XVIII Conferencia de la Asociación Española para la Inteligencia Artificial (CAEPIA 2018)

CAEPIA 3: Navegación y Smart Cities





Analysis of Sensor Fusion Solutions for UAV Platfoms

Jesus Garcia
Universidad Carlos III
Applied Artificial Intelligence Group
Madrid, Spain
jgherrer@inf.uc3m.es

Jose M. Molina
Universidad Carlos III
Applied Artificial Intelligence Group
Madrid, Spain
molina@ia.uc3m.es

Abstract—Evaluation of Unmanned Aerial Vehicle (UAV) systems is mostly based on simulation tools that are manually configured to analyse the system output. In this work, the authors present an original method to evaluate the perfor-mance of UAV platform in real situations based on available data. The main innovation is an evaluation for designing sensor fusion parameters using real performance indicators of accuracy of navigation in UAVs based on PixHawk flight controller and peripherals. This platform allows physical integration of the main types of sensors in UAV domain, and at the same time the use of powerful simulation models developed with Gazebo. This methodology and selected performance indicators allows to select the best parameters for the fusion system of a determined configuration of sensors and a predefined real mission.

Keywords— UAVs sensor fusion, EKF, Real Data Analysis, System Design.

I. INTRODUCTION

Unmanned vehicles must be able to control their attitude and position by means of automatic control algorithms, they are controlled by a computer that integrates data from some electromechanical sensors and any local or global positioning system and applies any output control system to change its location using any locomotion system. The controller usually is an embedded microcontroller with appropriate interfaces to all vehicle components. As an example, PixHawk Px4 system integrates navigation data and software modules including fusion algorithms [1].

The main problem in navigation focuses on improving GPS with the ability to provide accurate navigation output when GPS data becomes unavailable due to unexpected outages or intentional problems (jamming or spoofing) in certain environments. Therefore, an approach based on the fusion of complementary sensors is essential, resorting to the fundamental equations of navigation and the characterization of the errors committed by each data source. This area has become popular due to the ubiquity of GPS and the availability of inertial sensors based on inexpensive MEMS components [2], [3], [4]. The integration of these complementary technologies allows compact and robust navigation solutions to determine attitude and location, so that the vehicle can determine its state in a robust way and use appropriate control techniques for autonomy. Other more drastic options for non-dependence on the GPS signal

involve the deployment of autonomous localization systems such as the recognition of the environment by artificial vision [5] or location by means of electromagnetic beacons [6], with the associated cost of developing a complementary infrastructure.

Complementary to navigation technologies, the use of lasers in combination with other range detection sensors (sonar, radar, video), allows to extend the navigation conditions and obstacle avoidance. In order to develop obstacle avoidance algorithms, it is interesting to include software simulation to carry out tests without incurring risks for people and devices. Gazebo is a powerful 3D simulation environment for autonomous vehicles that is particularly suitable for testing object-avoidance. Gazebo can be used with Software In Loop (SIL) and Hardware In Loop (HIL) design. However, the simulation software will be outside the scope of the document. In the air vehicles (UAVs), the integration requirements (consume, weight, dimensions) are much more restrictive but, even so, it is a line in continuous development [7],[8],[9].

Therefore, research of robust and general techniques to integrate complementary data sources has become essential for this type of systems. In addition to theoretical developments, it is of vital importance the availability of equipment and experimental environments to validate the robustness of the solutions working in real-world conditions. The integration of sensors has to be based on the definition of parameters of the tracking system that should be adjusted to improve performance in a predefined set of missions with a defined set of sensors. The methodology proposed in this paper assumes that real system adjustments will be based on a real platform with predefined flight missions so that, in this context, the best parameters could be obtained analyzing the real operation of sensors and real output. Simulation of UAV environments is a powerful tool but not enough to evaluate in a thorough way these systems in real conditions of real missions. Accordingly to [13], evaluation tasks should be aligned with the user needs and how the fusion system meets the specifications. The selection of parameters and quality metrics is a complex task, particularly in real applications, since there are not ground truth or a standard methodology for making the data fusion evaluation. There are numerous examples of output analysis of algorithms and configurations based on simulation, such as characerizing navigation errors [14], sensor fault detection [15], or sensor integration in maritime navigation domain [16]. Other works in



UAV navigation use experimental real data sets, usually in a single flight, in order to assess specific aspects such as robustness against GPS outages [17] or impact of outliers in different solutios [18].

This paper presents the selected platform, design tools and environment for real experimentation, the proposed methodology and a selection of available data sources and effects of data processing techniques on the quality of the navigation solution. The main contribution of this paper is the briefing of a methodology used for adapting filter parameters to real conditions, and further systematic analysis of available real data. Section II introduces the selected working platform, detailing the architecture of its software and the vehicles we have made to test its capacities and collect data. Section III presents the proposed methodology and evaluation metrics, section IV explains experimental environment and and analysis of the PixHawk Px4 system filter and fusion algorithms following the presented methodology. Finally, section V summarizes the conclusions derived from this work.

II. THE PIXHAWK AND PX4 UAV SYSTEM

A. Architecture

Unmanned vehicles must be able to control their attitude and position by means of automatic control algorithms. They are controlled by a computer that integrates data from some electromechanical sensors and any local or global positioning system, and applies any output control system to change its location using any locomotion system. This controller is usually an embedded microcontroller that performs the core of all vehicle components.

This research is based in the study of the PixHawk flight controller performance. An open-hardware computer designed by 3D Robotics specifically to create autopilot vehicles, that arises from the combination of PX4FMU and PX4IO boards. Both cards, from their version v2, are integrated in the same PCB (Printed Circuit Board) giving origin to PixHawk.

B. Sensors and data sources

The PixHawk board has several sensors integrated, shown in Table I, which serve as data sources to the PX4 stack and include some processing functions

TABLE I. SENSORS INTEGRATED IN THE PIXHAWK BOARD

Sensor	Туре	Axes	Scale	ADC accuracy	Data rate
L3GD20H	gyroscope	3	2000 dps	16 bits	760 Hz
LSM303D	accelerometer/ magnetometer	6	± 16g / ± 2gauss	16 bits	1600 Hz/ 100 Hz
MPU- 6000	accelerometer/ gyroscope	6	± 16g / 2000 dps	16 bits	1000 Hz/ 8000 Hz
MS5611	barometer	1	1200 mbar	24 bits	1000 Hz

¹ www.nuttx.org

These sensors allow enhancing navigation capabilities and increase the accuracy of the stabilization system measurements, what is quite important when we want to create an unmanned vehicle, because allows a more faithful image of the flying environment.

C. Software for Flight Control and Data Processing

PX4 is the control software of PixHawk processor. It is a real-time operating system based on NuttX¹ and consists of two main layers: PX4 Flight Stack and PX4 Middleware. PX4 Flight Stack is the complete collection of applications embedded in PixHawk hardware for drone control, while PX4 Middleware is the interface that allows the flow of data from sensors to applications through a publish/subscribe system called uORB. uORB allows to publish the data coming from the sensors and make them available to the applications of the Flight Stack, obtaining a reactive system and totally parallelized. The outstanding modules are flight controller and sensor data processing [19].

Regarding the data processing, Px4 implements an AHRS (attitude and heading reference system) that implements different algorithms to estimate the vehicle attitude and creates a direction vector that allows the unmanned displacement. In this section we will overview some basic algorithms that run into the system during the flights.

a) Direction Cosine Matrix (DCM)

This program allows the analysis of the triaxial accelerometers and gyroscopes data to obtain a Direction Cosine Matrix [20]. It makes possible the conversion of real-time measurements into instantaneous orientation parameters of the vehicle to deliver roll, pitch and yaw angles or variations:

b) Inertial Navigation System (INS)

This algorithm calculates the trajectories and corrections that allows the vehicle to move between single points using the DCM data. It is used to estimate the vehicle attitude with high frequency, so it is especially useful to complement the global position obtained from the GPS data.

c) Extended Kalman Filter (EKF)

All measurements are affected by noise that should be taken into account in the estimation of attitude and cinematic parameters. The Px4 system counts with several Extended Kalman Filter algorithms to process all sensor data in a compensation function that depends of the specific noise and accuracy characterization of each sensor, throwing high accuracy estimations of the vehicle attitude. The Px4 application counts with the possibility of applying different EKF solutions running in parallel, using different sensor measurements and states. With this implementation, it is possible to increase the accuracy and consistence of estimates even if the vehicle losses the GPS signal in certain time intervals. Table II shows the three different available EKF modes.

