4437 4934 3646 5401 4260 4560 4687
[172] 4272 5855 5049 5595 3776 5000 5428 5717 6634 6299 5550 4665 6128 4771 1716 2189 1141 5109 4257
[191] 4259 4160 4687 1639 4013 5113 4537 2169 4962 5564 4259 4363 5797 3835 1489 3110 4294  904 4148
[210] 3932 3864 3038 4533 5328  915 3357 5149 3704 1665 2424 2221 4259 6324 5757 4494 5034 5678 5272
[229] 1785 4440 5159 4193 6081 6697 4989 3903 5029 4355 4726 4158
> plot(diari73, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-7.3",cex.main=1.5, font.main=2)
> plot.ts(diari73ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-7.3",cex.main=1.5, font.main=2)
```

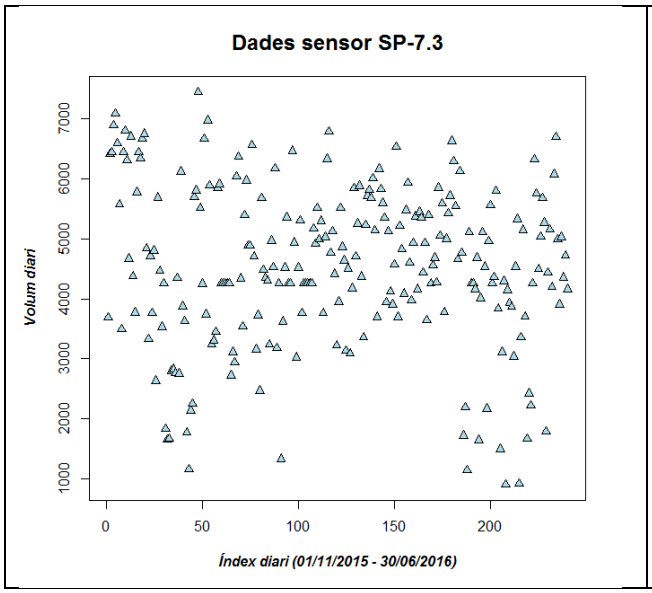

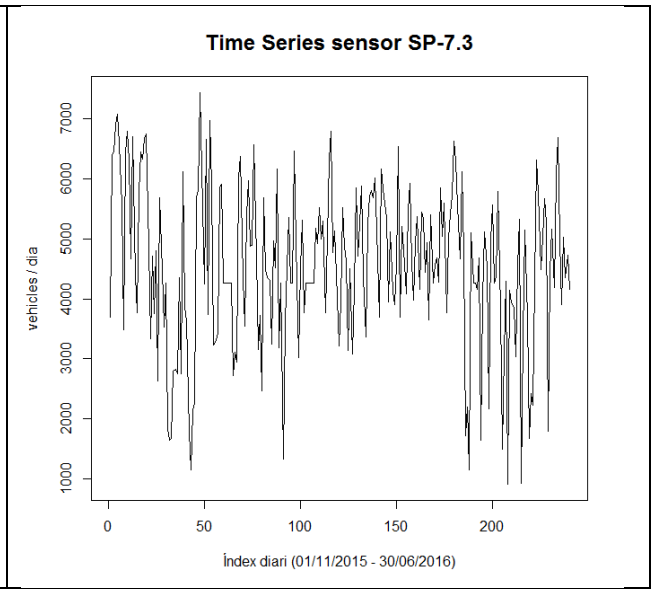


```
> diari73SMA<-SMA(diari73ts, n=10)
> plot.ts(diari73ts, xlim=c(0,250), ylim=c(0,7000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-7.3 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari73SMA, col="red", xlim=c(0,250), ylim=c(0,7000), xlab="", ylab="", lty=1, lwd=3)
```

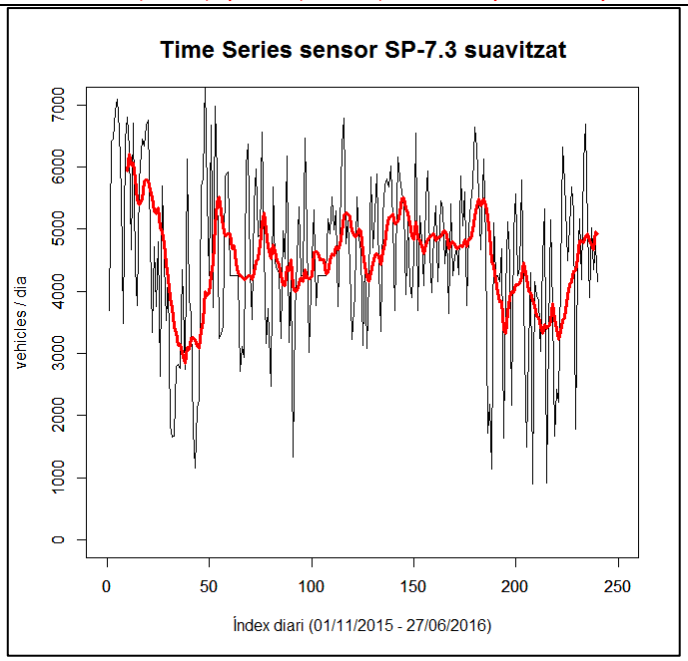


```
> diari73ts <- ts(diari73, frequency=30)
> diaricompo73<-decompose(diari73ts)
> plot(diaricompo73, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

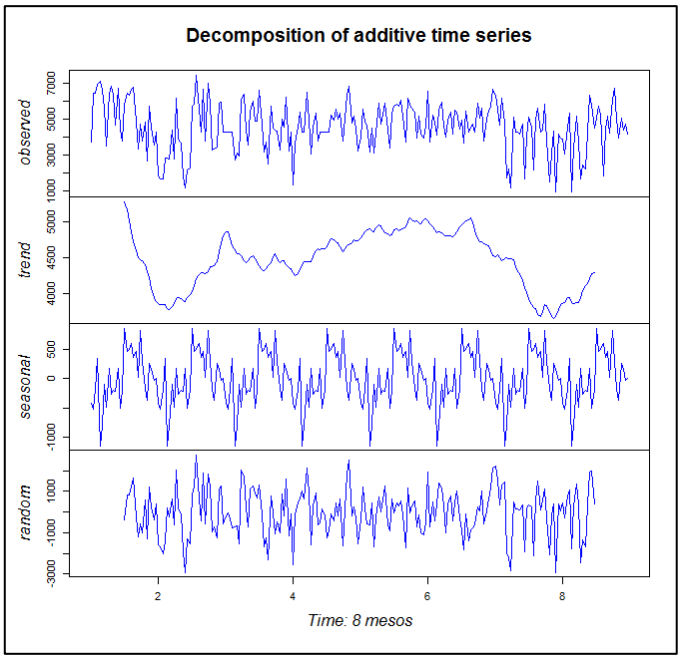


```
> diari73tsforecast<-HoltWinters(diari73ts, beta=FALSE, gamma=FALSE)
> diari73tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari73ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.2438751
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 4619.357
```

```
> diari73tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
          xhat    level
1.033333 3692.000 3692.000
1.066667 4355.340 4355.340
1.100000 4865.932 4865.932
1.133333 5361.259 5361.259
1.166667 5782.124 5782.124
1.200000 5979.633 5979.633
1.233333 5880.953 5880.953
1.266667 5297.859 5297.859
...
8.733333 4397.413 4397.413
8.766667 4807.998 4807.998
8.800000 5268.678 5268.678
8.833333 5200.472 5200.472
8.866667 4884.051 4884.051
8.900000 4919.400 4919.400
8.933333 4781.757 4781.757
8.966667 4768.159 4768.159
```

```
> plot(diari73tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-7.3)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

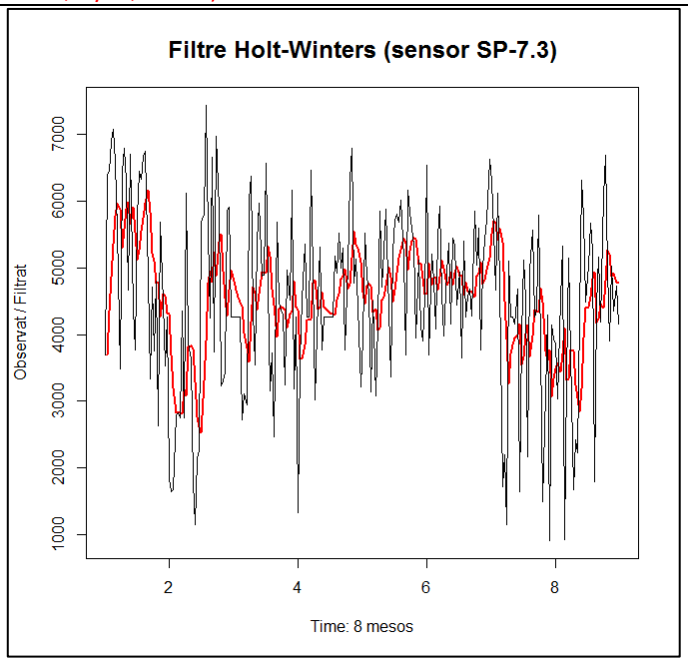


```
> diari73tsforecast2<-forecast.HoltWinters(diari73tsforecast, h=30)
> diari73tsforecast2
         Point Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000       4619.357 2946.094 6292.619 2060.3219 7178.391
9.033333       4619.357 2897.054 6341.660 1985.3215 7253.392
9.066667       4619.357 2849.372 6389.341 1912.3984 7326.315
9.100000       4619.357 2802.941 6435.772 1841.3888 7397.324
9.133333       4619.357 2757.668 6481.045 1772.1497 7466.563
9.166667       4619.357 2713.470 6525.243 1704.5549 7534.158
9.200000       4619.357 2670.274 6568.439 1638.4924 7600.221
9.233333       4619.357 2628.015 6610.698 1573.8627 7664.850
9.266667       4619.357 2586.634 6652.079 1510.5762 7728.137
9.300000       4619.357 2546.079 6692.634 1448.5527 7790.160
9.333333       4619.357 2506.303 6732.411 1387.7193 7850.994
9.366667       4619.357 2467.261 6771.452 1328.0101 7910.703
9.400000       4619.357 2428.915 6809.798 1269.3650 7969.348
9.433333       4619.357 2391.229 6847.484 1211.7290 8026.984
9.466667       4619.357 2354.169 6884.544 1155.0518 8083.661
9.500000       4619.357 2317.707 6921.006 1099.2870 8139.426
9.533333       4619.357 2281.813 6956.900 1044.3920 8194.321
9.566667       4619.357 2246.462 6992.251  990.3273 8248.386
9.600000       4619.357 2211.630 7027.083  937.0562 8301.657
9.633333       4619.357 2177.295 7061.419  884.5450 8354.168
9.666667       4619.357 2143.435 7095.278  832.7618 8405.951
9.700000       4619.357 2110.033 7128.680  781.6773 8457.036
9.733333       4619.357 2077.069 7161.644  731.2640 8507.449
9.766667       4619.357 2044.528 7194.185  681.4960 8557.217
9.800000       4619.357 2012.393 7226.321  632.3492 8606.364
9.833333       4619.357 1980.649 7258.065  583.8008 8654.912
9.866667       4619.357 1949.282 7289.431  535.8296 8702.884
9.900000       4619.357 1918.279 7320.434  488.4155 8750.298
9.933333       4619.357 1887.629 7351.084  441.5394 8797.174
9.966667       4619.357 1857.318 7381.395  395.1835 8843.530
```

```
> plot.forecast(diari73tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-7.3)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

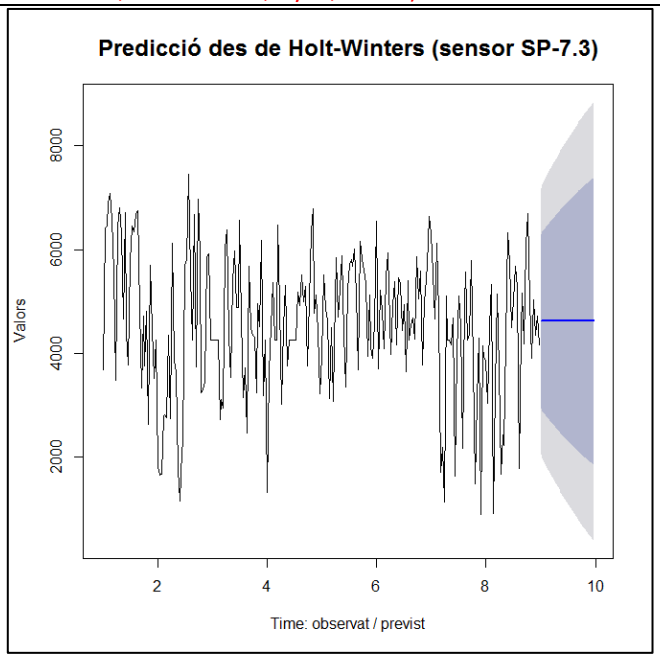


```
> acf(diari73tsforecast2$residuals, lag.max=30)
```

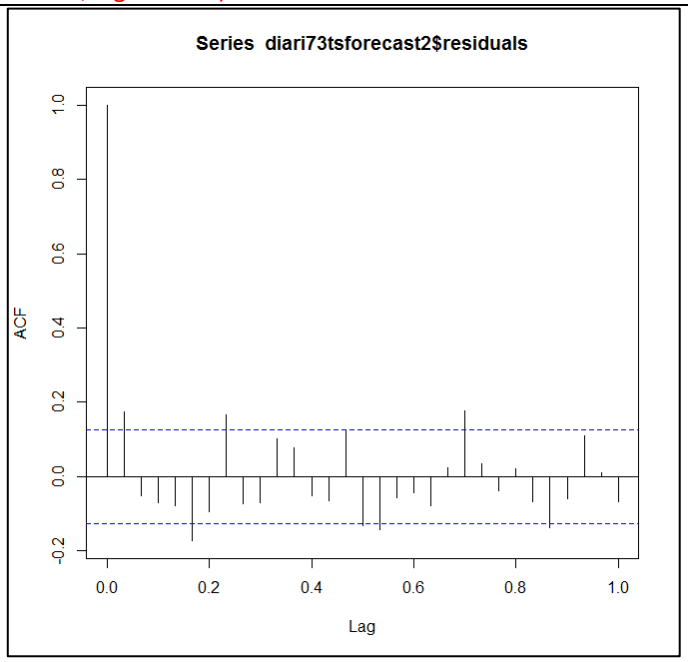


```
> Box.test(diari73tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari73tsforecast2$residuals
X-squared = 73.257, df = 30, p-value = 1.755e-05
```

```
> plot.ts(diari73tsforecast2$residuals)
```

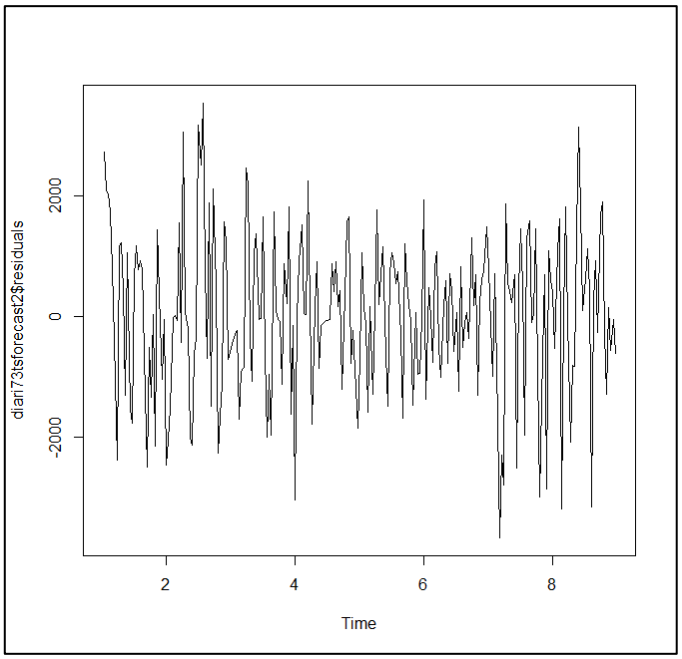


```
> plotForecastErrors(diari73tsforecast2$residuals)
```

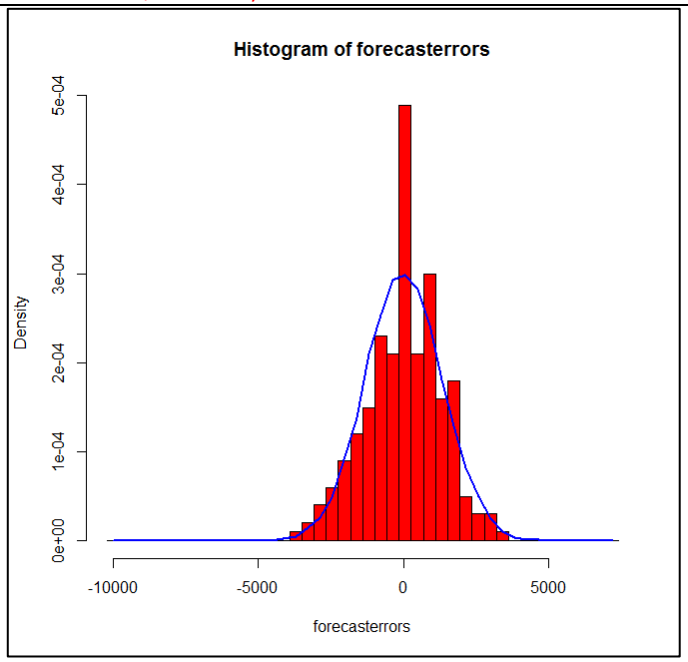

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

- **Sensor SP-7.4** (fitxer SP74diari.dat)