D. Possibility of SIL and HIL design.



Pixhawk supports SIL [29] and HIL [30] using Gazebo simulation This way, it is possible to debug navigation and object-avoidance algorithms in PixHawk fligh controller, without using any real device. In this way, you could save on material cost, as well as increase the quality of the final product.

TABLE II. PX4 EXTENDED KALMAN FILTERS

Name	Specification
EKF1	Only use the DCM for attitude control and the Inertial navigation
	for AHRS reckoning for position control
EKF2	Use the GPS for 3D velocity and position. The GPS altitude could
	be used if barometer data is very noisy.
EKF3	If there is no GPS, it can use optical flow to estimate 3D velocity
	and position.

In addition, Gazebo offers various models of real autonomous vehicles, saving modeling time. In case of not being offered by Gazebo, it will be necessary to use time and resources in a correct physical modeling, so that the conditions of simulation could be as close as possible to reality. It will be the task of the engineer to evaluate the interest in using software simulation. Furthermore, it is necessary to keep in mind the fact that Sotfware modeling and simulation is only of interest when it is carried out by an experienced engineer in the field. Otherwise, the behavior of the system would not be reproduced in a faithful manner.

Specifically, in the case of Pixhawk, a HIL configuration allows running the code written in the flight controller without using any real sensor. That fact allows a first contact in the study of the effect of the parameters of navigation and evasion algorithms.

III. EVALUATION OF UAV SENSOR FUSION IN REAL CONDITIONS

In many real problems, simulated environments are used to define UAV sensors and the system parameters to optimize the system performance [14],[15],[16],[21],[22]. Some problems appear with this kind of methodologies, basically how to represent in simulation all effects appearing in real conditions and the way to evaluate the parameters configuration. UAV simulation have been applied to design the control subsystem for predefined missions, but simulation of real sensors is a major problem in this kind of approach. Real UAV conditions are not easy to model in simulators. UAV are affected for atmospheric conditions and random movements of UAV platforms, so accurate simulation of input data is extremely complicated for designing system parameters. As mentioned before, it would be necessary to evaluate advantages and disvantages of using simulation environments.

In this scenario, the proposed methodology, depicted in Fig. 1, tries to test the system parameters under real conditions. The first step of this methodology is the definition of the UAV platform, the type, cinematic characteristics, set of sensors and the tracking algorithms. Once the UAV platform is defined, the methodology is composed by the following steps:

1.- Mission definition. Parameters are selected from a set of possible values for a specific mission, defined by means of several waypoints. These waypoints are used to repeat the same mission every time that a new evaluation is done.

- 2.- Each time a flight of the UAV passing through the predefined waypoints (mission) is carried out, the values of the sensor data are stored (position and velocity taken from GPS, inertial data, magnetometers, etc.)
- 3.- A set of flights, with the same waypoints defining the mission, are carried out and the corresponding sets of sensors data are stored together with system output, using several configurations of parameters for filtering. These values are postprocessed offline.
- 4.- The best configuration of parameters is selected, analyzing the performance metrics for the set of missions carried out over the same waypoints.
- 5.- The selected parameters are introduced in UAV system to perform real mission

The decision about "the best" parameters should be based in a set of indicators to evaluate the quality of the main components of the data fusion system. The validation and quality assessment of fusion system is a fundamental step in the development. However, as indicated in [23], the development of objective evaluation metrics with no available ground truth is a challenge yet for data fusion researchers. There are no well-established procedures to systematically evaluate sensor fusion systems beyond simulated conditions, making in many times difficult to predict performance in real-world conditions. After a revision of previous works, there are scarce global metrics without ground truth of fusion system, such as [24] where the metrics are fusion break rate, rate of fusion tracks and track recombination rate. This terminology considers "global" metrics as those assessing the global fusion system output, while "local" metrics evaluate specific outputs from individual sensor data processes in a decentralized fusion architecture. Some local metrics without ground truth are: rate of non-associated data, rate of premature deleted tracks and average residual [24], association performance metrics for track purity and track switches [25], or number of missed targets, track life time, rate of false alarms, rate of track fragmentation and track latency [26].

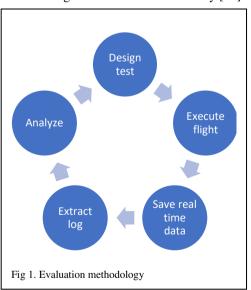




TABLE III. TEST PERFORMED OVER THE SAME CIRCUIT

Name	Specification
Static test without propellers	Accelerometers and gryroscopes, noise.
Static test on ifle	Accelerometers and gryroscopes, noise
Unmanned flight test	GPS, inertial navitation system
Unmanned hold test	GPS, Flow Sensor, DCM
Manual flight test	PID and configuration parameters

In navigation function, since data association is not a problem (all sensor data associate to the vehicle track), the sensor fusion performance is evaluated with the following global indicators:

- averaged innovations
- fusion break rate

These metrics allow the validation of the designed system and decision of appropriate configuration parameters in complex scenarios.

1) Averaged innovations

The innovation, or residual, is computed in the tracking filter each time an update is done for the prediction. For instance, for horizontal XY position, denoting with sub-index p the predicted track and sub-index m for measurement, and considering the average along a time window with $N_{\rm T}$ measurements, it is defined as:

$$r = \frac{1}{N_T} \sum_{i,k} (\hat{x}_{pi}[k] - x_{mi}[k])^2 + (\hat{y}_{pi}[k] - y_{mi}[k])^2$$
(1)

The normalized innovation also employs the covariance matrices considering both the predicted and observation uncertainties, matrix S. The averaged value of normalized innovations defined as:

$$r_{n} = \frac{1}{N_{T}} \sum_{i} \left[\hat{x}_{pi}[k] - x_{mi}[k] \quad \hat{y}_{pi}[k] - y_{mi}[k] \right] S_{i}[k]^{-1} \left[\hat{x}_{pi}[k] - x_{mi}[k] \right]$$

$$(2)$$

This value is a-dimensional, and represents the discrepancy between observations and predictions, averaged along the measurements contained in $N_{\rm T}$.

Sometimes, if full covariance matrices are not available, a simplification is done and only the variances (diagonal terms) are considered:

$$r_{n} = \frac{1}{N_{T}} \sum_{i} \left(\frac{\left(\hat{x}_{pi}[k] - x_{mi}[k]\right)^{2}}{\sigma_{xp}^{2} + \sigma_{xm}^{2}} + \frac{\left(\hat{y}_{pi}[k] - y_{mi}[k]\right)^{2}}{\sigma_{yp}^{2} + \sigma_{ym}^{2}} \right)$$
(3)

2) Fusion break rate

The rate of fusion break, t_{FB} , is the number of times some navigation source is declared as inconsistent in the integrity analysis and therefore de-fused (the less consistent component is removed from the system track). This may lead to tracker reinitialization or keep the system track with a component less, the faulty sensor. It is computed as:

$$t_{FB} = \frac{\sum_{i} \{gt_{i} \mid gt_{i} \text{ is inconsistent track}\}}{N_{T}}$$
(4)

The value, averaged along N_T measurements, is obtained counting the total number of fusion break events during the interval. The test to decide the removal of a data source is done using the innovation, this time normalized by a higher number of standard deviations, typically 5.

IV. EXPERIMENTAL ENVIRONMENT AND EVALUATION OF TRACKING FILTERS FOR SENSOR FUSION

The process of data acquisition was based on several flight test missions that have taken place on circuits like the one sketched in Fig. 2. For each specified mission, we applied different configuration parameters to analyze the performance differences between each setting up of tracking filters. The flight controller log data was saved together with the configuration settings to be analyzed. For instance, table III, shows different tests carried out on the previous circuit and the analyzed elements of the navigation system (sensors and controllers). Remember, for information purposes that HIL strategy could be used in order to get simulated sensor data instead of real data.

The most typical task carried out by the data fusion process of the Pixhawk (EKF2 filter) is the attitude estimation using magnetometer, gyroscope and accelerometer data (attitude and heading reference system), and then fuse with accelerometers and GPS data to estimate position and velocity.

So, the sensor fusion system is based on a loosely coupled position and architecture which uses GPS measurements to aid the INS, typically used in most of navigation solutions based on sensor [15],[18],[19],[21],[28]. In this way, the IMU sensors are used extrapolate position, velocity, and attitude at high frequency (50 Hz), while updates from GPS measurements at low frequency (1 Hz) allows refinement of cinematic estimates and inertial sensor biases. Typically, the estimated state vector resulting in the output for the GNSS/INS filter contains the attitude vector represented with a quaternion, 3D position and velocity, three gyro biases and three accelerometer biases. The selected coordinate frame for position and velocity is the ENU frame (East, North, Down) with respect to the tangent plan with origin defined by the arming point in the start of the mission.

The EKF filter, used for sensor fusion in navigation, depends on two sets of parameters wich are sensor noise and plant noise. Both the estimation of cinematic parameters and sensor biases critically depend on the parameters characterizing noise in sensor data and uncertainty in prediction (process noise). Speficicallly, process noise parameters affect to the predicted error covariance and have critical impact in the weights given to the sensor observations with respect to the predicted estimates. A higher value for these parameters imply higher values of predicted covariance and so higher gain to observations (since the confidence on prediction decreases). Conversely, lower values imply lower gain to observations (higher confidence on predictions). The first set (sensor noise parameters) is usually given by accuracy tables from sensor providers.



TABLE IV. PROCESS NOISE PARAMETERS OF EKF

Name	Specification	Flight 1	Flight2	Flight3	Flight4	Flight5	Flight6
EKF2_ACC_B_NOISE	Process noise for IMU	0.003	0.001 m/s^3	0.003 m/s^3	0.007 m/s^3	0.01 m/s^3	0.003 m/s^3
	accel. bias prediction	m/s ³					
EKF2_GYR_B_NOISE	Process noise for IMU	0.001	0.001	0.003	0.007	0.01 rad/s ²	0.001
	rate gyro bias	rad/s ²	rad/s ²	rad/s ²	rad/s ²		rad/s ²
	prediction						
EKF2_ACC_NOISE	Accelerometer noise	0.35	0.1 m/s/s	0.3 m/s/s	0.7 m/s/s	1.0 m/s/s	0.35 m/s/s
	for covariance	m/s/s					
	prediction						
EKF2_GYR_NOISE	Rate gyro noise for	0.015	0.01 rad/s	0.03 rad/s	0.07 rad/s	0.1 rad/s	0.015 rad/s
	covariance prediction	rad/s					
EKF2_ACC_B_NOISE	Process noise for IMU	0.003	0.001 m/s^3	0.003 m/s^3	0.007 m/s^3	0.01 m/s^3	0.003 m/s^3
	accel. bias prediction	m/s ³					

A. GPS and INS local position integration



Fig 2. Mission circuit design

With respect to process noise, the values which can be tunned in the available platform have been systematically analyzed in the six scenarios used, with flights repeating the programmed mission (waypoints), but changing the parameters affecting to EKF performance shown in table IV. The selected values, to analyze the impact on performance metrics appear also in table IV and have been set considered the minimum and maximum values recommended in the implemented EKF2 system.

Fig. 3 presents a zoom of horizontal position estimated by tracking filter and GPS observations (circles), corresponding to right-bottom corner of mission. As can be appreciated, the flights corresponding to higher values of parameters (like flight 1, in blue, flight 5, in black) present lower deviations during turns, and, conversely, are affected more by the sensor noise.

Analysis of innovations

The normalized innovations are presented in this section. Fig. 4 presents aggregated position and velocity in a 6D innovation vector, normalized by its covariance matrix. In this case can be seen that flights 4,5 present the lower values. Table VI summarizes the innovation analysis for the 6 flights. The results showed in detail the system output with different parameters, reflecting the impact assessed through different

magnitues and the quality metrics considered (averaged innovations and fusion breaks).

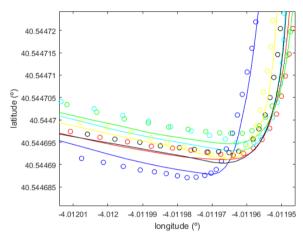


Fig. 3: Details of lat-lon GPS input and EKF output for all flights (1-blue, 2red, 3-cyan, 4-green, 5-black, 6-yellow)

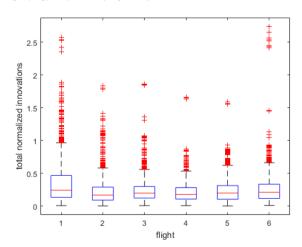


Fig 4. Normalized innovations for all flights

The methodology allows to take decisions of appropriate parameters for the mission considering the global residual of navigation vector and difference with respect to the default configuration, corresponding to the default configuration (flight #4). A moderate improvement in averaged residuals was appreciated, while the robustness in terms of fusion breaks, is



not critically dependent on these parameteres within the recommended intervals.

Finally, the methodology can be generalized and applied to different missions and sets of available sensors to explore the sensitivity of fusion algorithms and find the optimal parameters.

V. CONCLUSIONS

This paper presented a platform (Pixhawk PX4) and methodology to experiment with real data for UAV navigation. Based on data analysis and characterization the algorithms can take advantage of available sources. The quality of all inputs was systematically analyzed, and three processing algorithms, DCM, LPF and EKF, were evaluated with different parameters to exploit the data in the appropriate way considering the output analysis and specific performance metrics not based on ground truth.

So, this work presents a methodology to test and configure UAV navigation systems in real conditions, illustrated with an open environment for experimentation. The analysis of real data in a systematic way will allow successive improvements and parametrization, considering, among others, the following aspects:

- Data filtering to reduce errors and remove outliers
- Quality analysis to weight data uncertainty
- Analysis of biases and calibration previous to fusion.
- Parameter adjustment to optimize performance (PID gains, filter parameters, observation and plant noises, etc.)

ACKNOWLEGMENTS

This work was funded by public research projects of Spanish Ministry of Economy and Competitivity (MINECO), references TEC2017-88048-C2-2-R, RTC-2016-5595-2, RTC-2016-5191-8 and RTC-2016-5059-8.

REFERENCES

- Garcia J. Molina J.M., J. Trincado. "Analysis of real data with sensors and estimation outputs in configurable UAV platforms". Sensor Data Fusion: trends, solutions and applications 2017. Bonn, Germany, 10-12 Oct. 2017.
- [2] Groves P.D. "Navigation using inertial sensors". IEEE AES Magazine (Vol.30, Iss. 2) 42 - 69 Feb. 2015
- [3] Britting, K.R. "Inertial navigation systems analysis". Artech House, 2010
- [4] Farrel J.A., "Aided Navigation: GPS with High Rate Sensors", McGraw-Hill, New York, 2008.
- [5] Choi H., Kim Y.. "UAV guidance using a monocular-vision sensor for aerial target tracking". Control Engineering Practice, 22, 10-19, 2014.
- [6] Torres-González A., Martínez-de Dios J.R., Ollero A. "Robot-Beacon "Distributed Range-Only SLAM for Resource-Constrained Operation". Sensors 2017, 17(4), 903.
- [7] Ferrick A., Fish J., Venator E. and Lee G.S. "UAV Obstacle Avoidance Using Image Processing Techniques Technologies for Practical Robot Applications (TePRA", 2012 IEEE International Conference on 23-24 April 2012
- [8] Fasano G., Accado D., Moccia A., Moroney D., "Sense and avoid for unmanned aircraft systems". IEEE Aerospace and Electronic Systems Magazine, vol. 31, no 11, pp. 82-110, 2016.
- [9] Rankin G., Tirkel A., Leukhin A. "Millimeter Wave Array for UAV Imaging". MIMO Radar Radar Symposium (IRS), 2015 16th International 24-26 June 2015
- [10] Broumandan A., Siddakatte R, Lachapelle G. "An Approach to Detect GNSS Spoofing". IEEE AESS Magazine Vol. 32, N8, August 2017. 64-75