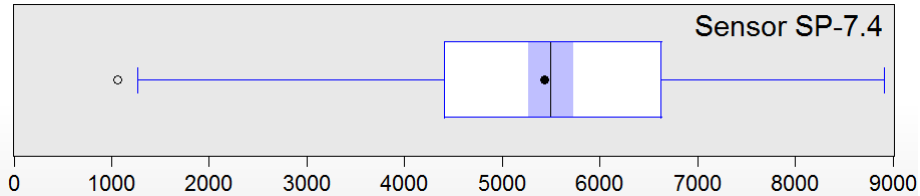

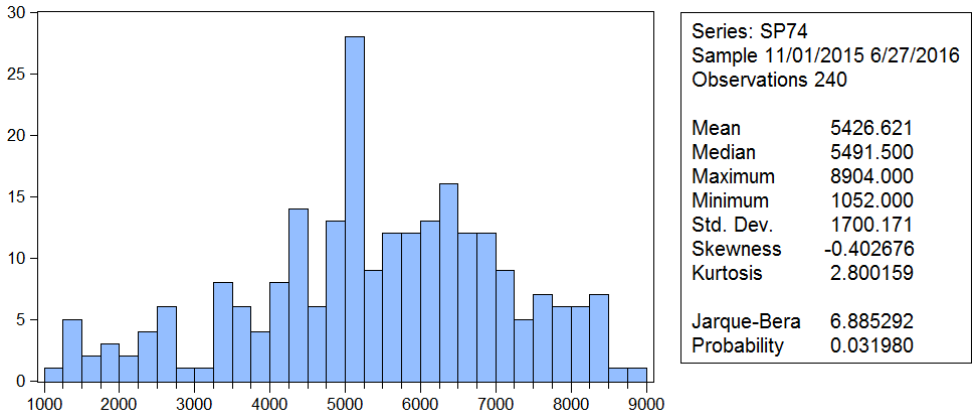


```
> diari74 <- scan("SP74diari.dat")
Read 240 items
> diari74ts<-ts(diari74)
> diari74ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 4339 7562 7603 8244 8696 8326 6928 4393 7848 8396 8073 5875 8407 5576 4617 6923 7784 7649 8272
 [20] 8478 5910 3930 5594 5055 6334 3307 6907 5871 4393 1465 2735 2406 2448 3688 3784 3503 5357 3390
 [39] 7072 4433 4416 2195 1260 2615 2633 6482 6679 8904 7132 5140 7906 4855 8424 7129 3908 4293 4302
 [58] 7040 7088 5125 5125 5125 5125 5125 3292 3994 3564 7519 7682 5699 4233 6204 7079 5675 6025 7844
 [77] 5654 4036 5151 3487 6857 5816 6070 5403 4155 6297 5732 8015 4409 1357 1960 4466 5667 6170 5125
 [96] 5125 8124 6313 3389 6132 6584 5127 5125 5125 5125 5125 5125 5802 6366 6789 6243 6651 4563 6107
[115] 7366 8078 6032 6786 5492 3355 4975 7944 6686 6500 4544 6135 4299 5884 7455 6352 7123 7743 6041
[134] 4530 6853 6436 6654 5202 6577 6469 4398 7314 7114 6759 6899 5077 6227 4782 4182 5491 7502 4637
[153] 5986 3409 4137 6331 5168 5106 4834 4820 6478 4787 6470 6271 5325 5721 4470 6500 4816 5781 5910
[172] 5458 6486 6170 6355 4295 6076 6516 6895 4932 7757 4216 5615 7012 5462 2250 2825 1656 6292 2568
[191] 5125 4223 3699 1960 4353 5434 4888 1737 5978 5447 1052 5138 5854 3283 1375 3625 5067 1298 4774
[210] 4960 3102 1949 4244 5190 5125 3709 6702 4615 2121 2688 2597 5125 8054 7250 5098 6465 6908 6851
[229] 2313 5843 6687 4931 7494 8331 6568 5621 5628 5623 4923 5141
> plot(diari74, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-7.4",cex.main=1.5, font.main=2)
> plot.ts(diari74ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-7.4",cex.main=1.5, font.main=2)
```

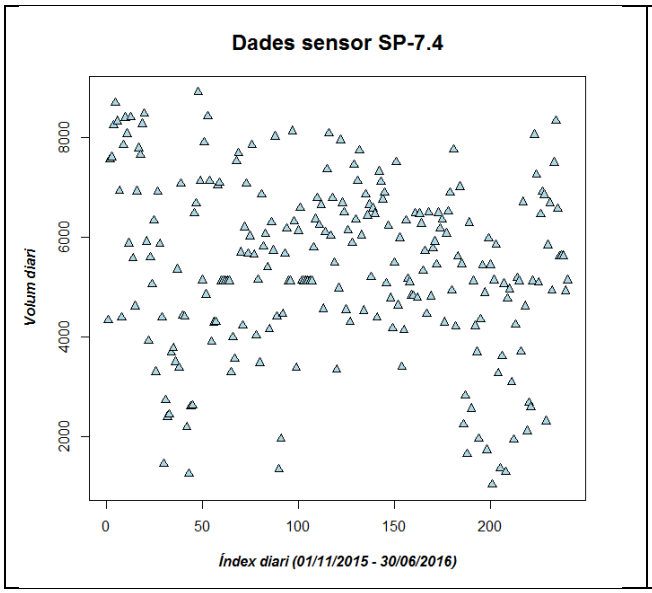

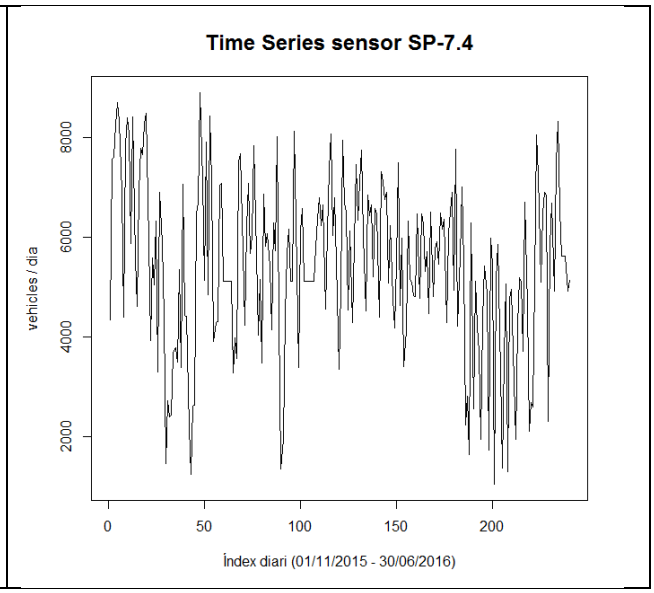


```
> diari74SMA<-SMA(diari74ts, n=10)
> plot.ts(diari74ts, xlim=c(0,250), ylim=c(0,9000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-7.4 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari74SMA, col="red", xlim=c(0,250), ylim=c(0,9000), xlab="", ylab="", lty=1, lwd=3)
```

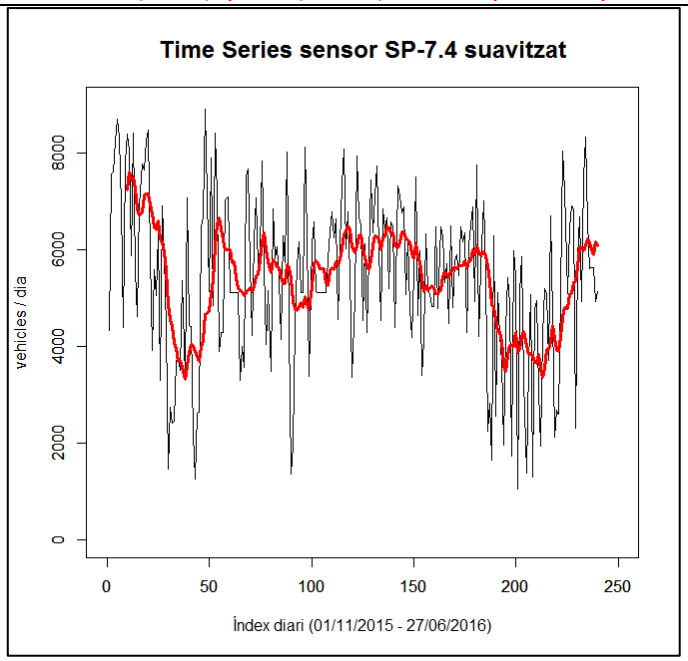


```
> diari74ts <- ts(diari74, frequency=30)
> diaricompo74<-decompose(diari74ts)
> plot(diaricompo74, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

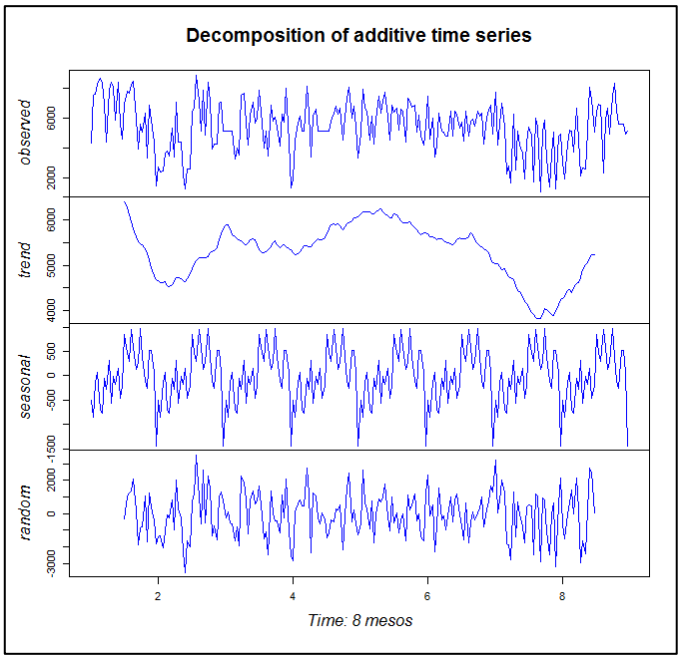


```
> diari74tsforecast<-HoltWinters(diari74ts, beta=FALSE, gamma=FALSE)
> diari74tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari74ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.241949
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 5612.741
```

```
> diari74tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
          xhat    level
1.033333 4339.000 4339.000
1.066667 5118.802 5118.802
1.100000 5719.851 5719.851
1.133333 6330.566 6330.566
1.166667 6902.880 6902.880
1.200000 7247.203 7247.203
1.233333 7169.972 7169.972
1.266667 6498.086 6498.086
...
8.733333 5510.245 5510.245
8.766667 5990.212 5990.212
8.800000 6556.563 6556.563
8.833333 6559.330 6559.330
8.866667 6332.302 6332.302
8.900000 6161.897 6161.897
8.933333 6031.512 6031.512
8.966667 5763.308 5763.308
```

```
> plot(diari74tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-7.4)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

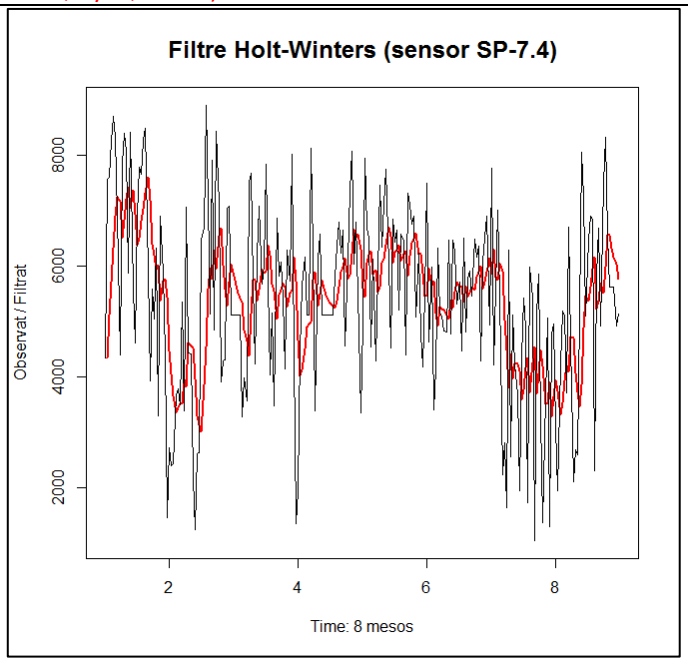


```
> diari74tsforecast2<-forecast.HoltWinters(diari74tsforecast, h=30)
> diari74tsforecast2
         Point Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000       5612.741 3559.535 7665.948 2472.6333  8752.850
9.033333       5612.741 3500.293 7725.190 2382.0305  8843.452
9.066667       5612.741 3442.668 7782.815 2293.9002  8931.583
9.100000       5612.741 3386.534 7838.949 2208.0504  9017.432
9.133333       5612.741 3331.781 7893.702 2124.3127  9101.170
9.166667       5612.741 3278.311 7947.172 2042.5386  9182.944
9.200000       5612.741 3226.040 7999.443 1962.5959  9262.887
9.233333       5612.741 3174.888 8050.595 1884.3669  9341.116
9.266667       5612.741 3124.789 8100.694 1807.7460  9417.737
9.300000       5612.741 3075.678 8149.805 1732.6378  9492.845
9.333333       5612.741 3027.500 8197.983 1658.9562  9566.527
9.366667       5612.741 2980.204 8245.279 1586.6227  9638.860
9.400000       5612.741 2933.742 8291.740 1515.5661  9709.917
9.433333       5612.741 2888.073 8337.410 1445.7210  9779.762
9.466667       5612.741 2843.157 8382.326 1377.0274  9848.456
9.500000       5612.741 2798.957 8426.525 1309.4302  9916.053
9.533333       5612.741 2755.442 8470.041 1242.8786  9982.604
9.566667       5612.741 2712.579 8512.904 1177.3254 10048.157
9.600000       5612.741 2670.340 8555.143 1112.7271 10112.756
9.633333       5612.741 2628.699 8596.783 1049.0431 10176.440
9.666667       5612.741 2587.632 8637.851  986.2356 10239.247
9.700000       5612.741 2547.114 8678.369  924.2693 10301.214
9.733333       5612.741 2507.125 8718.358  863.1115 10362.371
9.766667       5612.741 2467.645 8757.838  802.7312 10422.752
9.800000       5612.741 2428.654 8796.829  743.0995 10482.383
9.833333       5612.741 2390.134 8835.348  684.1893 10541.294
9.866667       5612.741 2352.070 8873.413  625.9750 10599.508
9.900000       5612.741 2314.445 8911.038  568.4324 10657.051
9.933333       5612.741 2277.244 8948.239  511.5389 10713.944
9.966667       5612.741 2240.454 8985.029  455.2729 10770.210
```

```
> plot.forecast(diari74tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-7.4)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

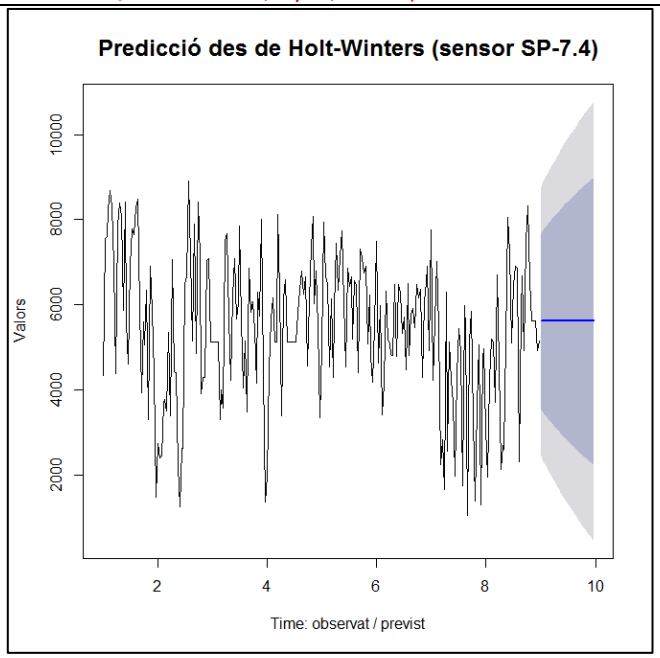


```
> acf(diari74tsforecast2$residuals, lag.max=30)
```

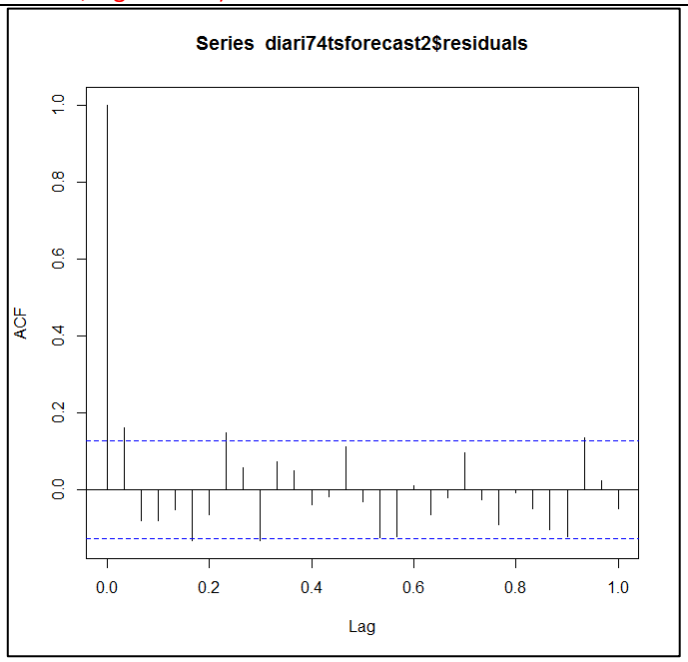


```
> Box.test(diari74tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari74tsforecast2$residuals
X-squared = 59.113, df = 30, p-value = 0.001177
```

```
> plot.ts(diari74tsforecast2$residuals)
```

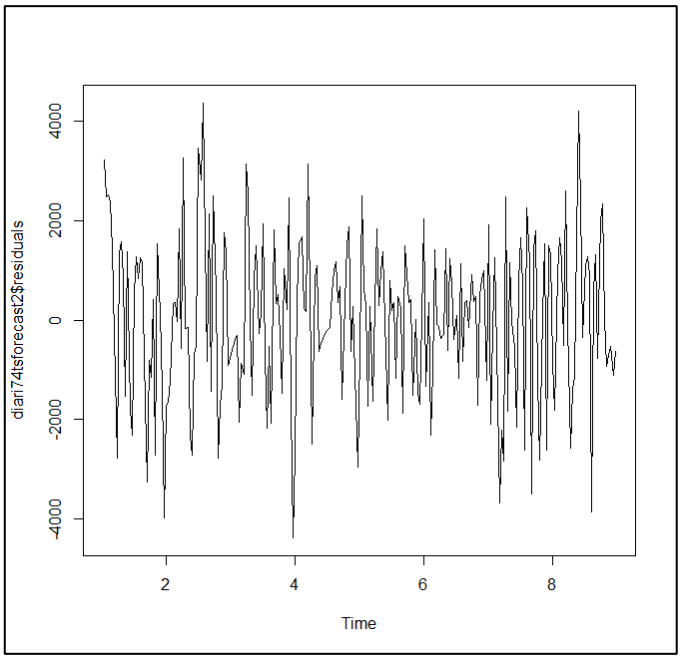


```
> plotForecastErrors(diari74tsforecast2$residuals)
```

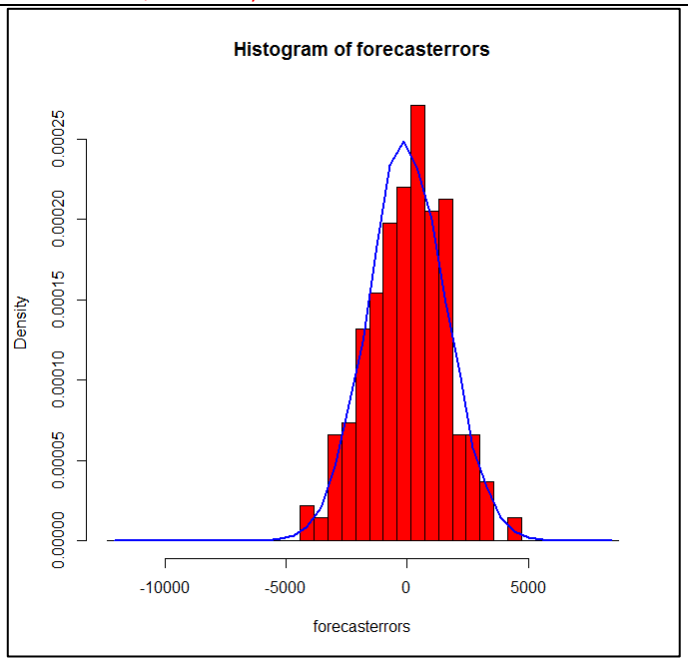

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

- **Sensor SP-7.5** (fitxer SP75diari.dat)

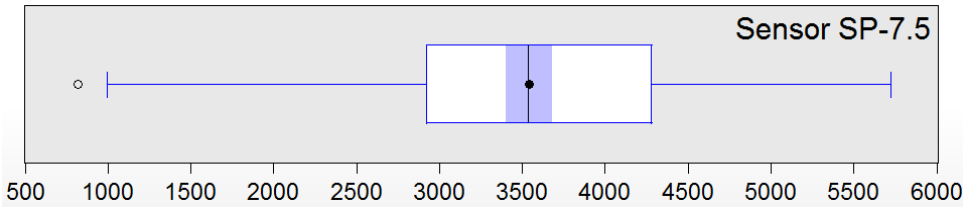

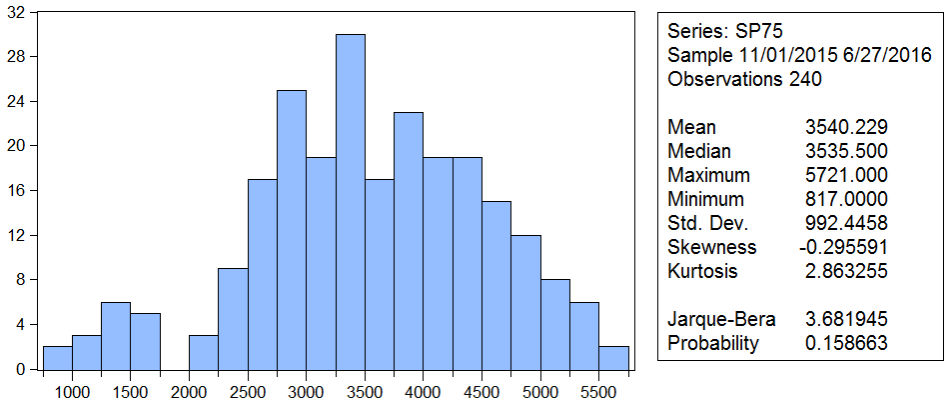


```
> diari75 <- scan("SP75diari.dat")
Read 240 items
> diari75ts<-ts(diari75)
> diari75ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 2719 4924 5054 4932 5389 4987 4532 2821 4850 5279 5056 3625 5110 3682 2911 4309 4959 4725 5254
 [20] 5319 4077 2304 3402 2983 3996 2029 4311 3830 2656 3277 1626 1329 1404 2276 2618 2135 3629 2284
 [39] 4606 3221 2919 1478 3277 1614 1685 4282 4448 5721 4688 3220 5146 2949 5550 4826 2823 2893 2562
 [58] 4413 4534 3277 3277 3277 3277 3277 2343 2545 2481 4680 4728 3536 2601 3837 4393 3568 3727 5059
 [77] 4000 2496 3067 2111 4250 3865 3726 3468 2574 4138 3747 5343 3060 3277 1351 3049 3384 3812 3277
 [96] 3277 4930 3969 2274 3688 4084 2878 3277 3277 3277 3277 3277 3930 3826 4482 3838 4126 2605 3425
[115] 4340 4692 3974 4212 3425 2611 2880 5146 4223 4102 2615 4382 2880 3793 4993 4064 4794 5141 4021
[134] 2968 4524 4929 4601 4661 5069 4265 2730 4404 4369 4072 4370 3178 3899 2890 2764 3535 4546 2752
[153] 3844 3888 2862 3791 4552 3244 3120 3603 3967 2586 3797 3643 3103 3413 2605 4189 2979 3348 3624
[172] 3107 4347 3848 4820 2797 3758 4124 4209 5392 4569 4473 3725 4476 2989 1237 1658  817 3808 3182
[191] 3277 3232 3225 1130 2824 3822 2960  992 3457 3989 3277 3104 4127 2718 1169 2552 3181 3277 2995
[210] 3012 2656 2292 3547 4097 3277 2467 4025 2655 1336 3277 1608 3277 4603 4438 3008 3661 4164 3879
[229] 1348 3390 4117 2921 4405 4951 3542 2933 3054 3172 2985 2889
> plot(diari75, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-7.5",cex.main=1.5, font.main=2)
> plot.ts(diari75ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-7.5",cex.main=1.5, font.main=2)
```

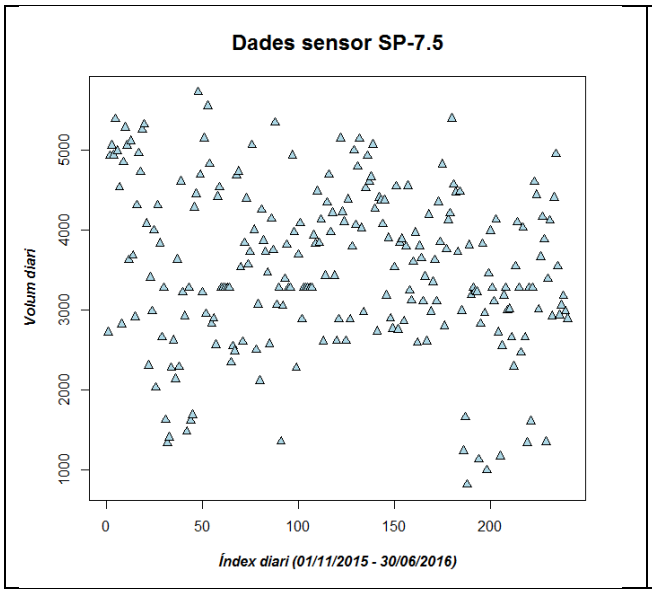

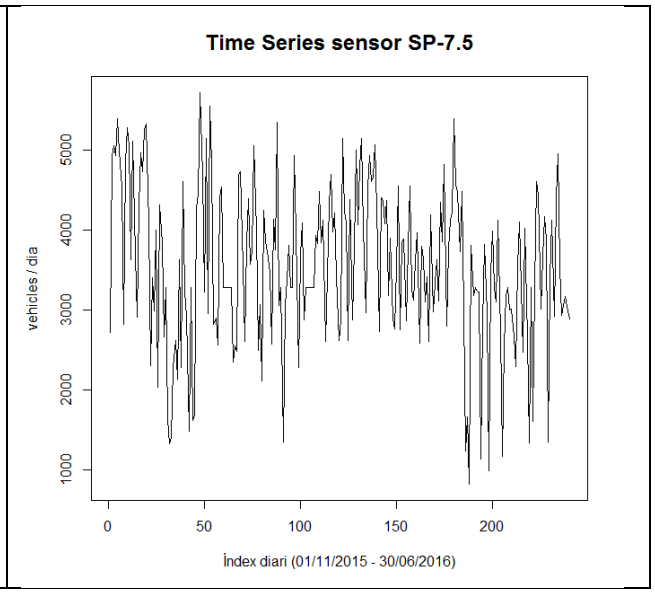


```
> diari75SMA<-SMA(diari75ts, n=10)
> plot.ts(diari75ts, xlim=c(0,250), ylim=c(0,6000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-7.5 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari75SMA, col="red", xlim=c(0,250), ylim=c(0,6000), xlab="", ylab="", lty=1, lwd=3)
```

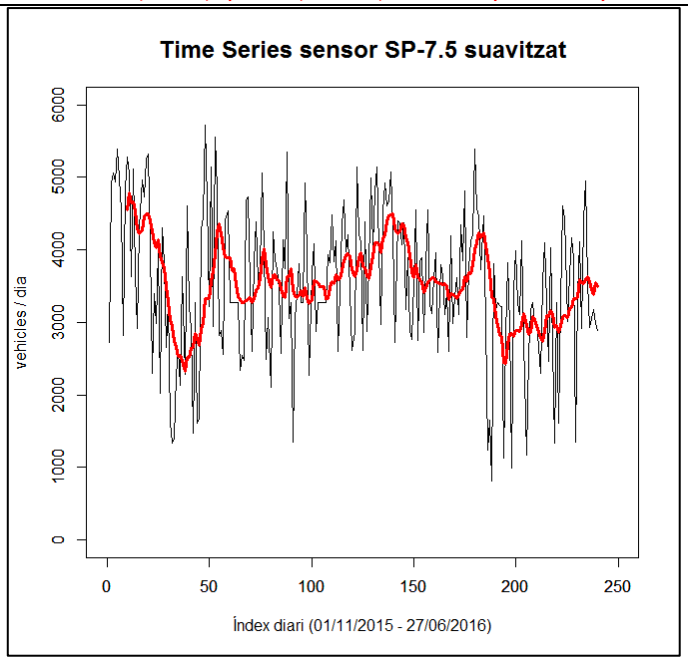


```
> diari75ts <- ts(diari75, frequency=30)
> diaricompo75<-decompose(diari75ts)
> plot(diaricompo75, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

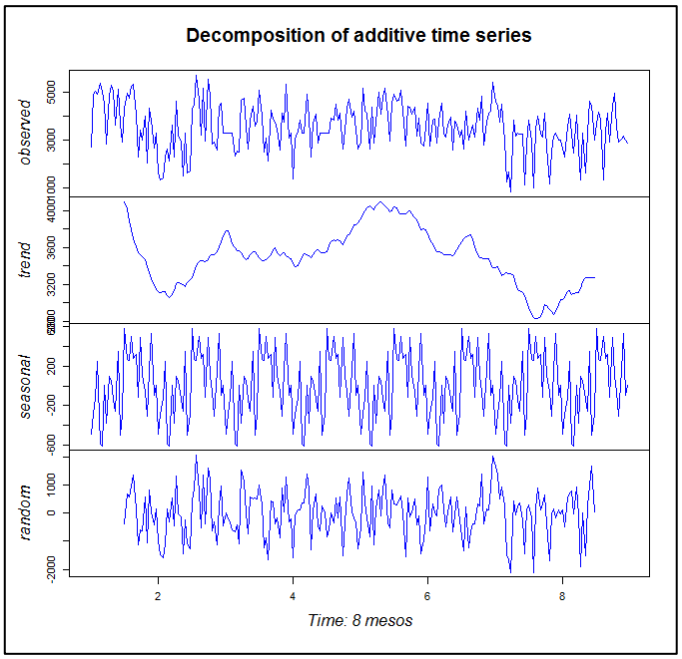


```
> diari75tsforecast<-HoltWinters(diari75ts, beta=FALSE, gamma=FALSE)
> diari75tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari75ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.2264995
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 3214.404
```

```
> diari75tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
          xhat    level
1.033333 2719.000 2719.000
1.066667 3218.431 3218.431
1.100000 3634.187 3634.187
1.133333 3928.141 3928.141
1.166667 4259.025 4259.025
1.200000 4423.911 4423.911
1.233333 4448.393 4448.393
1.266667 4079.789 4079.789
...
8.733333 3290.956 3290.956
8.766667 3543.286 3543.286
8.800000 3862.133 3862.133
8.833333 3789.623 3789.623
8.866667 3595.598 3595.598
8.900000 3472.927 3472.927
8.933333 3404.767 3404.767
8.966667 3309.690 3309.690
```

```
> plot(diari75tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-7.5)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

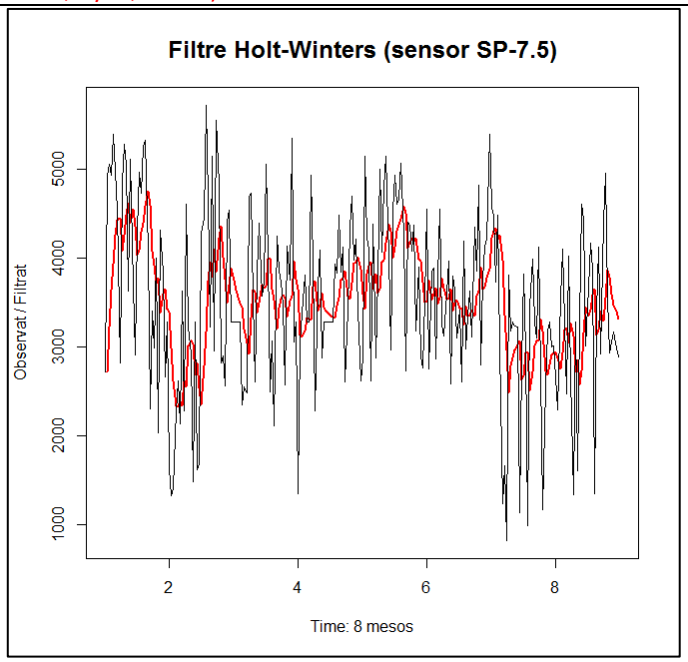


```
> diari75tsforecast2<-forecast.HoltWinters(diari75tsforecast, h=30)
> diari75tsforecast2
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
9.000000	3214.404	1972.958	4455.850	1315.7755	5113.032
9.033333	3214.404	1941.511	4487.296	1267.6829	5161.125
9.066667	3214.404	1910.824	4517.984	1220.7501	5208.058
9.100000	3214.404	1880.842	4547.966	1174.8970	5253.911
9.133333	3214.404	1851.520	4577.288	1130.0523	5298.755
9.166667	3214.404	1822.815	4605.993	1086.1524	5342.655
9.200000	3214.404	1794.691	4634.117	1043.1399	5385.668
9.233333	3214.404	1767.113	4661.695	1000.9631	5427.845
9.266667	3214.404	1740.051	4688.757	959.5750	5469.233
9.300000	3214.404	1713.476	4715.331	918.9331	5509.875
9.333333	3214.404	1687.364	4741.443	878.9983	5549.809
9.366667	3214.404	1661.691	4767.116	839.7351	5589.073
9.400000	3214.404	1636.436	4792.372	801.1105	5627.697
9.433333	3214.404	1611.579	4817.229	763.0945	5665.713
9.466667	3214.404	1587.101	4841.707	725.6591	5703.149
9.500000	3214.404	1562.986	4865.821	688.7785	5740.029
9.533333	3214.404	1539.218	4889.589	652.4287	5776.379
9.566667	3214.404	1515.783	4913.025	616.5876	5812.220
9.600000	3214.404	1492.667	4936.141	581.2342	5847.573
9.633333	3214.404	1469.857	4958.951	546.3493	5882.458
9.666667	3214.404	1447.341	4981.467	511.9146	5916.893
9.700000	3214.404	1425.109	5003.699	477.9132	5950.894
9.733333	3214.404	1403.149	5025.658	444.3291	5984.479
9.766667	3214.404	1381.453	5047.355	411.1473	6017.660
9.800000	3214.404	1360.010	5068.797	378.3538	6050.454
9.833333	3214.404	1338.813	5089.995	345.9351	6082.873
9.866667	3214.404	1317.852	5110.955	313.8787	6114.929
9.900000	3214.404	1297.121	5131.687	282.1728	6146.635
9.933333	3214.404	1276.611	5152.196	250.8061	6178.002
9.966667	3214.404	1256.317	5172.491	219.7679	6209.040

```
> plot.forecast(diari75tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-7.5)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

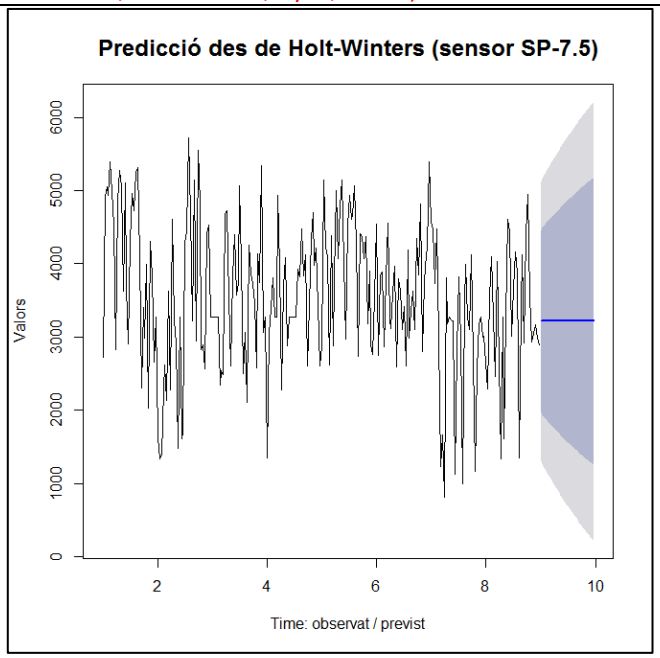