TABLE V. RMS OF INNOVATIONS

Variable	Flight 1	Flight 2	Flight 3	Fligt 4	Flight 5	Flight 6
Pos_x	0.1456	0.1786	0.2011	0.1958	0.1205	0.1684
Pos_y	0.1366	0.1220	0.1451	0.1368	0.1294	0.1070
Pos_z	0.1674	0.1468	0.1452	0.1414	0.1527	0.1651
Vel_x	0.3495	0.2583	0.2280	0.2059	0.2517	0.2746
Vel_y	0.3250	0.2276	0.2187	0.2025	0.2732	0.2610
Vel_z	0.2115	0.1940	0.2226	0.2192	0.2060	0.2172
Aggregate d pos-vel	0.4574	0.3040	0.2878	0.2532	0.2926	0.3456

- [11] Xiao L., "GNSS Receiver Anti-spoofing Techniques: A Review and Future Prospects". 5th Electronics and Network conference (CECNet 2015) Shanghai, 2015.
- [12] Carson N., Martin S.M., Starling J., and Bevly D.M. "GPS Spoofing Detection and Mitigation Using Cooperative Adaptive Cruise Control System". 2016 IEEE Intelligent Vehicles Symposium (IV) Gothenburg, Sweden, June 19-22, 2016. 1091-1096
- [13] Blasch E., Pribilski M., Daughtery B., Roscoe B., and Gunsett J., "Fusion Metrics for Dynamic Situation Analysis," Proc. SPIE 5429, April 2004.
- [14] Kim J., Cheng J., Guivant J., Nieto J., "A. Compressed Fusion of GNSS and Inertial Navigation with Simultaneous Localization and Mapping". IEEE AESS Magazine Vol. 32, N8, August 2017. 22-36
- [15] Sun R., Cheng Q., Wang G. and Ochieng W.Y. "A Novel Online Data-Driven Algorithm for Detecting UAV Navigation Sensor Faults". Sensors 2017, 17(10), 2243;
- [16] Gao W., Zhang Y. and Wang J." A Strapdown Interial Navigation System/Beidou/Doppler Velocity Log Integrated Navigation Algorithm Based on a Cubature Kalman Filter". Sensors 2014, 14(1), 1511-1527
- [17] Yao Y. and Xu X. "A RLS-SVM Aided Fusion Methodology for INS during GPS Outages". Sensors 2017, 17(3).
 [18] Jiang C., Zhang S.B. and Zhang Q.Z. "A New Adaptive H-Infinity
- [18] Jiang C., Zhang S.B. and Zhang Q.Z. "A New Adaptive H-Infinity Filtering Algorithm for the GPS/INS Integrated Navigation". Sensors 2016, 16(12), 2127
- [19] Babister, A. W. (1980). "Aircraft dynamic stability and response" (1st ed.). Oxford: Pergamon Press. ISBN 978-0080247687.
- [20] Hyyti H. and Visala A., "A DCM Based Attitude Estimation Algorithm for Low-Cost MEMS IMUs". International Journal of Navigation and Observation, Volume 2015, Article ID 503814.
- [21] Martí E., García J., Molina J.M. "A Simulation Framework for UAV Sensor Fusion". Hybrid Artificial Intelligence Systems 5th International Conference, HAIS 2010, San Sebastián, Spain, June 23-25, 2010.
- [22] Layh T., Demoz G.E. "Design for Graceful Degradation and Recovery from GNSS Interruptions", IEEE AESS Magazine Vol. 32, N9, September 2017. 4-17.
- [23] Khaleghi B., Khamis A., Karray F.O., Razavi S.N., "Multisensor data fusion: A review of the state-of-the-art". Information Fusion Volume 14, Issue 1, January 2013, Pages 28–44
- [24] García, J., Luis, Á., Molina, J. M. "Quality-of-service metrics for evaluating sensor fusion systems without ground truth". 19th International Conference on Information Fusion, Heidelberg, Germany, July 2016.
- [25] Colegrove, S. B., Bldg, I. B., Cheung, B., & Davey, S. J. (2003). "Tracking System Performance Assessment". 6th International Conference on Information Fusion, 926–933, Queensland, Australia, July 2003
- [26] Gorji, A.A., Tharmarasa, R., and Kirubarajan, T. "Performance measures for multiple target tracking problems". 14th International Conference on Information Fusion. Chigaco, USA, July 2011.
- [27] Meier L., PX4 Development Guide. [Online]. Available https://dev.px4.io/en/
- [28] Martí E., García J., Escalera A., Molina J.M., Armingol J.M. "Context-Aided Sensor Fusion for Enhanced Urban Navigation". Sensors Vol. 2012 16802-16837. 2012
- [29] Dronecode. PX4 Development Guide [Online]. Available: https://dev.px4.io/en/simulation/gazebo.html



Evasión de obstáculos apoyada en localización basada en simulación de instancias — Navegación autónoma en entornos cerrados.

1st Mario Bartolomé Manovel Departamento de Ingeniería Civil Universidad de Burgos Burgos, España mario.bartolome@gmail.com 2nd César I. García Osorio Departamento de Ingeniería Civil Universidad de Burgos Burgos, España cgosorio@ubu.es 3rd José-Francisco, Díez-Pastor Departamento de Ingeniería Civil Universidad de Burgos Burgos, España ¡fdpastor@ubu.es

4th Alejandro, Merino Gómez

Departamento de Ingeniería Electromecánica

Universidad de Burgos

Burgos, España

alejandromg@ubu.es

Resumen—Este artículo, detalla el uso dado a la implementación de dos algoritmos, con una gran componente estocástica, en la creación de un sistema de navegación en entornos cerrados.

El primero, denominado Filtro de Partículas, e introducido en 1993 por N. Gordon, D. Salmond y A. Smith [5], proporciona un mecanismo de localización basado en filtros bayesianos recursivos, haciendo uso del método de Montecarlo. Se tratará de estimar la posición, realizando múltiples simulaciones del entorno en el que se desplaza el agente.

El segundo algoritmo, denominado *Vector Field Histogram*, Histograma de Campos Vectoriales, o *VFH* por su sigla en inglés, fue introducido por Borenstein y Koren en el año 1991 [2], [3], proporciona un método de evasión de obstáculos basado en el planeamiento, local, de la ruta a seguir por el agente.

Trabajando de forma conjunta, proporcionan un método de evasión de obstáculos y planeamiento de rutas tremendamente robusto.

Index Terms—drone, RaspberryPi, filtro de partículas, histograma de campos vectoriales, simulaciones Montecarlo

I. Introducción

I-A. Motivación

Este artículo, es parte de un Trabajo de Final de Grado. La intención tras la implementación, y unión de los métodos a continuación descritos, es que formen parte de un sistema de control automatizado para un *drone*. El Filtro de Partículas fue elegido por su robustez y precisión, frente a sistemas incapaces de funcionar en entornos cerrados. El *VFH* fue elegido como solución a una serie de limitaciones dadas en el uso de algoritmos de Campos Potenciales¹ para la evasión de obstáculos. Lejos de quedarse *sólo* en la teoría, se ha construido un *drone* en el que instalar todo el hardware necesario.

¹Estos no son adecuados para la navegación en corredores, o entornos altamente ocupados por obstáculos.

I-B. Estado del arte

Con el creciente uso de sistemas automatizados que ha presentado la industria en los últimos años, el nicho que los *drones* han pasado a ocupar, crece de forma rápida haciendo que se descarten métodos muy consolidados hasta el momento. Vigilancia, industria cinematográfica, ocio, deportes y mensajería son solo algunos de los ejemplos en los que los *drones* se van abriendo camino.