```
> acf(diari75tsforecast2$residuals, lag.max=30)
```

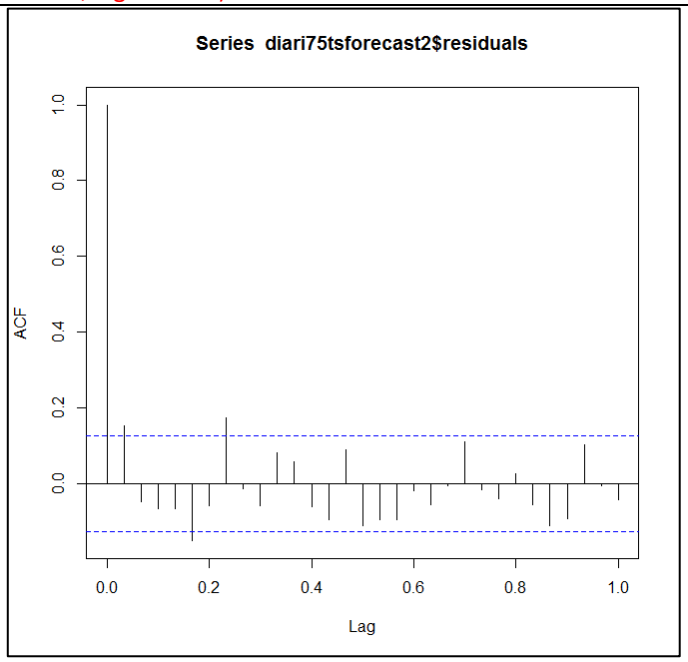


```
> Box.test(diari75tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari75tsforecast2$residuals
X-squared = 53.719, df = 30, p-value = 0.004941
```

```
> plot.ts(diari75tsforecast2$residuals)
```

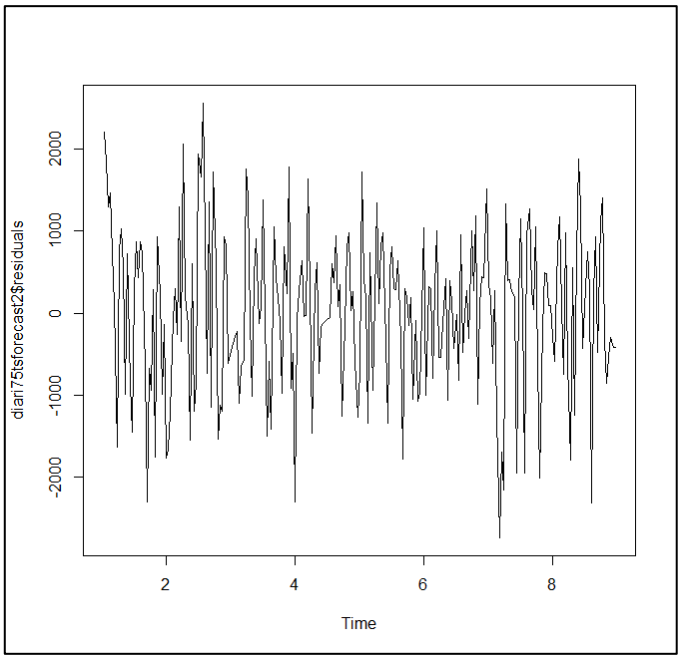


```
> plotForecastErrors(diari75tsforecast2$residuals)
```

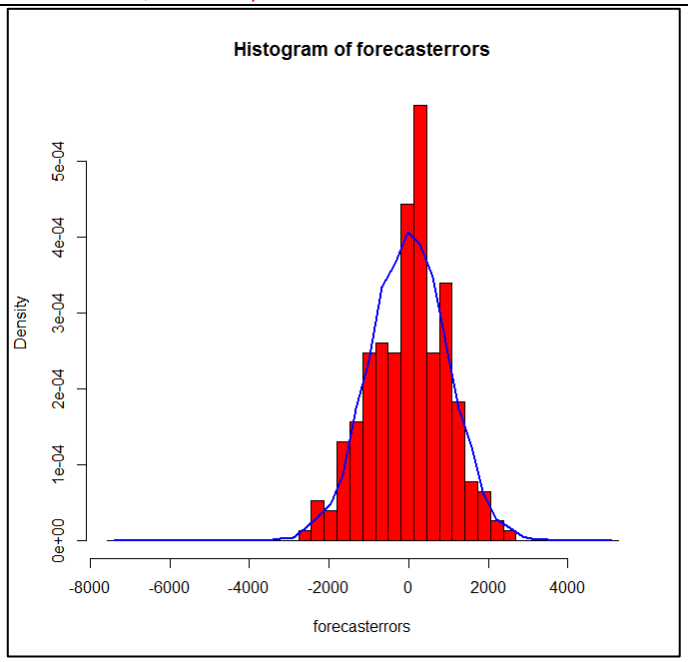

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

- **Sensor SP-7.6** (fitxer SP76diari.dat)

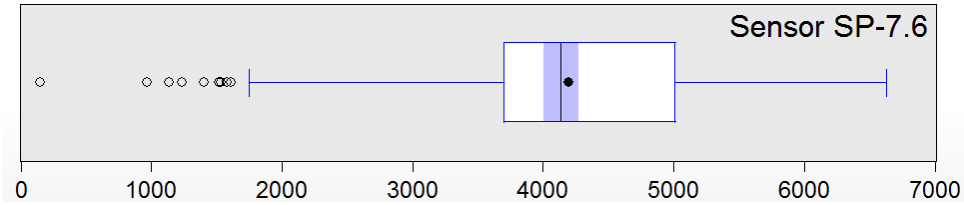

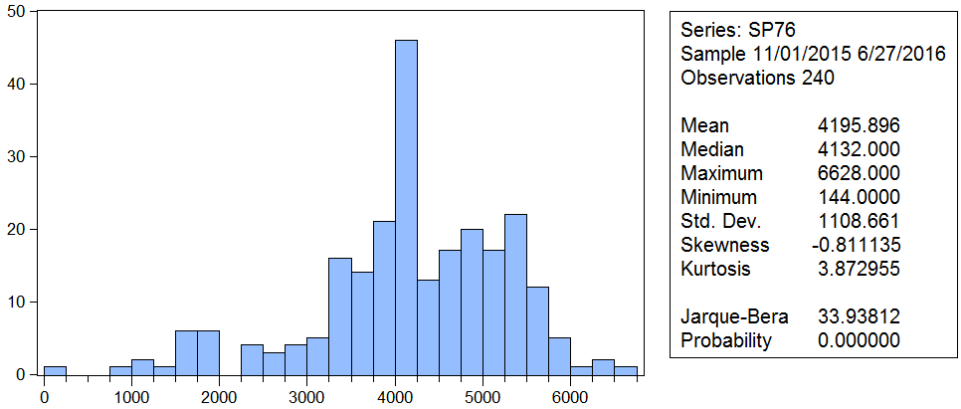


```
> diari76 <- scan("SP76diari.dat")
Read 240 items
> diari76ts<-ts(diari76)
> diari76ts
Time Series:
Start = 1
End = 240
Frequency = 1
  [1] 3660 5393 5658 5677 5854 5583 5240 3692 5371 5775 5339 3932 5674 4110 3851 4735 5326 5226 5454
 [20] 5706 4682 3212 3856 3207 4366 2349 4740 4335 3645 4132 1792 1511 1606 2472 2797 2770 4188 2944
 [39] 5128 3501 3258 1746 1135 1790 1972 4784 4972 6312 5270 4159 5489 3322 5949 5418 3603 3680 3390
 [58] 4925 5234 4132 4132 4132 4132 4132 2317 3091 3262 5298 5441 4016 3429 4320 4873 4083 4305 5594
 [77] 4710 3450 3435 2471 4751 4076 4129 4077 3301 4147 3789 4942 4132 4132 4132 3217 3307 6473 2622
 [96] 4225 4132 5453 4185 6628 5323 3784 4132 4132 4132 4132  144 4609 5654 5415 4601 5038 3714 4192
[115] 5089 5532 4424 4773 4425 3676 3472 5727 4785 4871 3166 5107 3853 4207 5845 4721 5385 5843 4940
[134] 4080 5185 5522 5123 5143 5574 5010 3545 5182 5129 4927 4873 3983 4795 4097 3846 4083 5352 3258
[153] 4751 4643 3966 4745 5278 4009 3771 4456 4994 3933 4694 4580 3793 4262 3254 4971 4033 3844 4256
[172] 3692 5187 4646 5506 3839 4515 4701 4999 6084 5389 5290 4188 5338 3754 1529 1929  966 4777 4065
[191] 4132 3985 4099 1579 3673 5040 4352 1837 4488 4743 4132 3759 5191 3709 1233 2672 3575 4132 3498
[210] 3613 3818 2539 4116 4517 4132 2855 4797 3382 1403 4132 1891 4132 5270 5449 4112 4130 4712 4398
[229] 1579 3799 4831 3974 5105 5406 4036 3495 4182 3950 4488 3264
> plot(diari76, pch=24, bg="light blue", xlab="Índex diari (01/11/2015 - 30/06/2016)", cex.lab=1, font.lab=4,
ylab="Volum diari", main="Dades sensor SP-7.6",cex.main=1.5, font.main=2)
> plot.ts(diari76ts, xlab="Índex diari (01/11/2015 - 30/06/2016)", ylab="vehicles / dia", main="Time Series sensor
SP-7.6",cex.main=1.5, font.main=2)
```

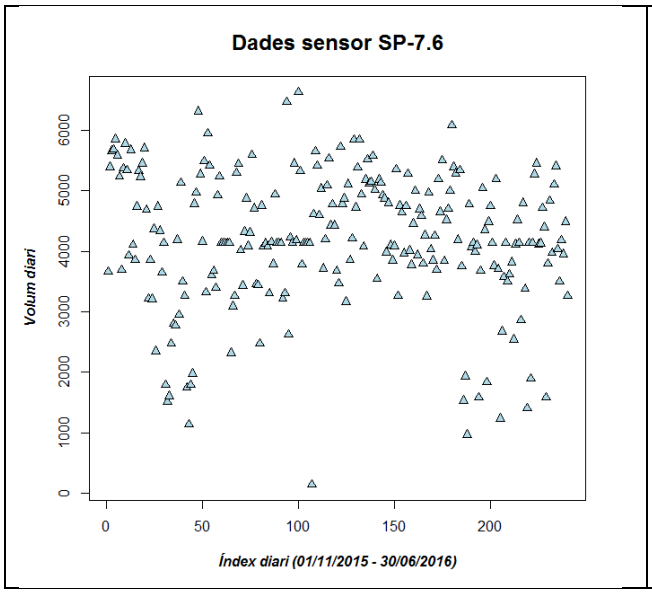

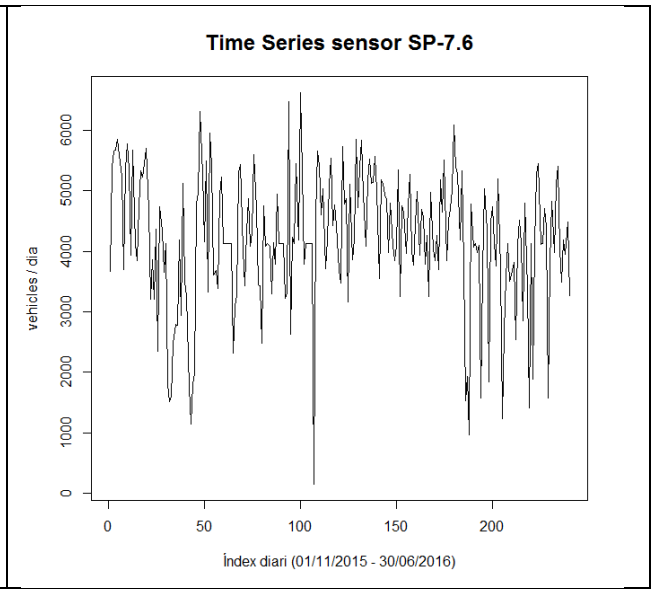


```
> diari76SMA<-SMA(diari76ts, n=10)
> plot.ts(diari76ts, xlim=c(0,250), ylim=c(0,7000), xlab="Índex diari (01/11/2015 - 27/06/2016)", ylab="vehicles / dia", main="Time Series sensor SP-7.6 suavitzat",cex.main=1.5, font.main=2)
> par(new=T)
> plot.ts(diari76SMA, col="red", xlim=c(0,250), ylim=c(0,7000), xlab="", ylab="", lty=1, lwd=3)
```

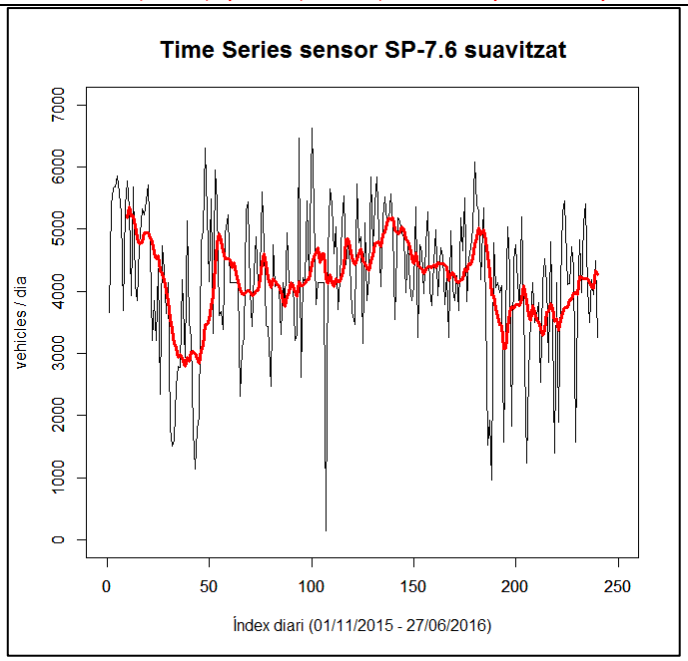


```
> diari76ts <- ts(diari76, frequency=30)
> diaricompo76<-decompose(diari76ts)
> plot(diaricompo76, col="blue", xlab="Time: 8 mesos", cex.lab=1, font.lab=3)
```

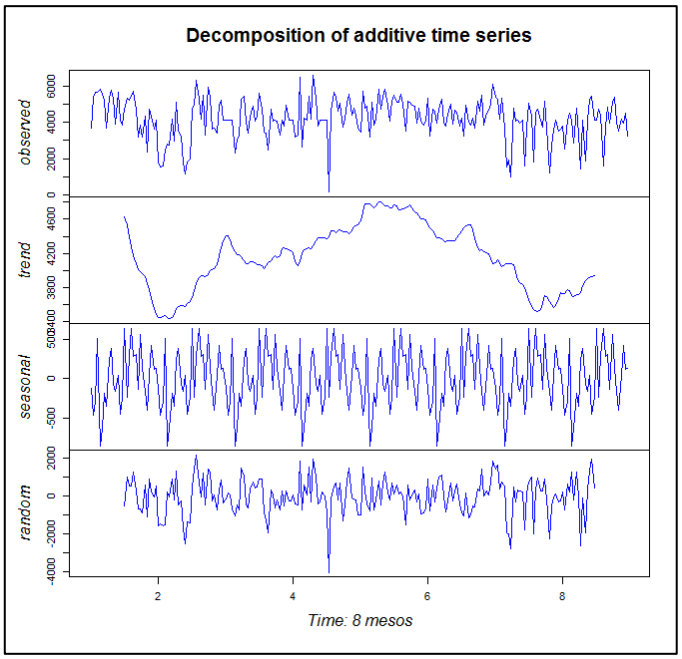


```
> diari76tsforecast<-HoltWinters(diari76ts, beta=FALSE, gamma=FALSE)
> diari76tsforecast
Holt-Winters exponential smoothing without trend and without seasonal component.
Call:
HoltWinters(x = diari76ts, beta = FALSE, gamma = FALSE)
Smoothing parameters:
 alpha: 0.1957862
 beta : FALSE
 gamma: FALSE
Coefficients:
     [,1]
a 4019.692
```

```
> diari76tsforecast$fitted
Time Series:
Start = c(1, 2)
End = c(8, 30)
Frequency = 30
          xhat    level
1.033333 3660.000 3660.000
1.066667 3999.297 3999.297
1.100000 4324.049 4324.049
1.133333 4588.938 4588.938
1.166667 4836.619 4836.619
1.200000 4982.750 4982.750
1.233333 5033.116 5033.116
1.266667 4770.544 4770.544
...
8.733333 3955.393 3955.393
8.766667 4180.470 4180.470
8.800000 4420.412 4420.412
8.833333 4345.149 4345.149
8.866667 4178.702 4178.702
8.900000 4179.348 4179.348
8.933333 4134.444 4134.444
8.966667 4203.666 4203.666
```