La industria parece moverse hacia sectores dedicados actividades en exterior, donde propuestas como la evasión de obstáculos, pueden ser algo más triviales o innecesarias:

- Sistemas de vigilancia de incendios, campos y cultivos.
- Sistemas de fumigación agrícola.
- Sistemas de inspección de zonas de difícil acceso.
- Sistemas de grabación a nivel profesional.

Sin embargo, parece estar obviándose el uso que se puede dar a un *drone* en un espacio cerrado, ya sea para acceder a zonas complejas en edificios o estructuras con gran cantidad de obstáculos, movimiento de mercancías ligeras en ciudades, en el ámbito militar, o vigilancia en general.

II. ESTIMACIÓN DE LA POSICIÓN MEDIANTE SIMULACIONES MONTECARLO

El Filtro de Partículas es un algoritmo basado en simulaciones de Montecarlo, y algoritmos bioinspirados. En concreto, se trata de una ramificación de estos. Es un algoritmo de estimación de una distribución, ya que adopta la característica de remuestreo de una población, que presentan los algoritmos genéticos, pero no así otras, como la mutación o cruce.

De esta forma, estimará la posición y orientación de un agente en un entorno, haciendo uso de múltiples hipótesis





Figura 1. Detalle del *drone* construido, con los sensores de distancia instalados.

ponderadas [6], denominadas partículas². Dicha ponderación, peso o probabilidad, se basa en la similitud de la hipótesis, o partícula, con la instancia que representa el agente.

Para lograr obtener información del entorno, y poder dar una serie de atributos con que poder comparar el agente y las particular que lo simulan, se debe hacer uso de sensores, como los mostrados en la Figura 1, que proporcionen la distancia del agente al obstáculo hacia el que se dirige el sensor.

Habitualmente, se comienza con una distribución de partículas aleatoriamente dispersas por el mapa y con una orientación definida, obviamente no se establecen partículas dentro de obstáculos. Esto, representa el total desconocimiento de la posición del agente, es decir, todas las hipótesis son equiprobables y por lo tanto la posición del agente es, equiprobablemente, cualquier posición del mapa.

A medida que el agente comienza a moverse, las partículas se mueven en la dirección y orientación que determina el agente. A continuación el agente y las partículas toman medidas de su entorno haciendo uso de los sensores de distancia, en el caso del agente, y de forma simulada en el caso de las partículas.

Una vez realizado el movimiento, la distribución de partículas es remuestreada en base a como de parecidas son las hipótesis al estado real del sistema. El remuestreo, o *resample*, conlleva reducir la población de partículas descartando las menos parecidas, o menos probables. De esta manera al cabo de cierto número de iteraciones la distribución converge hacia la posición real del agente.

II-A. Representación del estado

El estado del agente se puede representar mediante una n-tupla, donde n=3 en este caso, tal que: $[x,y,\theta]$ siendo x e y las coordenadas de posición y θ la orientación. La altura del agente no es tenida en cuenta, dado que se establece esta

²Una partícula es el homólogo de un individuo en un algoritmo genético.

como fija, es decir, no existen zonas en las que el agente deba navegar a menor o mayor altura para poder acceder, de manera que no es relevante para el cálculo de la posición.

El peso de las partículas, o estimación de la probabilidad de que la partícula sea la ubicación real del agente, es una función de densidad de probabilidad distribuida sobre el espacio de estados, descrito en [7]. En el Filtro de Partículas la variable de interés, la posición del agente, es representada por un conjunto de M partículas en el instante t=k, tal que $S^k=[e^k_j,w^k_j]:j=1..M$ tal y como se muestra en [6]. Cada partícula tiene asignado un peso, w^k_j que define la contribución de esa partícula a la estimación de la posición.

Aquellas regiones del espacio de estados con una gran cantidad de partículas, se corresponden con zonas en las que hay una alta probabilidad de que el agente se encuentre en ellas. Aquellas zonas con una densidad de partículas baja, representan zonas en las que es improbable que el agente se encuentre.

El algoritmo asume la *propiedad de Markov*³, de manera que solo funciona correctamente si el entorno es estático.

II-B. Actualización de movimiento

Durante la actualización de movimiento, descrita en [1], [6], el agente predice su nueva localización basándose en el movimiento, supuestamente, realizado. Sin embargo, la capacidad del agente de rotar o trasladarse no es perfecta. Si el sistema de evasión de obstáculos indica al agente que debe rotar n° para dirigirse hacia la meta por un camino seguro, el agente $tratar\acute{a}$ de rotar n° , pero es muy probable que infra/sobrecorrija. Si el agente trata de desplazarse en línea recta, inevitablemente escorará en una dirección u otra.

El movimiento se define de la siguiente manera, para el instante de tiempo t=k, teniendo en cuenta el ruido existente en las medidas de los sensores y sistemas de movimiento:

$$\begin{bmatrix} x' \\ y' \\ \hat{\theta}' \end{bmatrix} = \begin{bmatrix} x + \rho \cdot \cos(\hat{\theta}_k) \\ y + \rho \cdot \sin(\hat{\theta}_k) \\ \hat{\theta}_k + f(rand|\mu, \sigma^2) \end{bmatrix}$$
(1)

Donde:

 $[x,y,\hat{ heta}]^T$: Posición inicial del agente. $\hat{ heta} = \arctan rac{\delta y}{\delta}$

 $[x', y', \hat{\theta}']^T$: Posición final del agente.

 $\rho = \sqrt{\Delta x^2 + \Delta y^2} \cdot f(rand|\mu, \sigma^2)$: la distancia a recorrer **añadiendo ruido** dado por una distribución normal.

 $\mu = 0.0$: se desea un valor aleatorio dentro de una gaussiana con centro en 0.0.

 σ : Errores de los sensores o sistemas de movimiento.

El ruido, como puede verse en la ecuación 1, se genera mediante una función de distribución normal, como la detallada en la ecuación 2, con centro en 0,0 de manera que se pueda simular el hecho de infra/sobrecorrejir el movimiento.

³En un proceso estocástico que cumple la propiedad de Markov, el estado futuro depende únicamente del estado presente, y no de los estados pasados.



II-C. Actualización de sensores

Cuando el agente toma medidas a través de sus sensores, actualiza la distribución de partículas de forma ponderada, tal y como se describe en [1], [6], de manera que aquellas que más afinidad presentan en sus mediciones, serán tenidas en cuenta más a menudo que aquellas que no se parezcan al agente.

Para ello, se calcula para cada partícula la probabilidad, p_j^k de ser la posición real del agente basándose en el estado que esta representa, y haciendo uso de una función de distribución normal, o Gaussiana:

$$p_j^{k+1} = f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$
 (2)

Donde:

 $\mu=$ Distancias de la partícula a los diferentes obstáculos.

 σ = Ruido del sistema de sensores.

x= Distancias reales obtenidas por los sensores del agente.

Cabe destacar, que la probabilidad p_j^{k+1} tiene como superíndice k+1, determinando este el instante de tiempo siguiente, es decir la probabilidad de la partícula j **después** de haber realizado el movimiento.

Se le asignará a cada partícula un peso, proporcional a la probabilidad de tratarse de la ubicación del agente:

$$w_j^{k+1} = w_j^k \cdot p_j^{k+1} \tag{3}$$

Dicho peso será normalizado de la forma habitual mediante:

$$w_j^{k+1} = \frac{\tilde{w}_j^k}{\sum_j^M \tilde{w}_j^k} \tag{4}$$

Donde \tilde{w}_j^k es la medida de peso de una partícula j en el instante de tiempo k, antes de ser normalizado.

II-D. Remuestreo

Una vez que se han obtenido los pesos, el algoritmo deberá generar un nuevo conjunto de partículas a partir del anterior, teniendo en cuenta el peso de cada partícula. Es decir, si se deben generar N nuevas partículas, el algoritmo deberá escoger de entre el conjunto M de partículas, dando mayor prioridad a aquellas que tengan mayor peso. Cabe destacar, que el proceso de selección ha de ser con reemplazo, de manera que puede seleccionarse múltiples veces la misma partícula.

De esta forma se genera un nuevo conjunto de partículas M_{k+1} , en el que la mayor parte de las partículas se encontrará en aquellas posiciones que proporcionen medidas parecidas a las obtenidas por el agente real.

III. EVASIÓN DE OBSTÁCULOS MEDIANTE PLANEAMIENTO LOCAL DE RUTAS

El VFH permite la detección de obstáculos y su evasión mediante el control de la dirección y velocidad del agente en tiempo real.

Para ello realiza una representación del entorno del agente en forma de histograma. Dicho entorno, llamado *Región Activa*

C*, se representa como una *ventana* que se desplaza con el agente en el centro. Se trata un algoritmo de búsqueda local, sin embargo se ha mostrado que suele producir rutas cercanas al óptimo, aunque en el caso de este proyecto no es relevante, dado que la intención es que se exploren todas las zonas del entorno.

Se compone de tres partes:

- Red Cartesiana de Histogramas: Derivado del concepto de malla de certidumbre propuesto por Moravec y Elfes en 1985, ver [4], en la universidad de Carnegie Mellon. Se construye un plano cartesiano representando el entorno cercano del agente. Por cercano, se entiende una distancia que los sensores de distancia puedan abarcar. Dicho plano será representado como un histograma, y de ahí su nombre habitual Cartesian Histogram Grid. Ver subsección III-A.
- Histograma Polar: Una representación unidimensional, obtenida a partir de una reducción de la Red Cartesiana definida en el punto anterior. Se compone de n sectores angulares k, de anchura α, de forma que n · α = 360; n ∈ Z. Dichos sectores k contienen un valor h_k que representa la densidad de obstáculos, Polar Obstacle Density o POD, contenida en él. Ver subsección III-B.
- 3. Capa de salida: Representa el resultado del algoritmo. A partir del POD, se obtienen los posibles valles⁴ candidatos existentes entre obstáculos, y se elige el que más se aproxime a la dirección de la meta establecida. Así, devolverá la orientación necesaria a seguir por el agente. Ver subsección III-C.

III-A. Cartesian Histogram Grid

Se modela el espacio cercano al agente en forma de malla. En cada celda (i,j) de esa malla se encuentra un valor $c_{i,j} \in \mathbb{Z}$ que establece la certeza de la existencia de un obstáculo. La cantidad de celdas existentes en la malla se establece en función de los límites del sensor, y teniendo en cuenta que es necesario establecer una precisión c, por ejemplo: Si se dispone de un sensor con un rango de medidas de hasta 400 cm se puede crear una malla de 81×81 , suponiendo que cada celda tenga un tamaño de c=5 cm \times 5 cm, en cuyo centro se encuentra el agente, dejando 40 filas y columnas a cada lado. Estableciendo así, un perímetro de medidas de 200 cm en cada dirección, con una precisión de ± 5 cm.

Dicho valor se obtiene de la lectura proporcionada por el sensor de distancia, y se establece en el centro del ángulo de barrido sensor. La elevada eficiencia de este algoritmo se basa precisamente en incrementar el valor $c_{i,j}$ de únicamente una celda con cada medida. Dicha celda (i,j) se encuentra a una distancia de $R=\frac{\delta_{obs}q}{c}$ celdas y en la bisectriz del ángulo barrido por el sensor. Si bien está solución puede parecer una simplificación del problema, se llega a generar una distribución probabilística tomando múltiples medidas de forma continua mientras el agente se desplaza por el entorno. Por tanto, la misma celda, cercana a un obstáculo, y sus vecinas serán

⁴Así denominados por su representación en forma de histograma



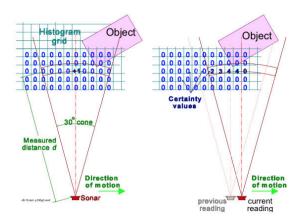


Figura 2. Distribución Histográmica de Probabilidades. Extraida de [3]

incrementadas repetidas veces, tal y como se muestra en la Figura 2.

III-B. Polar Histogram

A partir de las medidas obtenidas en el Histogram Grid, se realiza la primera reducción de información para construir un Histograma Polar. Para ello, los contenidos de la región activa C* son tratados como un *vector de obstáculos* cuya dirección está definida por la dirección β de la celda en cuestión al centro del agente VCP^5 , y que viene definida por la función:

$$\beta_{i,j} = \tan^{-1} \frac{y_i - y_0}{x_i - x_0} \tag{5}$$

La ecuación 5 devuelve un valor $\beta \in [-\frac{\pi}{2}, \frac{\pi}{2}]$ rad.

Nótese, que para llevar a cabo la obtención de estos ángulos, se debería utilizar una función que tenga en cuenta el signo de las componentes del vector dirección $[y_i-y_0,x_i-x_0]$ resultante, de forma que devuelva el ángulo de giro, sea en sentido horario (valores positivos) o antihorario (valores negativos), más corto posible⁶.

La magnitud de cada zona es entonces calculada de la siguiente forma:

$$m_{i,j} = c *_{i,j}^2 \cdot (a - bd_{i,j})$$

$$\tag{6}$$

Donde a representa la fuerza con que un obstáculo afecta al agente, y b representa la distancia desde la que un obstáculo afecta al agente, ambos positivos.

El plano es convertido en una secuencia de sectores que cubren los 360°. Se definen, por tanto, $n \in \mathbb{Z}$ sectores k de amplitud α , por ejemplo $n=72; \alpha=5$. Y se distribuyen las medidas tomadas anteriormente en los diferentes ángulos relativos al VCP del agente, en los sectores k_i correspondientes.

$$k = \frac{\beta_{i,j}}{\alpha} \tag{7}$$

⁵El VCP o *Vehicle Center Point* se define como el centro geométrico del vehículo. En nuestro caso, al tratarse de un *drone*, se considera el centro del mismo como VCP

⁶Obviamente es lo deseable, no sería eficiente realizar un giro de 225° en el sentido de las agujas del reloj, cuando uno de 135° en el sentido contrario a las agujas del reloj bastaría.

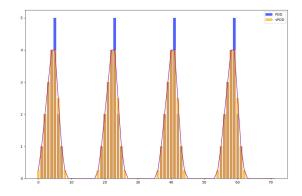


Figura 3. En azul Polar Obstacle Density (POD). En naranja el suavizado de este (sPOD).

con un valor h_k , véase la ecuación 8, de densidad de obstáculos en ellos:

$$h_k = \sum m_{i,j} \tag{8}$$

Dada la discretización de los datos obtenidos del Polar Histogram el resultado, al realizar esta conversión y al obtener el sumatorio h_k de todos los valores pertenecientes a un sector k, puede parecer que el histograma varía de forma muy repentina entre dos sectores. Por ello se aplica una función de suavizado, según J. Borenstein y Y. Koren en [3]:

$$h'_{k} = \frac{h_{k-l} + 2h_{k-l+1} + \dots + lh_{k} + \dots + 2h_{k+l-1} + h_{k+l}}{2l+1}$$
(9)

Donde l es una constante positiva a la que se le ha dado un valor de 5.

Sin embargo, existe una errata en el artículo publicado, y la ecuación 9 no es consistente, i.e: La función de suavizado parece poder expresarse de forma general tal que:

$$h'_{k} = \frac{1}{2l+1} \sum_{n=-l}^{l} (l-|n|+1) \cdot h_{k+n}$$
 (10)

ej:
$$l=5\ h_k'=\frac{1h_{k-5}+2h_{k-4}+3h_{k-3}+\ldots+6h_k+\ldots+2h_{k+l-1}+h_{k+l}}{2l+1}$$

Como puede verse, el valor central $6h_k$ correspondiente a n=0, no coincide con la posición dada para ese valor de n, donde el coeficiente que multiplica a h_k es igual a l en lugar de l+1.