```
> plot(diari76tsforecast, xlab="Time: 8 mesos", ylab="Observat / Filtrat", main="Filtre Holt-Winters (sensor SP-7.6)",cex.main=1.5, font.main=2, lty=1, lwd=2)
```

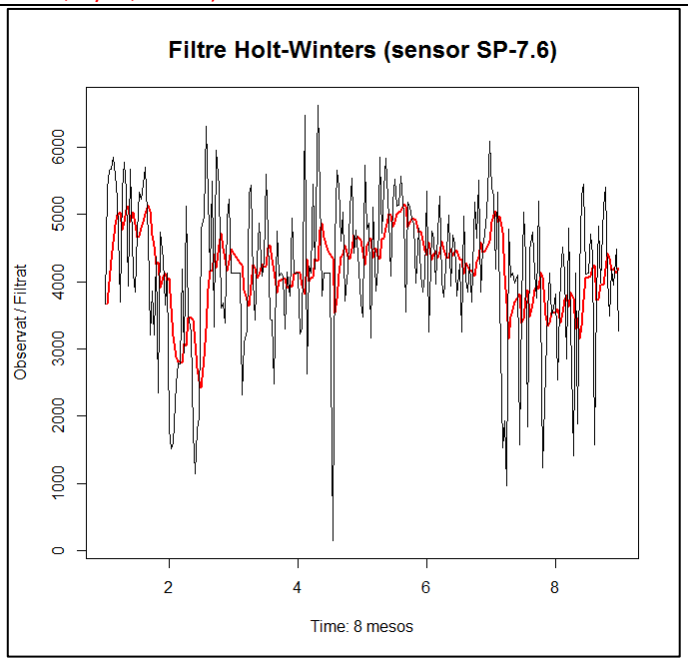


```
> diari76tsforecast2<-forecast.HoltWinters(diari76tsforecast, h=30)
> diari76tsforecast2
         Point Forecast     Lo 80     Hi 80     Lo 95     Hi 95
9.000000       4019.692 2636.832 5402.552 1904.7900 6134.594
9.033333       4019.692 2610.577 5428.807 1864.6368 6174.748
9.066667       4019.692 2584.803 5454.582 1825.2181 6214.166
9.100000       4019.692 2559.483 5479.901 1786.4950 6252.889
9.133333       4019.692 2534.595 5504.789 1748.4321 6290.952
9.166667       4019.692 2510.117 5529.267 1710.9966 6328.388
9.200000       4019.692 2486.030 5553.354 1674.1585 6365.226
9.233333       4019.692 2462.316 5577.069 1637.8902 6401.494
9.266667       4019.692 2438.957 5600.428 1602.1658 6437.219
9.300000       4019.692 2415.938 5623.446 1566.9618 6472.423
9.333333       4019.692 2393.245 5646.139 1532.2559 6507.128
9.366667       4019.692 2370.864 5668.520 1498.0276 6541.357
9.400000       4019.692 2348.783 5690.601 1464.2578 6575.127
9.433333       4019.692 2326.991 5712.394 1430.9284 6608.456
9.466667       4019.692 2305.475 5733.910 1398.0227 6641.362
9.500000       4019.692 2284.226 5755.159 1365.5250 6673.859
9.533333       4019.692 2263.233 5776.151 1333.4204 6705.964
9.566667       4019.692 2242.489 5796.895 1301.6949 6737.689
9.600000       4019.692 2221.984 5817.400 1270.3355 6769.049
9.633333       4019.692 2201.711 5837.673 1239.3298 6800.055
9.666667       4019.692 2181.661 5857.723 1208.6661 6830.718
9.700000       4019.692 2161.827 5877.557 1178.3333 6861.051
9.733333       4019.692 2142.203 5897.181 1148.3209 6891.063
9.766667       4019.692 2122.782 5916.602 1118.6189 6920.765
9.800000       4019.692 2103.558 5935.826 1089.2180 6950.166
9.833333       4019.692 2084.525 5954.860 1060.1091 6979.275
9.866667       4019.692 2065.677 5973.707 1031.2838 7008.101
9.900000       4019.692 2047.009 5992.375 1002.7339 7036.650
9.933333       4019.692 2028.516 6010.868  974.4516 7064.933
9.966667       4019.692 2010.194 6029.191  946.4296 7092.955
```

```
> plot.forecast(diari76tsforecast2, xlab="Time: observat / previst", ylab="Valors", main="Predicció des de Holt-Winters (sensor SP-7.6)",cex.main=1.5, font.main=2, lty=1, lwd=1)
```

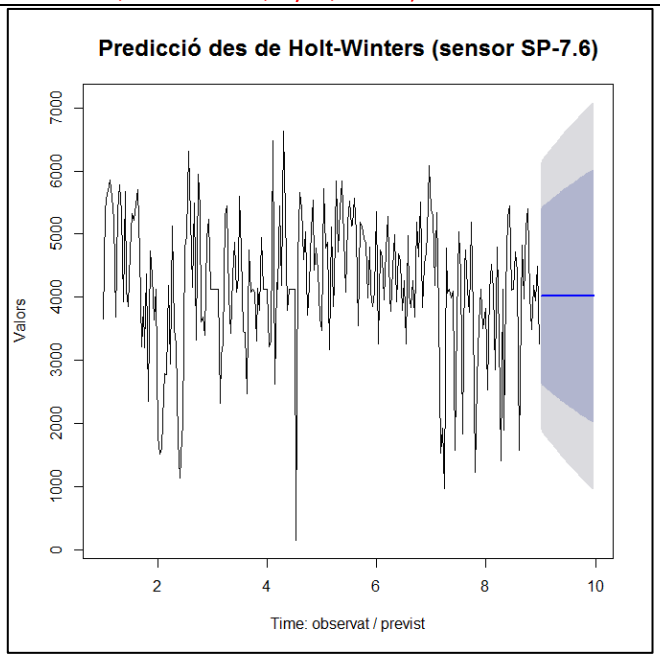


```
> acf(diari76tsforecast2$residuals, lag.max=30)
```

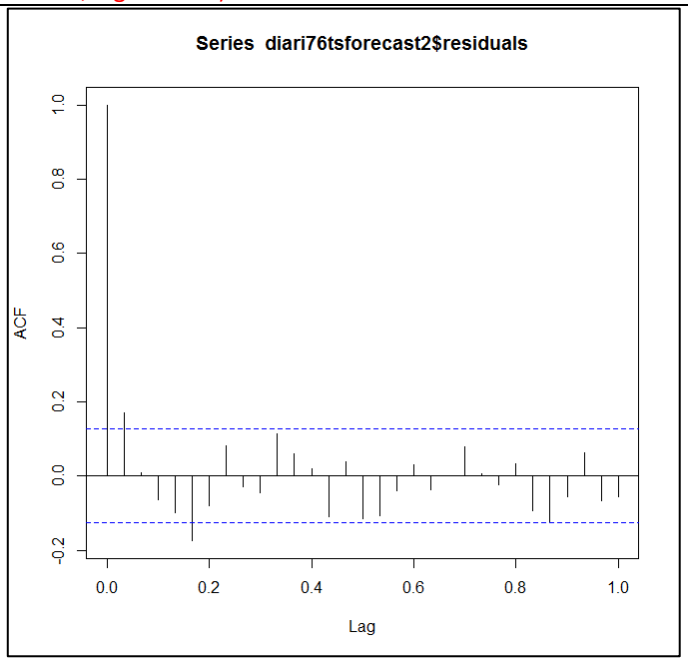


```
> Box.test(diari76tsforecast2$residuals, lag=30, type="Ljung-Box")
        Box-Ljung test
data:  diari76tsforecast2$residuals
X-squared = 49.439, df = 30, p-value = 0.01417
```

```
> plot.ts(diari76tsforecast2$residuals)
```

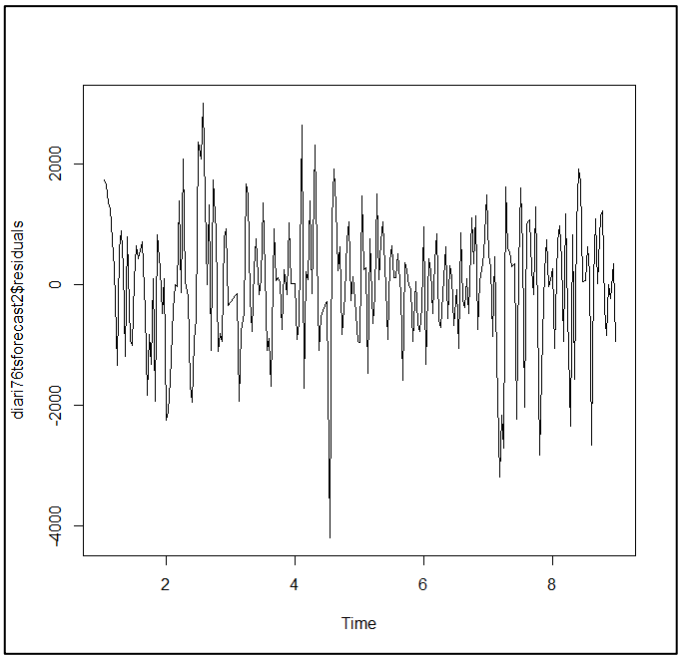