Por ello, se ha hecho uso de la función de suavizado de *Hann*, llamada así por el meteorólogo austriaco Julius van Hann. Se conoce a esta función por el nombre de Campana de Coseno, y se define por la ecuación 11.

$$w(n) = 0.5 - 0.5\cos\frac{2\pi n}{M - 1} 0 \le n \le M - 1$$
 (11)

Donde M es el número de puntos en la ventana de salida. En este caso tomará el valor de l.

De esta forma, de obtener un histograma de n sectores con valores h_k , posiblemente dispares, en sectores k contiguos, se pasa a obtener un histograma suavizado, que será de mayor utilidad para el sistema de evasión de obstáculos. Véase la Figura 3.



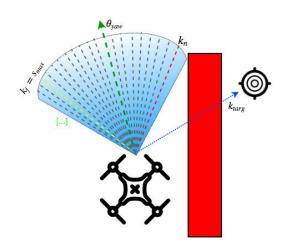


Figura 4. Valle ancho encontrado entre el obstáculo, a la derecha, y un espacio abierto, a la izquierda.

III-C. Output Layer

En el último estadio del algoritmo VFH, se computa el ángulo de giro θ que se debe aplicar al agente para dirigirlo, por una ruta segura, hacia el destino establecido. Una vez obtenido el Polar Obstacle Density, y aplicado el suavizado correspondiente, se puede determinar en que sectores k existe un valle. Se define un valle candidato como una zona, compuesta de varios sectores por los que es seguro navegar, es decir, están libres de obstáculos o su densidad de obstáculos está por debajo de cierto umbral.

Por lo general, se crean dos o más valles candidatos al analizar el entorno, de forma que es necesario elegir aquel que dirigirá al agente en dirección al destino k_{tarq} . Una vez escogido el valle, se deberá seleccionar el sector k idóneo. Para ello se mide el tamaño del valle, es decir el número de sectores consecutivos por debajo del umbral que lo componen. De esta forma, se distinguen dos tipos de valles: amplios y estrechos. Los valles amplios son el resultado de espacios grandes entre obstáculos, o de situaciones en las que únicamente existe un obstáculo lo suficientemente cerca del agente. Por grande se define una constante s_{max} que determina el número de sectores k que componen un valle amplio.

El sector más cercano a k_{tarq} y por debajo del umbral se denomina k_n , y representa el borde cercano del valle. El más lejano se denomina k_f , y en el caso de los valles amplios, coincide con el valor de $s_{max} + k_n$. Véase la Figura 4.

El sector que debe seguir el agente para dirigirse hacia k_{tarq} sin peligro, se denomina θ_{yaw} , y su valor es la media de los valores de k_n y k_f , como puede verse en la ecuación 12.

$$\theta_{yaw} = \frac{k_n + k_f}{2} \tag{12}$$

Sin embargo, la ecuación 12 presenta un comportamiento errático cuando el destino se encuentra dentro de un valle, dado que se establece θ_{yaw} como la media entre los sectores cercano y lejano, al encontrarse la meta en un sector dentro del valle, el agente no se aproxima a ella, sino que realiza

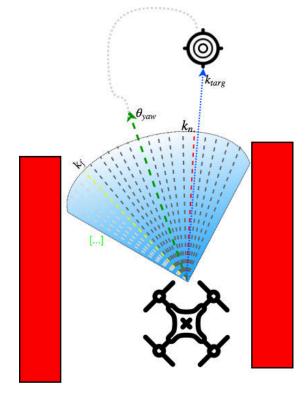


Figura 5. Movimiento circular al encontrarse k_{tarq} en un sector seguro por ecuación 12

círculos cada vez más cerrados hasta llegar al destino, como puede verse en la Figura 5

La intención tras la ecuación 12 es la navegación segura en entornos con obstáculos cercanos, ya que aporta la cualidad de escoger la zona central entre dos obstáculos. Además en el momento en que la posición del agente sea intermedia entre dos obstáculos, la ecuación 12 dará como resultado el mismo sector, con lo que se consigue un movimiento rectilíneo.

Sin embargo, en el momento en el que el destino k_{tarq} se encuentra en un sector k por el que es seguro navegar, no existe la necesidad escoger la zona intermedia del valle, sino que es deseable dirigirse hacia él directamente.

En el caso de valles estrechos, el comportamiento es prácticamente el mismo. Para este caso el valor del último sector con un POD por debajo del umbral escogido será $k_f < s_{max}$. Se usa la ecuación 12 para obtener el valor de θ_{yaw} , ilustrado en la Figura 6.

El cálculo de la velocidad, se puede derivar en el VFH, haciendo que este calcule la velocidad en base a la ocupación de un sector. Puede calcularse de la siguiente manera:

$$V = V_{\text{max}} \cdot \left(1 - \frac{h_c''}{h_m}\right) + V_{\text{min}} \tag{13}$$

Dónde:

 $h_c'' = \min(h_c', h_m).$ h_c' es la POD suavizada en el sector por el que navega

 h_m es una constante establecida de forma empírica.



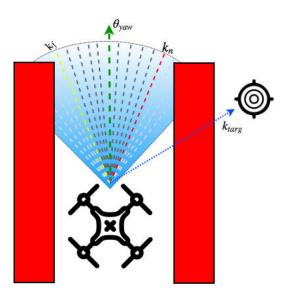


Figura 6. Valle estrecho encontrado entre dos obstáculos. La ecuación 12 proporciona un sector seguro ubicado en la zona central del valle.

 V_{\min} es la velocidad mínima del agente. V_{\max} es la velocidad máxima del agente.

III-C0a. Umbral: Se ha referenciado numerosas veces el umbral que parece definir un valle como candidato. Su definición se ha dejado para el final, debido a que el VFH presenta una gran robustez ante configuraciones probablemente erróneas. Aumentar o reducir el umbral, únicamente, afecta a la anchura de los valles candidatos cuando estos son estrechos. En el caso de los valles anchos sencillamente se aumenta o reduce la distancia existente entre el obstáculo y el agente.

Establecer un umbral muy alto, hace que el agente no sea consciente de la existencia de obstáculos y que se aproxime a ellos. Sin embargo, las repetidas medidas de un obstáculo en ese sector harán que el valor de certidumbre del *Polar Histogram* se eleve hasta superarlo, produciendo que el agente trate de variar su curso. De esta forma el agente se acercará mucho a los obstáculos, haciendo posible que llegue a colisionar, si la velocidad de aproximación es demasiado rápida.

Por el contrario, si el umbral es muy bajo, hará que los valles candidatos se vean reducidos, haciendo que el agente no pueda pasar por espacios estrechos.

IV. RESULTADOS PRÁCTICOS

El despliegue de estos algoritmos se ha realizado en una RaspberryPi 3B, haciendo uso de sensores de ultrasonidos HC-SR04, capaces de medir distancias de entre 5 cm y 400 cm con una precisión de ± 1 cm. Su tasa de adquisición de datos es, aproximadamente, 16Hz para un único sensor. Los sensores deberán obtener sus medidas de forma secuencial, para evitar la recepción de ecos de otros sensores, lo que hace que la tasa se reduzca todavía más, bajando hasta los 3Hz al utilizar 5 sensores. Esto les hace poco fiables para un entorno en producción. I.e., al proporcionar a un controlador PID el valor objetivo, sea la velocidad o la rotación del drone, calculado

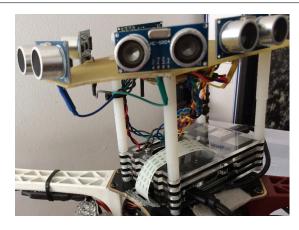


Figura 7. Detalle de los sensores y la RaspberryPi instalada en el drone.

por el VFH, tan solo 3 veces por segundo, es **muy** probable que el movimiento se realice con información desactualizada. De hecho, hasta 16Hz se han mostrado insuficientes para llevar a cabo el control de la altitud en un sistema con una dinámica tan alta como es un *drone*.