```
> plotForecastErrors(diari76tsforecast2$residuals)
```

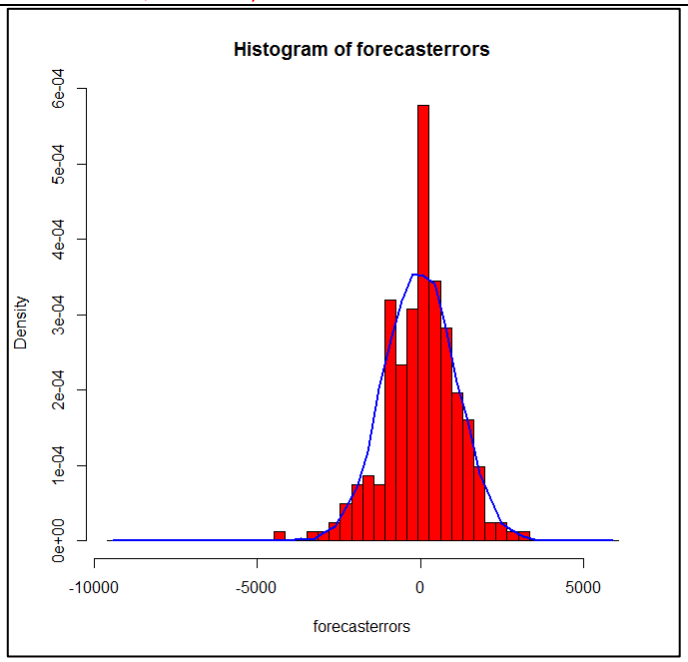

També amb totes aquestes proves:

- Test de Ljung-Box: no hi ha evidència d'autocorrelació de valors no nuls en els erros de pronòstic de la mostra.
- Distribució dels errors: sembla una distribució normal amb mitjana zero.

Podem deduir que les prediccions dels intervals del 80 % i del 95 % que hem vist provablement són vàlides.

5 RESULTATS

Abans de fer el càlcul de predicció farem la comparació visual dels 10 punts estudiats de les prediccions suavitzades, dintre del mateix ordre de valors observats, amb una mitjana mòbil d'ordre 10. Per poder comparar les 10 gràfiques forçarem l'eix d'ordenades de vehicles/dia a un valor màxim igual per a totes les gràfiques, en aquest cas 10000 vehicles/dia. Seguidament farem la predicció fora d'ordre i el seu càlcul aproximat.

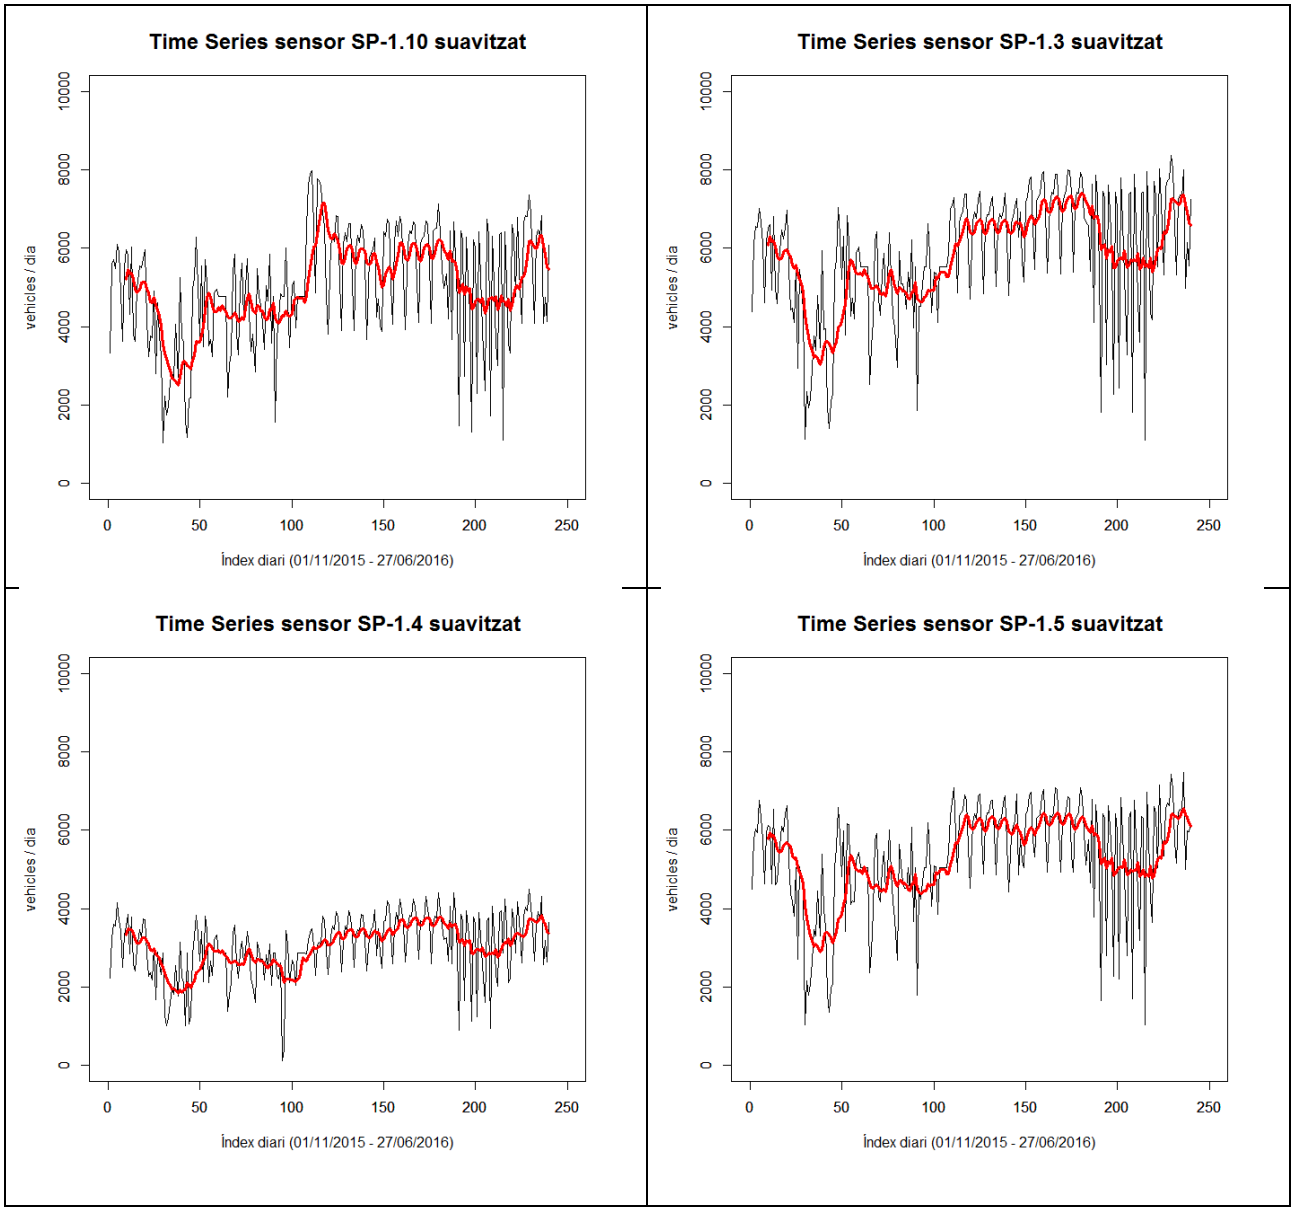

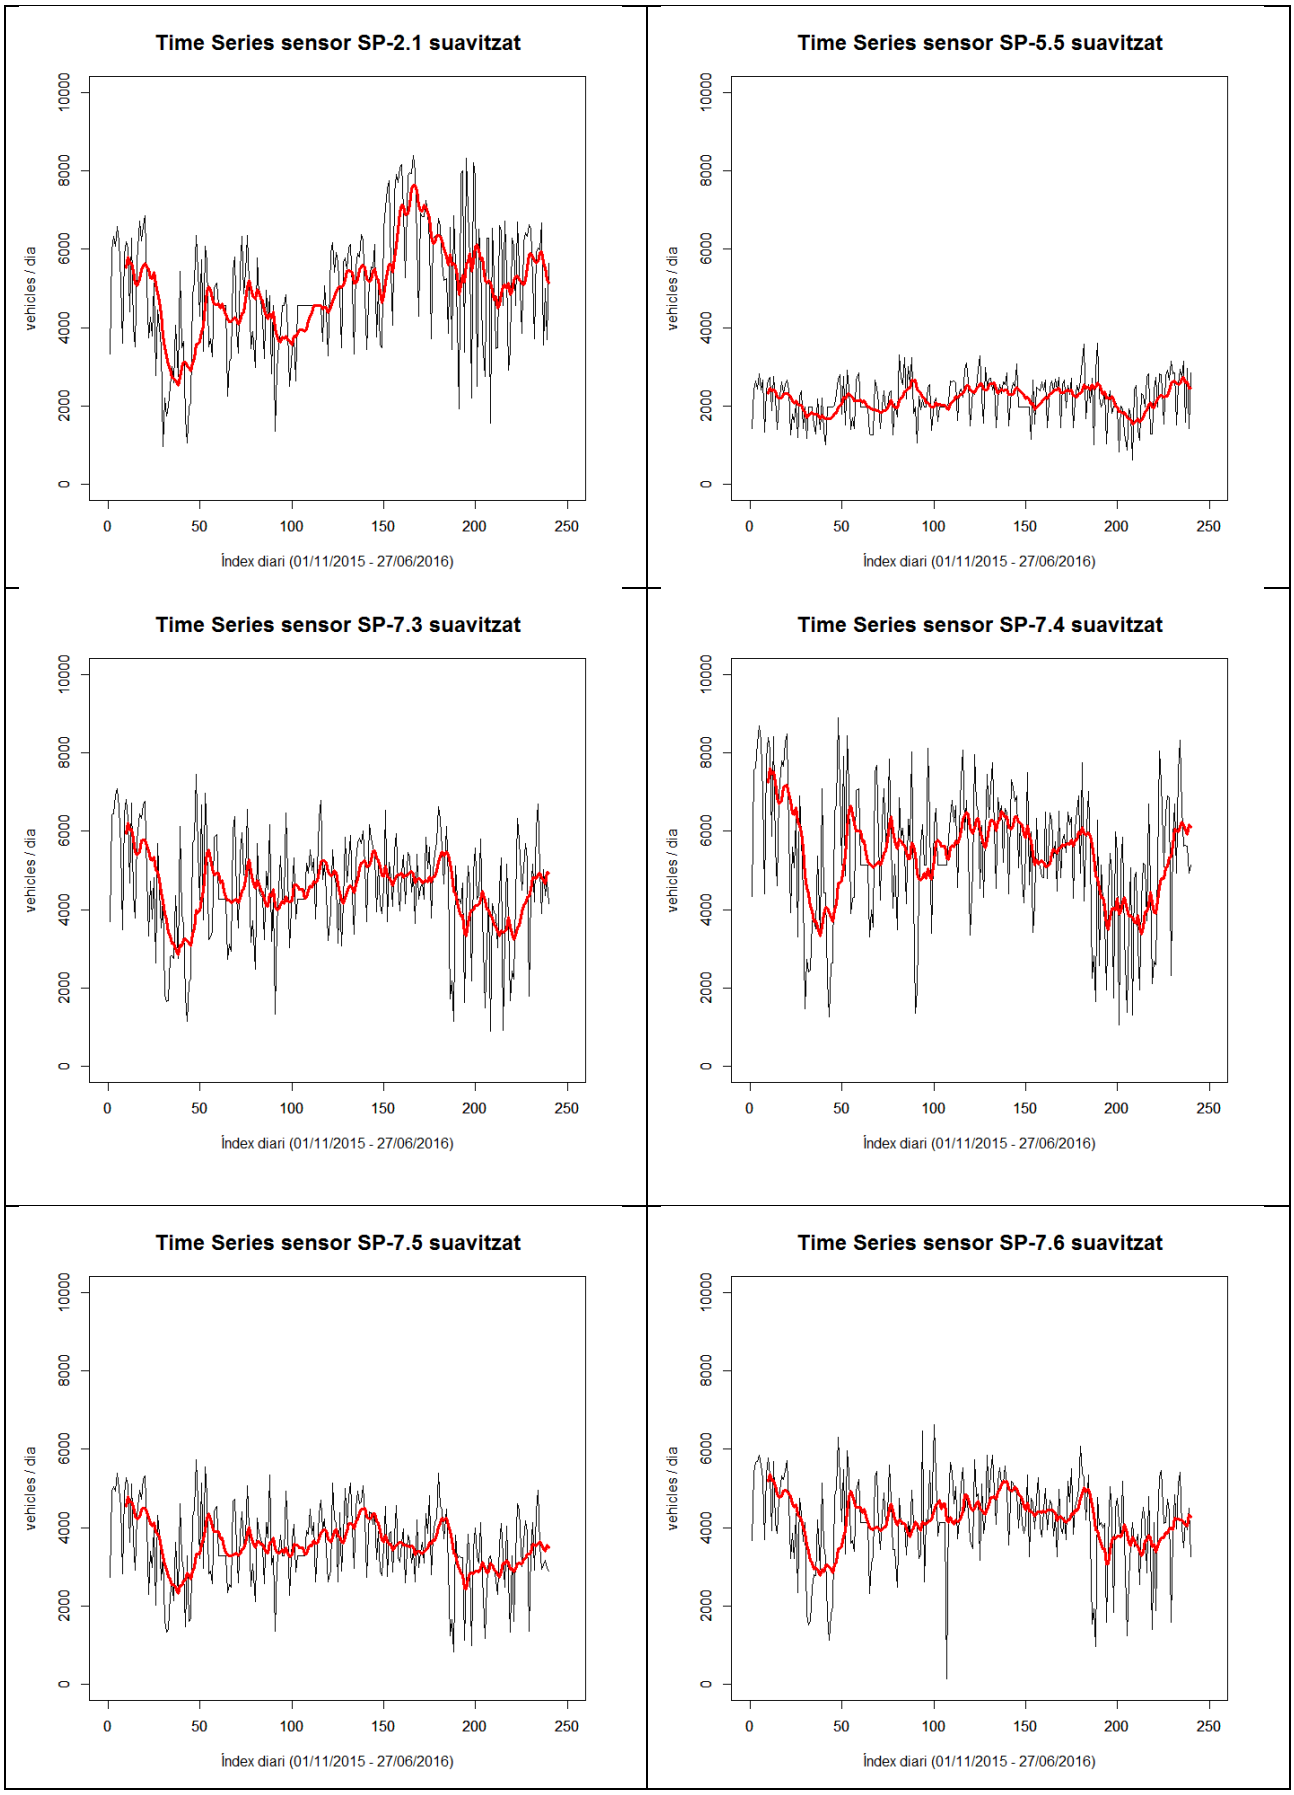
Time Series sensor SP-2.1 suavitzat
Time Series sensor SP-5.5 suavitzat
Time Series sensor SP-7.3 suavitzat
Time Series sensor SP-7.4 suavitzat
Time Series sensor SP-7.5 suavitzat
Time Series sensor SP-7.6 suavitzat
vehicles / dia
0
2000
4000
6000
8000
10000
0
50
100
150
200
250
Índex diari (01/11/2015 - 27/06/2016)

Fem servir les gràfiques de previsions de cada sensor amb el mètode "*STL + ETS(A,N,N)*[50]". Forçarem totes les gràfiques a una ordenada amb màxim de 10000 per tenir una millor visualització comparativa. Seguidament per cada punt o sensor farem un càlcul, aplicant el mètode de les **mitjanes mòbils de les sèries temporals**, dels valors previst pel període de 30 dies següents dels valors observats. Aquest càlcul es fa en un full de càlcul aplicant el següent procediment per cada sensor:

- Importar al full de càlcul el fitxer CSV amb els camps "Data" i "Valor" (240 registres). El valors són els acumulats diaris del volum de trànsit.
- Separar tots els registres en blocs de 30 i nomenar cada bloc "mes1", "mes2", "mes3"...
- Fer la suma de valors de cada bloc a partir de la meitat del primer bloc fins la meitat de l'últim bloc.
- Fer la mitjana mòbil de 30 dies amb aquests valors.
- Fer la mitjana mòbil centrada de 30 dies. Cada dos valors consecutius.
- Calcular el percentatge de cada valor real sobre la mitjana mòbil.
- Fer una transposició de dades en 30 columnes i 8 files (30 dies x 8 mesos).
- Fer la suma de cada columna restant el valor màxim i el valor mínim de la columna.
- Dividir cada suma per 5 (nou promig).
- Calcular el factor d'ajustament de totes les sumes.
- Ajustar cada nou promig amb el factor d'ajustament.
- Dividir per 100 cada valor i obtenir l'índex estacional, per cada dia del primer bloc.
- Replicar aquests índex en cada bloc.
- Calcular els valors desestacionalitzats per cada dia (dividir el valor observat per l'índex estacional)
- Numerar tots els valors de l'1 al 240.
- Dividir tots els valors en dos grans blocs i per cada bloc calcular la mitjana dels dos valors centrals.
- Dividir també tots els valors desestacionalitzats en dos grans blocs i calcular la mitjana de cada bloc.
- Calcular la línia de tendència amb el mètode de les semimitjanes $Y = a + bx$
- Aplicar el valor de l'eqüació de la recta a cada valor diari.
- Calcular el percentatge de tendència per cada valor desestacionalitzat.
- Calcular per cada percentatge el residu cíclic relatiu (restant 100).
- Calcular l'eqüació de la recta pels 30 valor següents als observats.
- Aplicar el factor d'ajustament a aquests valors i obtindrem la predicció (valor esperat).

Seguidament posarem al costat de cada gràfica de predicció els càlculs obtinguts de predicció amb el procediment descrit.

Cada taula d'aquestes dades enllaça amb el full de càlcul que conté tots els càlculs del procediment.

[50] Forecasting STL+ETS: aquest mètode produeix prediccions basades en dades històriques subministrades per l'usuari. STL és l'acrònim de "**S**easonal and **T**rend decomposition using **L**oess" desenvolupat per Cleveland et al. (1990) i ETS és l'acrònim de "**E**xponen**T**ial **S**mooting" basat en Error, Trend i Seasonal.

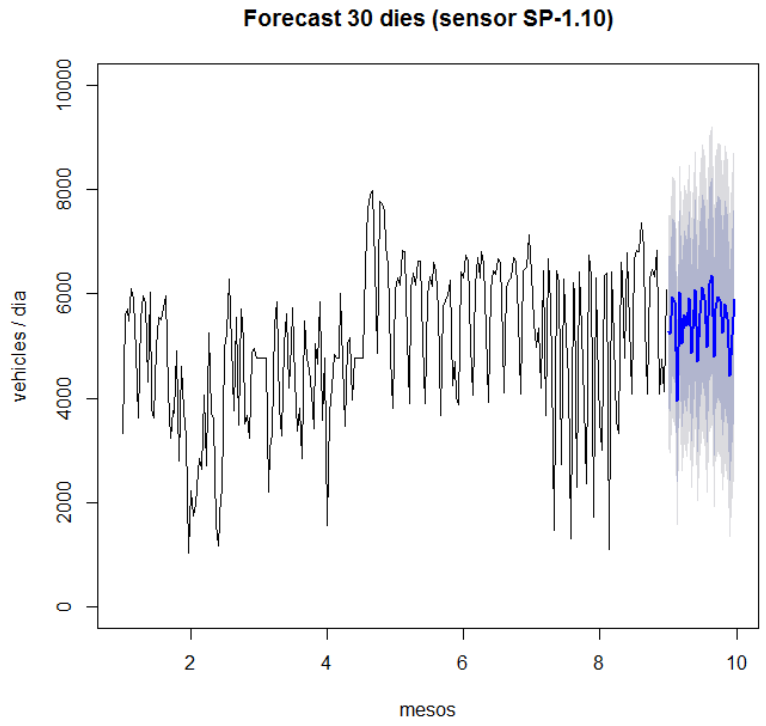

	Dia núm.	Valor esperat
28/06/2016	241	5391,23
29/06/2016	242	5387,00
30/06/2016	243	6064,32
01/07/2016	244	6117,78
02/07/2016	245	4600,02
03/07/2016	246	5865,87
04/07/2016	247	5755,50
05/07/2016	248	6102,23
06/07/2016	249	6500,72
07/07/2016	250	6179,85
08/07/2016	251	5810,80
09/07/2016	252	5558,27
10/07/2016	253	6429,86
11/07/2016	254	5004,56
12/07/2016	255	5948,00
13/07/2016	256	6906,22
14/07/2016	257	6503,19
15/07/2016	258	6332,85
16/07/2016	259	7207,40
17/07/2016	260	6851,18
18/07/2016	261	6530,57
19/07/2016	262	6311,80
20/07/2016	263	6461,93
21/07/2016	264	6493,16
22/07/2016	265	6064,62
23/07/2016	266	5860,86
24/07/2016	267	6622,06
25/07/2016	268	6272,69
26/07/2016	269	5913,34
27/07/2016	270	6122,09

URL càlculs: http://goo.gl/dhDLMa

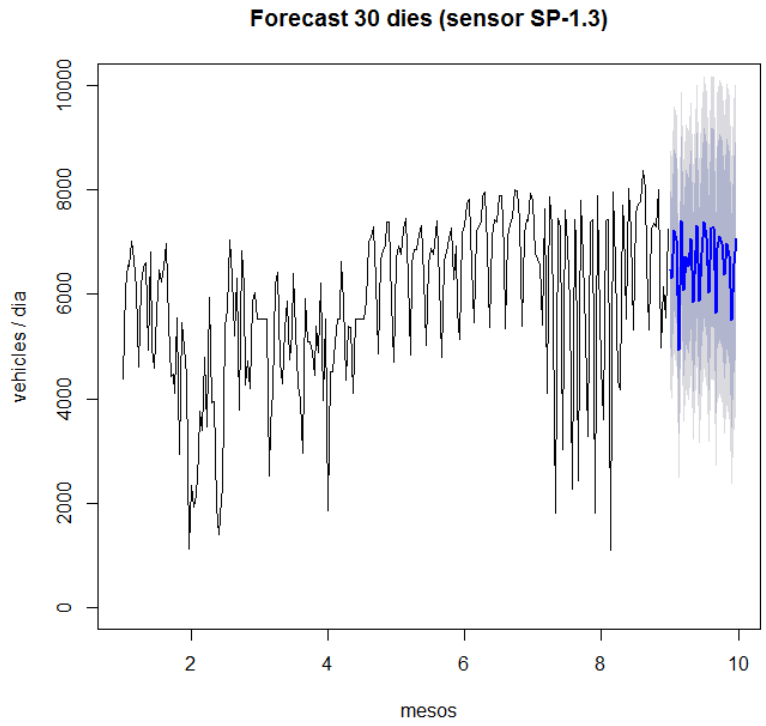

	Dia núm.	Valor esperat
28/06/2016	241	6551,06
29/06/2016	242	6547,91
30/06/2016	243	7373,42
01/07/2016	244	7440,67
02/07/2016	245	5596,39
03/07/2016	246	7138,56
04/07/2016	247	7006,33
05/07/2016	248	7430,63
06/07/2016	249	7918,22
07/07/2016	250	7529,62
08/07/2016	251	7082,05
09/07/2016	252	6776,27
10/07/2016	253	7841,15
11/07/2016	254	6104,79
12/07/2016	255	7257,76
13/07/2016	256	8429,43
14/07/2016	257	7939,81
15/07/2016	258	7734,08
16/07/2016	259	8804,68
17/07/2016	260	8371,92
18/07/2016	261	7982,42
19/07/2016	262	7717,23
20/07/2016	263	7903,04
21/07/2016	264	7943,49
22/07/2016	265	7421,33
23/07/2016	266	7174,02
24/07/2016	267	8108,05
25/07/2016	268	7682,43
26/07/2016	269	7244,35
27/07/2016	270	7502,19

URL càlculs: http://goo.gl/W2DmHE

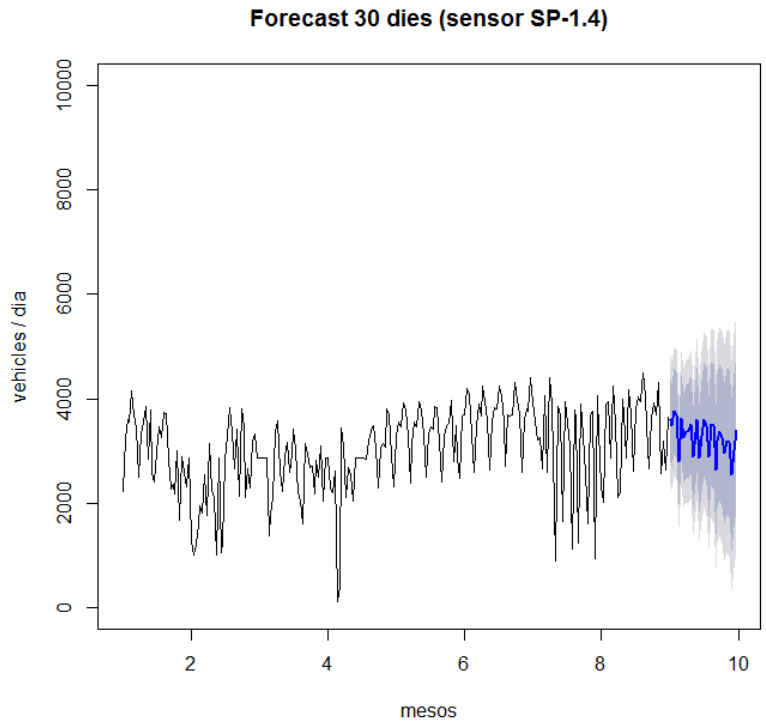

	Dia núm.	Valor esperat
28/06/2016	241	3368,10
29/06/2016	242	3366,15
30/06/2016	243	3790,15
01/07/2016	244	3824,34
02/07/2016	245	2876,15
03/07/2016	246	3668,35
04/07/2016	247	3600,05
05/07/2016	248	3817,70
06/07/2016	249	4067,82
07/07/2016	250	3867,81
08/07/2016	251	3637,56
09/07/2016	252	3480,16
10/07/2016	253	4026,68
11/07/2016	254	3134,71
12/07/2016	255	3726,39
13/07/2016	256	4327,55
14/07/2016	257	4075,81
15/07/2016	258	3969,82
16/07/2016	259	4518,93
17/07/2016	260	4296,42
18/07/2016	261	4096,15
19/07/2016	262	3959,70
20/07/2016	263	4054,66
21/07/2016	264	4075,04
22/07/2016	265	3806,82
23/07/2016	266	3679,62
24/07/2016	267	4158,32
25/07/2016	268	3939,68
26/07/2016	269	3714,69
27/07/2016	270	3846,55

URL càlculs: http://goo.gl/FIQm7j

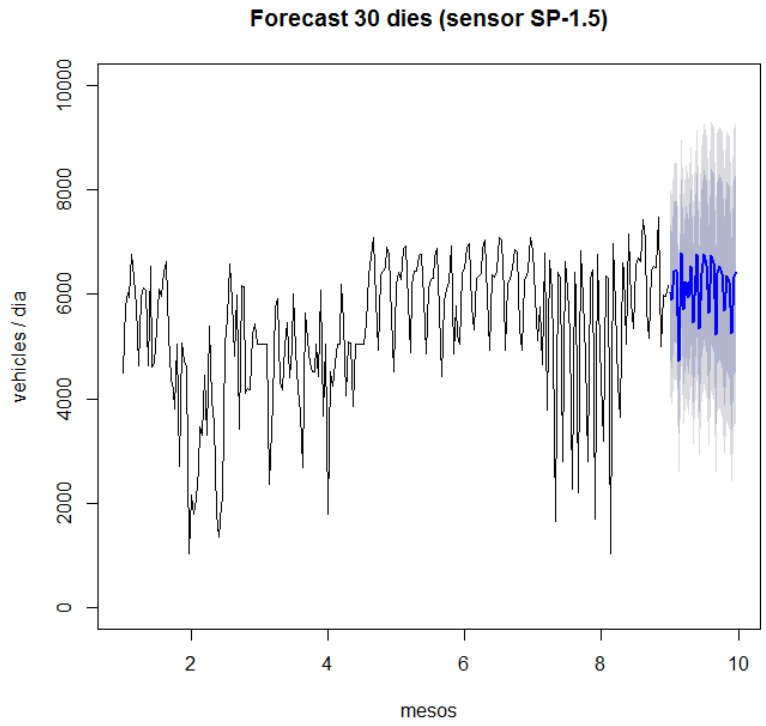

	Dia núm.	Valor esperat
28/06/2016	241	5735,97
29/06/2016	242	5731,59
30/06/2016	243	6452,36
01/07/2016	244	6509,38
02/07/2016	245	4894,56
03/07/2016	246	6241,58
04/07/2016	247	6124,26
05/07/2016	248	6493,33
06/07/2016	249	6917,50
07/07/2016	250	6576,19
08/07/2016	251	6183,59
09/07/2016	252	5914,98
10/07/2016	253	6842,63
11/07/2016	254	5325,93
12/07/2016	255	6330,08
13/07/2016	256	7349,99
14/07/2016	257	6921,20
15/07/2016	258	6740,04
16/07/2016	259	7670,97
17/07/2016	260	7291,98
18/07/2016	261	6950,86
19/07/2016	262	6718,15
20/07/2016	263	6878,07
21/07/2016	264	6911,44
22/07/2016	265	6455,41
23/07/2016	266	6238,64
24/07/2016	267	7049,04
25/07/2016	268	6677,27
26/07/2016	269	6294,86
27/07/2016	270	6517,20

URL càlculs: http://goo.gl/ZOscFV

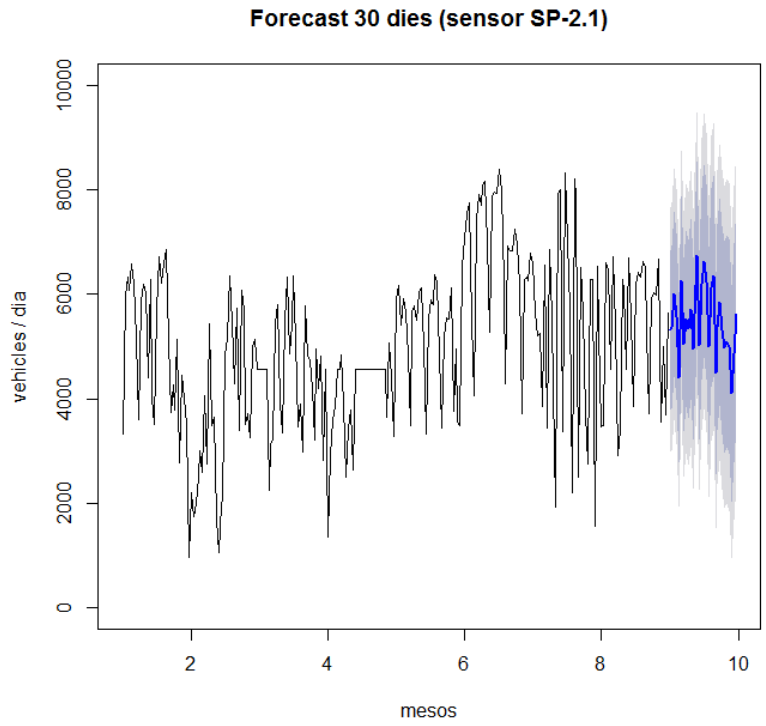

	Dia núm.	Valor esperat
28/06/2016	241	5752,47
29/06/2016	242	5750,54
30/06/2016	243	6476,48
01/07/2016	244	6536,49
02/07/2016	245	4917,05
03/07/2016	246	6272,92
04/07/2016	247	6157,61
05/07/2016	248	6531,44
06/07/2016	249	6961,02
07/07/2016	250	6620,34
08/07/2016	251	6227,71
09/07/2016	252	5959,66
10/07/2016	253	6897,18
11/07/2016	254	5370,61
12/07/2016	255	6385,82
13/07/2016	256	7417,76
14/07/2016	257	6987,88
15/07/2016	258	6807,75
16/07/2016	259	7751,20
17/07/2016	260	7371,23
18/07/2016	261	7029,26
19/07/2016	262	6796,66
20/07/2016	263	6961,25
21/07/2016	264	6997,84
22/07/2016	265	6538,72
23/07/2016	266	6321,68
24/07/2016	267	7145,70
25/07/2016	268	6771,51
26/07/2016	269	6386,23
27/07/2016	270	6614,40

URL càlculs: http://goo.gl/tzG8eY

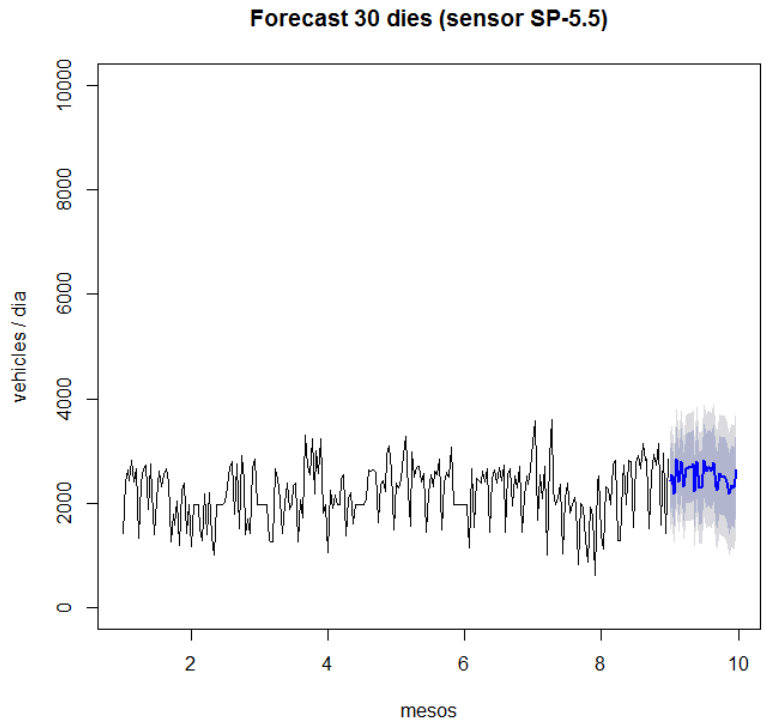

	Dia núm.	Valor esperat
28/06/2016	241	2115,63
29/06/2016	242	2112,31
30/06/2016	243	2376,04
01/07/2016	244	2395,11
02/07/2016	245	1799,50
03/07/2016	246	2292,90
04/07/2016	247	2248,00
05/07/2016	248	2381,58
06/07/2016	249	2535,13
07/07/2016	250	2408,14
08/07/2016	251	2262,58
09/07/2016	252	2162,58
10/07/2016	253	2499,77
11/07/2016	254	1944,15
12/07/2016	255	2308,89
13/07/2016	256	2678,79
14/07/2016	257	2520,54
15/07/2016	258	2452,65
16/07/2016	259	2789,23
17/07/2016	260	2649,36
18/07/2016	261	2523,46
19/07/2016	262	2437,09
20/07/2016	263	2493,17
21/07/2016	264	2503,33
22/07/2016	265	2336,35
23/07/2016	266	2256,16
24/07/2016	267	2547,28
25/07/2016	268	2411,08
26/07/2016	269	2271,26
27/07/2016	270	2349,68

URL càlculs: http://goo.gl/zrP2Os

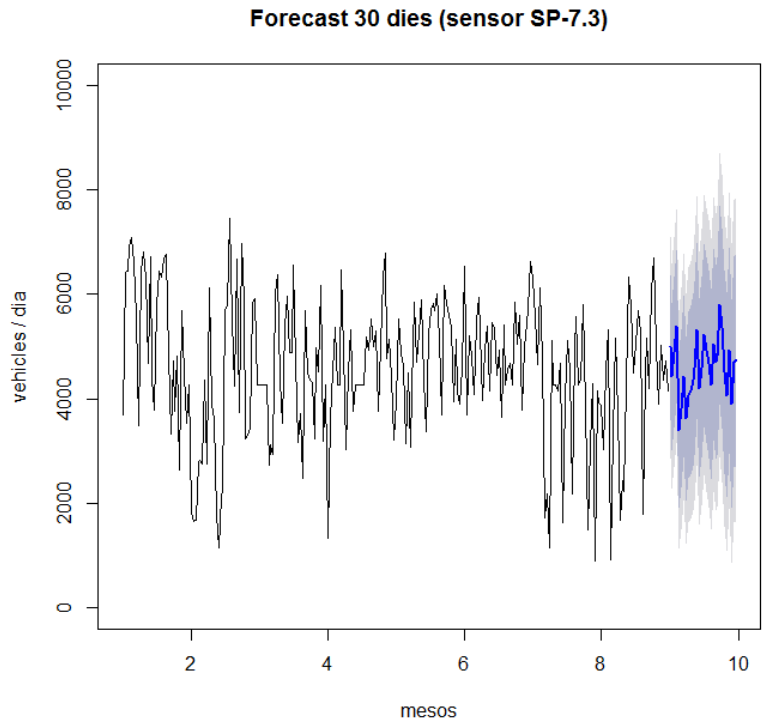

	Dia núm.	Valor esperat
28/06/2016	241	4041,54
29/06/2016	242	4032,42
30/06/2016	243	4532,74
01/07/2016	244	4565,98
02/07/2016	245	3428,16
03/07/2016	246	4365,12
04/07/2016	247	4276,71
05/07/2016	248	4527,72
06/07/2016	249	4816,34
07/07/2016	250	4571,93
08/07/2016	251	4292,64
09/07/2016	252	4100,11
10/07/2016	253	4736,14
11/07/2016	254	3680,93
12/07/2016	255	4368,50
13/07/2016	256	5064,91
14/07/2016	257	4762,43
15/07/2016	258	4630,98
16/07/2016	259	5262,90
17/07/2016	260	4995,57
18/07/2016	261	4754,94
19/07/2016	262	4589,04
20/07/2016	263	4691,44
21/07/2016	264	4707,35
22/07/2016	265	4390,36
23/07/2016	266	4236,78
24/07/2016	267	4780,20
25/07/2016	268	4521,54
26/07/2016	269	4256,43
27/07/2016	270	4400,41

URL càlculs: http://goo.gl/THc6Nq

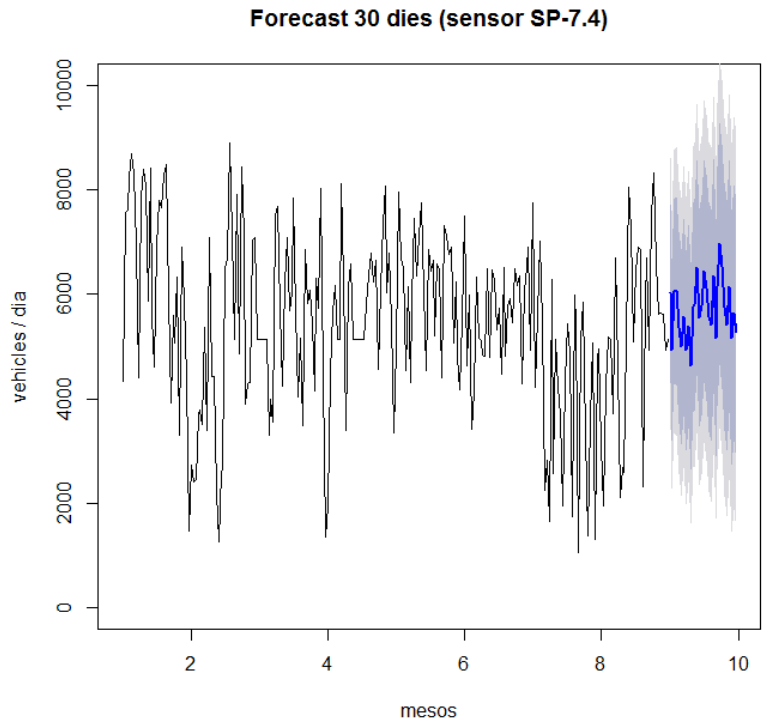

	Dia núm.	Valor esperat
28/06/2016	241	4654,42
29/06/2016	242	4642,45
30/06/2016	243	5216,81
01/07/2016	244	5253,39
02/07/2016	245	3943,03
03/07/2016	246	5019,11
04/07/2016	247	4915,90
05/07/2016	248	5202,76
06/07/2016	249	5532,66
07/07/2016	250	5250,23
08/07/2016	251	4927,93
09/07/2016	252	4705,41
10/07/2016	253	5433,61
11/07/2016	254	4221,65
12/07/2016	255	5008,63
13/07/2016	256	5805,23
14/07/2016	257	5456,80
15/07/2016	258	5304,49
16/07/2016	259	6026,39
17/07/2016	260	5718,44
18/07/2016	261	5441,24
19/07/2016	262	5249,72
20/07/2016	263	5365,14
21/07/2016	264	5381,61
22/07/2016	265	5017,61
23/07/2016	266	4840,53
24/07/2016	267	5459,64
25/07/2016	268	5162,55
26/07/2016	269	4858,29
27/07/2016	270	5021,01

URL càlculs: http://goo.gl/zEzkO7

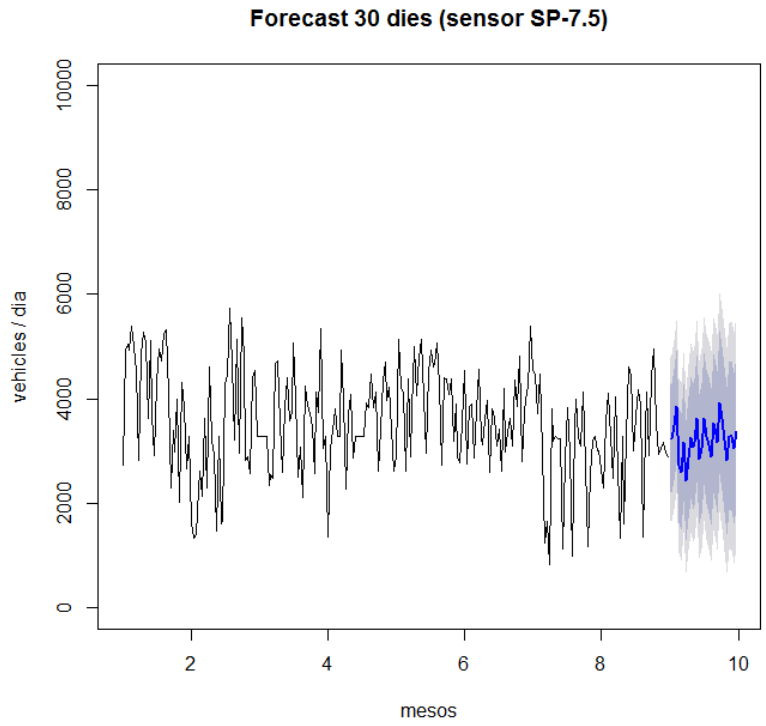

	Dia núm	Valor esperat
28/06/2016	241	3097,52
29/06/2016	242	3090,12
30/06/2016	243	3473,08
01/07/2016	244	3498,09
02/07/2016	245	2626,04
03/07/2016	246	3343,34
04/07/2016	247	3275,19
05/07/2016	248	3466,97
06/07/2016	249	3687,49
07/07/2016	250	3499,91
08/07/2016	251	3285,67
09/07/2016	252	3137,89
10/07/2016	253	3624,19
11/07/2016	254	2816,35
12/07/2016	255	3341,98
13/07/2016	256	3874,24
14/07/2016	257	3642,39
15/07/2016	258	3541,39
16/07/2016	259	4024,11
17/07/2016	260	3819,20
18/07/2016	261	3634,75
19/07/2016	262	3507,48
20/07/2016	263	3585,27
21/07/2016	264	3596,95
22/07/2016	265	3354,30
23/07/2016	266	3236,54
24/07/2016	267	3651,18
25/07/2016	268	3453,15
26/07/2016	269	3250,26
27/07/2016	270	3359,76

URL càlculs: http://goo.gl/fQEQpy

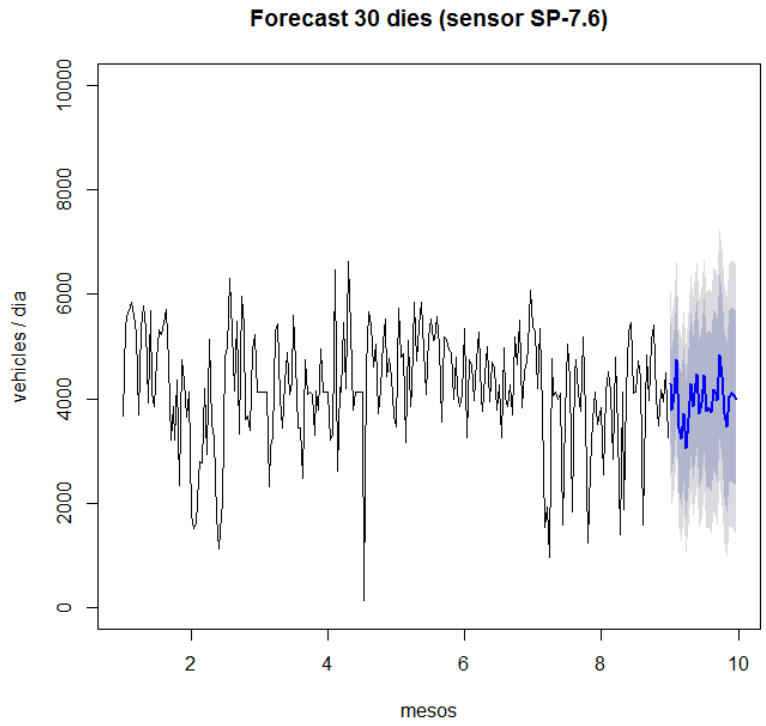

	Dia núm.	Valor esperat
28/06/2016	241	3817,75
29/06/2016	242	3809,87
30/06/2016	243	4283,41
01/07/2016	244	4315,64
02/07/2016	245	3240,83
03/07/2016	246	4127,38
04/07/2016	247	4044,56
05/07/2016	248	4282,77
06/07/2016	249	4556,65
07/07/2016	250	4326,25
08/07/2016	251	4062,75
09/07/2016	252	3881,27
10/07/2016	253	4484,22
11/07/2016	254	3485,81
12/07/2016	255	4137,72
13/07/2016	256	4798,26
14/07/2016	257	4512,58
15/07/2016	258	4388,87
16/07/2016	259	4988,71
17/07/2016	260	4736,21
18/07/2016	261	4508,94
19/07/2016	262	4352,46
20/07/2016	263	4450,44
21/07/2016	264	4466,38
22/07/2016	265	4166,42
23/07/2016	266	4021,45
24/07/2016	267	4538,12
25/07/2016	268	4293,38
26/07/2016	269	4042,43
27/07/2016	270	4179,97

URL càlculs: http://goo.gl/TMhxtt

6 CONCLUSIONS

El conjunt tecnològic implementat a la ciutat, les ombres de comunicacions i el nivell de manteniment correctiu estan lluny de la perfecció desitjable per a l'alta disponibilitat 24x7 i això implica mancances temporals de dades que s'han de suplir amb metodologies estadístiques i de mineria de dades adients. Pensem en dues tecnologies, també basades en xarxes, que al llarg de la història s'han anat perfeccionant, la distribució d'electricitat i les comunicacions d'internet, que han arribat quasi al 100 % lliure d'errors. Estem segurs que la captació de dades dels sensors de trànsit també arribarà a aquest punt lliure d'errors.

Actualment hi ha molts sistemes i tecnologies de captació de dades de trànsit però no podem dir quin sistema és millor ja que cadascun té les seves avantatges i els seus inconvenients. El sistema que es fa servir en aquest cas d'estudi és d'aplicació "in situ" però té l'avantatge de la seva simplicitat i manteniment mínim i això permet la seva implantació en un àrea urbana amplia que ens donarà més dades que altres sistemes. Es pot complementar amb la generalització de sensors de pàrquing o amb la implantació de les modernes tecnologies de càmeres.

Les dades d'aquest cas d'estudi compleixen la condició de sèries temporals i és per això que s'han fet servir metodologies basades en aquesta condició. S'han implementat mètodes de pronòstic (forecast) STL+ETS i càlculs de mitjanes mòbils que ens dona valors dintre del marge d'error previst i ens dona una **informació que és factible d'utilitzar pels serveis tècnics de l'ajuntament, per la Guàrdia Urbana o Policia Local i pels polítics en la seva presa de decisions**. Per poder arribar a aquest punt s'hauria de fer l'anàlisi de tots els punts (sensors) claus i trobar uns patrons d'interrelació entre ells.

Exemple de presa de decisions:

- Cas a: Un carrer suporta més trànsit del desitjat, aleshores s'han de trobar alternatives de desviament.
- Cas b: Un carrer suporta molt poc trànsit, aleshores es pot decidir la conversió total o parcial en prioritari per al vianant o en afegir un carril bici.

També la informació donada per l'anàlisi de les dades en permetrà arribar al requisit de ciutat més sostenible de la següent manera:

- Millorar la capacitat real de les infraestructures existents
- Millorar el flux del tràfic
- Augment de la seguretat dels conductors (mobilitat i comoditat)
- Estalvi de temps i reducció de la congestió de tràfic
- Reducció emissions CO_2
- Informació en temps real i ajuda a la presa de decisions.
- Informació ciutadana

Per poder arribar a l'aprofitament final de tota la informació per part del ciutadà es necessari crear i implantar interfícies que en un temps mínim doni una informació útil, per exemple amb panells informatius, amb aplicacions de mòbil o amb informació directa a les pantalles del vehicle.

Conseqüència de tots aquests estudis pot ser per exemple la creació de "cultura ciclista". A l'últim informe de l'observatori de mobilitat[51], de l'any 2014, s'observa que amb el pas del temps la implantació de la bicicleta com a sistema de transport públic és una realitat en augment i que això genera una major inversió en

[51] http://www.observatoriomovilidad.es/images/stories/05_informes/informe_OMM2014.pdf

bicicletes privades. Aquest informe disposa de les següents dades d'oferta i demanda d'aquest tipus de servei:

Tabla 29 - Oferta pública de bicicletas en la ciudad capital. Año 2014

	Puntos de préstamo	Número total de anclajes	Bicicletas disponibles	Ratio superficie servicio / superficie ciudad capital (%)	Horario de servicio (horas)
Madrid[1] (BiciMAD)	123	3.069	1.560	3,8	24
Barcelona[2] (Bicing)	421	15.000	6.000	73,9	18-24
Valencia (Valensbisi)	276	5.496	3.100	100,0	24
Sevilla (Sevici)	259	5.163	2.600	100,0	24
Sevilla (bus+bici)	1	172	172	100,0	16,5
Málaga (Málagabici)	23	600	400	n.d.	17
Palma de Mallorca[3] (BICIPALMA)	32	560	300	2,3	18
Palma de Mallorca[4] (Mou-te Bé)	1	50	50	2,3	14
Cádiz (+BICI)	1	-	15	98,6	14,25
Zaragoza[5] (BIZI)	130	2781	1.420	n.d.	16-19
San Sebastián[6]	12	180	100	100	17
Pamplona[7]	5	120	85	99,6	10-12'5
Algeciras (Bus+bici)	1	6	6	100	18
A Coruña[8] (Bicicoruña)	21	296	200	97	13'5-15
León (León te presta la bici)	20	200	100	25,6	15

1: Servicio desde el 23 de junio de 2014.
2: Horario de servicio: días laborables 18 horas, festivos 24 horas.
3: Horario de servicio: días laborables 18 horas, festivos 17 horas.
4: Horario de lunes a viernes: 7-21h, sábados y domingos 9-19h.
5: Horario de servicio: lunes a jueves 18h/día, viernes 19h/día, sábados 17h/día, domingos 16h/día.
6: Horario de servicio: invierno 16,5 horas, verano 17,5 horas.
7: Horario de servicio: invierno 10 horas, verano 12,5 horas.
8: Horario de servicio: invierno 13,5 horas, verano 15 horas.
Fuente: ATP

Tabla 30 - Demanda del servicio público de bicicletas en la ciudad capital. Año 2014

	Usuarios inscritos	Préstamos (año)	Viajeros-km (año)	Rotación bicicletas (día)*
Madrid (BiciMAD)	29.270	726.662	n.d.	11,0
Barcelona (Bicing)	96.250	12.349.000	34.577.200	5,7
Valencia (Valensbisi)	63.643	63.849	192.371	6,4
Sevilla (Sevici)	38.706	3.740.000	n.d.	4,2
Sevilla (bus+bici)	7.470	35.650	216.395	0,8
Bilbao (BIZIMETA)	4.000	n.d.	n.d.	n.d.
Málaga [1](Málagabici)	23.217	n.d.	n.d.	n.d.
Palma de Mallorca (BICIPALMA)	1.785	210.573	n.d.	2,7
Palma de Mallorca (Mou-te Bé)	337	7.500	n.d.	n.d.
Cádiz (+BICI)	n.d.	784	n.d.	n.d.
Zaragoza (BIZI)	33.628	2.867.380	6.451.605	6,4
San Sebastián	1.908	n.d.	n.d.	n.d.
Pamplona	4.177	11.190	27.975	0,5
Algeciras (Bus-bici)	-	150	n.d.	n.d.
A Coruña (Bicicoruña)	2.996	179.127	447.817	2,5
León (León te presta la bici)	10.888	36.023	n.d.	n.d.

**Media anual teniendo en cuenta el nº de usos y las bicicletas disponibles*
1: Tarjetas de Transporte del Consorcio activadas para el servicio Malagabici desde marzo a diciembre de 2014
Fuente: ATP

Font: Observatorio de la Movilidad Metropolitana

Segons dades del Baròmetre de Bicicleta 2015, a Catalunya són usuàries de la bicicleta més de 2,5 milions de persones, de les quals prop de 500000 ho fan de manera diària. Un 56,8% de la població té una bicicleta per a ús personal i el 40,8% en són usuàries amb alguna freqüència.

Aprofitant la inversió de 4 MEUR que el Departament de Territori i Sostenibilitat de Catalunya destinarà fins al 2018 a construir nous carril bici arreu de Catalunya i que una de les actuacions és la construcció de la Via verda entorn de la carretera C-31 entre els termes de Vilamalla i Figueres[52], des del PK 0+770 de la GIV-6228 fins al PK 1+250 de la GIV-6211, l'ajuntament de Figueres hauria d'aprofitar per estudiar i projectar diverses vies de l'entorn urbà que permetrà la reducció de vehicles motoritzats i pacificació progressiva de diverses zones.

Per últim, seguim la línia d'aquest estudi, s'haurien de potenciar nous estudis en aquest sentit i més amplis que abastin tota la zona urbana per arribar a l'objectiu últim d'elaborar un **projecte actualitzat de mobilitat** per a una ciutat més sostenible.

[52] http://upcommons.upc.edu/handle/2117/79155

7 REFERÈNCIES

Achaerrandio, R. et al. (2012) Análisis de las Ciudades Inteligentes de España 2012. El viaje a la Ciudad inteligente. IDC. Edición: IDC. Madrid. Recuperat de: http://www.socinfo.es/contenido/seminarios/1404smartcities6/02-IDC_Smart_City_Analysis_Spain_2012.pdf (juny de 2016)

Aggarwal, Charu C. (2015), *Data Mining. The TextBook*. Springer International Publishing. Switzerland

Al-Khateeb, K., & A. Y. Johari, J. (2005). *Intelligent Dynamic Traffic Light Sequence Using RFID. Electrical and Computer Engineering, 1367-1372*.

Brath, R. and Jonker, D. (2015). *Graph Analysis and Visualization. Discovering Business Opportunity in Linked Data.* John Wiley & Sons, Inc., Indianapolis.

Caballero, R. i Martín, E. (2015). *Las bases de Big Data.* Los Libros de La Catarata, Madrid.

Cebrián, I. et al. (2012). *Libro Blanco Smart Cities*. Recuperat de: http://www.innopro.es/pdfs/libro_blanco_smart_cities.pdf (juny de 2016)

Cichosz, Pawel (2015). *Data Mining Algorithms: Explained Using R*. John Wiley & Sons Ltd. Chichester. Regne Unit.

Clark, G. and Moonen, T. (2015). *The Density Dividend: solutions for growing and shrinking cities*. Urban Land Institute, London. Recuperat de: http://europe.uli.org/wp-content/uploads/sites/3/ULI-Documents/ULI-TH-Density-Dividend-Report.pdf (juny de 2016)

Cleveland et al. (1990). *STL: A Seasonal-Trend Decomposition Procedure Based on Loess*. Recuperat de: http://cs.wellesley.edu/~cs315/Papers/stl%20statistical%20model.pdf (agost de 2016)

Guisande, C. i Vaamonde, A. (2012). *Gráficos estadísticos y mapas con R.* Ediciones Díaz de Santos. Madrid.

Gutiérrez, A. et al. (2014). *Smart City. Hacia la gestión inteligente*. Marcombo Edicions, Barcelona.

Han, J., Kamber, M., Pei, J. (2012). *Data Mining. Concepts and Techniques.* Morgan Kaufmann Publishers. San Francisco, California. Recuperat de: http://www.cse.hcmut.edu.vn/~chauvtn/data_mining/Texts/[1]%20Data%20Mining%20-%20Concepts%20and%20Techniques%20(3rd%20Ed).pdf (juliol de 2016)

Holgado, Emma (2012). *Estudio de regulación del tránsito de vehículos y peatones en los alrededores de la Avenida de Portugal de Salamanca*. Recuperat de https://upcommons.upc.edu/bitstream/handle/2099.1/16776/EstudioDeRegulacionDelTransito_EmmaHolgado.pdf UPCommons. Barcelona.

Hyndman, R.J., Koehler, A.B., Ord, J.K., Snyder, R.D., (2008). *Forecasting with Exponential Smoothing: The State Space Approach. Springer Series in Statistics, Springer.* Recuperat de: http://www.exponentialsmoothing.net (juliol de 2016)

Hyndman, R.J., (2014). *Forecast: Forecasting functions for time series and linear models.* Recuperat de: http://CRAN.R-project.org/package=forecast . R package version 7.1 with contributions from George Athanasopoulos, Christoph Bergmeir, Yousaf Khan, Slava Razbash, Drew Schmidt, Earo Wang and Zhenyu Zhou. (juliol de 2016)

Hyndman, R.J. *Time Series Data Library*, Recuperat de http://data.is/TSDLdemo (juliol de 2016).

Hyndman, R.J. (2016), *CRAN Task View: Time Series Analysis*. Recuperat de: https://cran.r-project.org/web/views/TimeSeries.html (agost de 2016)

IDAE (2012). *Mapa Tecnológico "Ciudades Inteligentes"*. Observatorio Tecnológico de la Energía (IDAE). Edición: IDAE, Madrid.

Kachroo, P. & Sastry, S. (2014). *Traffic Flow Theory. Mathematical Framework*. University of California Berkeley. Recuperat de http://faculty.unlv.edu/pushkin/TrafficFlowTheory.pdf (juliol de 2016)

Kikstarting R. Recuperat de https://cran.r-project.org/doc/contrib/Lemon-kickstart/ (juny de 2016)

Klein, L.A. et al (2006). *Traffic Detector Handbook. Third Edition Volume II, Publication No.FHWA-HRT-06-139 October 2006., 2006.* Recuperat de https://www.fhwa.dot.gov/publications/research/operations/its/06139/06139.pdf (agost de 2016)

Kulkarni, G.H., & Waingankar, P.G. (2007). *Fuzzy Logic Based Traffic Light Controller*. Second International Conference on Industrial and Information Systems, ICIIS 2007, (pàgs. 107- 110). Sri Lanka

Lefebvre, H. (1969); *El derecho a la ciudad*, Ediciones Península, Barcelona

López, L.M. et al. (2015). *Estudio y Guía metodológica sobre Ciudades Inteligentes*. https://www2.deloitte.com/content/dam/Deloitte/es/Documents/sector-publico/Deloitt_ES_Sector_Publico_Estudio-sobre-ciudades-inteligentes.pdfa ONTSI, Madrid.

Matheu, T. (2012). *Course: Traffic Engineering & Management*. IIT Bombay. Recuperat de: http://nptel.ac.in/courses/105101008/ (juliol de 2016)

Mauricio, J.A. (2007). *Introducción al anàlisis de series temporales*. Recuperat de: https://www.ucm.es/data/cont/docs/518-2013-11-11-JAM-IAST-Libro.pdf (juliol de 2016)

Monzón, A. et al. (2016). Informe del Observatorio de la movilidad metropolitana. Recuperat de: http://www.observatoriomovilidad.es/images/stories/05_informes/informe_OMM2014.pdf (agost de 2016)

Mumford, L (2014). *La ciudad en la historia*, Logroño: Pepitas de calabaza

Navarro, F. i Piattini, M. (2013). *iPavement. El Pavimento Inteligente*. StarBook Editorial y Publicaciones. Paracuellos de Jarama, Madrid.

Olaya, V. (2016). Sistemas de Información Geográfica. Recuperat de: https://volaya.github.io/libro-sig/ (juny de 2016).

Peña, D. (2005). *Análisis de series temporales*. Alianza Editorial. Madrid.

Peña, D., Tiao, G.C. & Tsay, R.S. (2005). *A Course in Time Series Analysis*. Editorial John Wiley. New Jersey

Pérez López, César (2015). *R. Lenguaje de programación y anàlisis estadístico de datos*. Ibergarceta Publicaciones S.L. Madrid.

Pérez, M. (2014). *Minería de datos a través de ejemplos*. RC Libros. San Fernando de Henares, Madrid.

Prothmann, Holger (2011). *Organic traffic control.* KIT Scientific Publishing. Karlsruhe

Russell, S. i Norving, P. (2011). *Artificial intelligence: a modern approach*, (ed. Digital: http://stpk.cs.rtu.lv/sites/all/files/stpk/materiali/MI/Artificial%20Intelligence%20A%20Modern%20Approach.pdf)

Sáinz, R.M. (coordinación) (2011). *Smart Cities: un primer paso hacia la internet de las cosas.* Fundación Telefónica. Edición: Fundación Telefónica y Editorial Ariel, Madrid. Recuperat de: http://www.fundaciontelefonica.com/arte_cultura/publicaciones-listado/pagina-item-publicaciones/itempubli/101/ (juny de 2016)

Smart Cities, Ranking of European medium-sized cities. Final report. Vienna University of Technology, Delft University of Technology, University of Ljubljana. Edició: Centre of Regional Science, Vienna UT, 2007 Recuperat de: http://www.smart-cities.eu/download/smart_cities_final_report.pdf (juny de 2016)

Tascón, M. i Coullaut, A. (2016). *Big Data y el Internet de las cosas*. Los Libros de La Catarata, Madrid.

Wageningen-Kessels, Femke van et al. (2014). Genealogy of traffic flow models. Springer International Publishing AG. Cham, Suïssa. Recuperat de http://ta.twi.tudelft.nl/nw/users/vuik/papers/Wag14LVH.pdf (juliol de 2016)