V. CONCLUSIONES Y LÍNEAS FUTURAS

El Filtro de Partículas, pese a ser computacionalmente exigente⁷, provee de un medio para obtener la localización de un agente sin hacer uso de otras tecnologías menos fiables, como GPS, GLONASS o Galileo. Alimentar el *VFH* con la posición obtenida de un método como el Filtro de Partículas, puede ocasionar movimientos erráticos si se encuentran simetrías en el entorno, haciendo que la población de partículas se disperse en dichas áreas.

Se recomienda encarecidamente hacer uso de sensores con una tasa de adquisición de datos más rápida, como LIDAR o sensores LASER. De la teoría a la práctica hay, sin lugar a dudas, una ingente cantidad de parámetros que ajustar y personalizar en base a la dinámica del sistema elegido.

REFERENCIAS

- [1] Domingo Gallardo López. Localización basada en filtros de partículas. *Universidad de Alicante*, 2010.
- [2] Y. Koren J. Borenstein. Real-time obstacle avoidance for fast mobile robots in cluttered environments. *International Conference on Robotics* and Automation, 1990.
- [3] Y. Koren J. Borenstein. The vector field histogram fast obstacle avoidance for mobile robots. *Transactions on Robotics and Automation*, 7(3), 1991.
- [4] Hans Moravec and A. E. Elfes. High resolution maps from wide angle sonar. In *Proceedings of the 1985 IEEE International Conference on Robotics and Automation*, pages 116 – 121, March 1985.
- [5] Smith N. Gordon, J. Salmond. Novel approach to nonlinear/non-gaussian bayesian state estimation. *IEE Proceedings F (Radar and Signal Processing)*, 140(2), 1993.
- [6] Ioannis M. Rekleitis. A particle filter tutorial for mobile robot localization. McGill University, 2003.
- [7] Daniel Sabinasz. Robot localization IV: The particle filter, 2017. [Internet; descargado 9-abril-2018].

 7 Si se dispone el plano como una matriz, en la que en cada posición i,j se establecen n partículas para cubrir la mayor cantidad de orientaciones posibles, y cada partícula dispone de r rayos que intersectan o obstáculos, dicha matriz no es tal, sino que pasa a ser un tensor tetra-dimensional, o teseracto.



Medida de calidad de la planificación de recogida de residuos a partir del conocimiento del experto utilizando aprendizaje de preferencias

Laura Fdez-Díaz Global R&D, ArcelorMittal (España) Miriam Fdez-Díaz Global R&D, ArcelorMittal (España) José Ramón Quevedo Pérez Centro de Inteligencia Artificial Universidad de Oviedo (España)

Elena Montañés Roces Centro de Inteligencia Artificial Universidad de Oviedo (España)

Resumen—La investigación incluida en este trabajo surge a raíz de la necesidad de optimizar globalmente el proceso de recogida de residuos de la empresa Consorcio para la Gestión de los Residuos Sólidos de Asturias (COGERSA). Hasta ahora, el diseño de la planificación se iba realizando progresivamente bajo demanda, por lo que su optimización no es global. Los expertos crearon la planificación de forma manual construyendo localmente las nuevas rutas de los concejos en cuanto estos solicitaban el servicio de recogida. Un diseño global teniendo en cuenta todas las características de este proceso excede la capacidad de un experto humano debido, principalmente, a la gran cantidad de recursos humanos y materiales disponibles, al alto número de contenedores que se deben recolectar, a las diferentes limitaciones de tiempo y a la dependencia del trazado de la carretera. Normalmente, este tipo de problemas se resuelve utilizando algoritmos de optimización de planificación, para los cuales uno de los requisitos es diseñar una función objetivo que evalúe la calidad de la planificación. En este sentido, el objetivo de este trabajo es diseñar una función objetivo a partir del conocimiento de los expertos que sea capaz de evaluar la calidad de una planificación global de recogida de residuos, como paso previo a una posterior optimización de la planificación. Nuestra propuesta se enmarca dentro del aprendizaje de preferencias, donde además, se propone simplificar las decisiones de los expertos, ya que deberán decidir no entre dos planificaciones completas de la ruta, sino entre dos pares de rutas, que supone una tarea bastante más asequible, incluso abordable. El resultado será una función de ranking de planificación de rutas, donde dada una planificación candidata, se le asignará una puntuación que la coloque dentro del ranking.

Palabras clave—Aprendizaje de preferencias, Caracterización de rutas, Función objetivo

I. Introducción

Los expertos de la empresa Consorcio para la Gestión de los Residuos Sólidos de Asturias (COGERSA) planifican rutas de recogida de residuos según la demanda de los ayuntamientos y sin alterar las rutas ya existentes. Con el fin de optimizar en mayor medida los recursos disponibles, la empresa ha decidido realizar una única planificación conjunta. Optimizar los recursos tanto humanos como materiales, el tiempo de recogida o el consumo de combustible, entre otros, no es tarea sencilla ya que hay que tener en cuenta una serie de factores. Por ejemplo, el número de contenedores es fijo y las frecuencias de recogida vienen impuestas por el gobierno, al igual que varias restricciones en la planificación. No se deben recoger contenedores donde no se pueda llevar a cabo

la recogida de residuos, como, por ejemplo, si hay un mercado callejero o en contenedores ubicados en la entrada de colegios o institutos durante el comienzo o finalización del horario escolar. Otro factor a tener en cuenta es el tiempo de trabajo del personal o el uso de los camiones debido a que no se debe sobrepasar un cierto número de horas. También, se tendrá que controlar la distancia que recorre un camión cargado, puesto que para recorrer menos distancia cargado es mejor que el camión recoja los contenedores en el camino de regreso. Además, se debe considerar la lateralidad¹ de los contenedores debido a que en algunas áreas el camión tendrá que dar la vuelta para recoger un contenedor ubicado a la izquierda o derecha de la carretera.

Normalmente este tipo de problema, conocido generalmente como Problema de Enrutamiento de Vehículos (VPR, Vehicle Routing Problem) [1], se resuelve utilizando algoritmos de optimización de planificación, los cuales usan una función objetivo para evaluar la calidad de una determinada planificación. Sin embargo, obtener una función objetivo de este calibre teniendo en cuenta todos los factores que involucra no es una tarea trivial, aunque aprendible, como se puede ver en un clásico trabajo en el ámbito del juego de ajedrez [2]. Es por ello por lo que surge esta investigación, la cuál se centra en diseñar una función objetivo que recoja información de los expertos, quedando fuera del alcance de este trabajo la aplicación de esta función en un algoritmo de optimización. La solución que proponemos se enmarca dentro del aprendizaje de preferencias, donde los expertos deben decidir entre pares de planificaciones de rutas cuál es, a su juicio, la mejor planificación dentro de cada par. Sin embargo, esta tarea aún sobrepasa la capacidad humana, incluso la de los expertos, por lo que nuestra propuesta convierte el problema en decidir entre pares de rutas qué miembro de cada par es el mejor, en vez de entre planificaciones de rutas completas. Posteriormente, estas decisiones se utilizarán para diseñar una función objetivo, que, aunque se utilicen decisiones a nivel de ruta, será válida para evaluar planificaciones de ruta. La idea es diseñar una serie de indicadores clave (KPIs) que describan una ruta, teniendo en cuenta, en la medida de lo posible, tanto la información

¹Lateralidad es la propiedad que tiene un contenedor que indica el lado de la carretera por el que se tiene que recoger.



proporcionada por los expertos como los factores involucrados en todo el proceso de recogida.

Este trabajo se organiza de la siguiente manera. La Sección II describe algunos trabajos relacionados con el tema que nos ocupa. En la Sección III se detalla el proceso de construcción de una función objetivo para evaluar una planificación de recogida de residuos. En la Sección IV se muestran los resultados de los experimentos llevados a cabo, así como la discusión de los mismos. Finalmente, la Sección V esboza algunas conclusiones y propone varias líneas de investigación de trabajo futuro.

II. TRABAJOS RELACIONADOS

En inteligencia artificial, existen dos formas principales de obtener conocimiento de los expertos. Por un lado, si los expertos pueden describir su conocimiento, este conocimiento puede recogerse en forma de reglas, generando un sistema experto. Por otro lado, y siendo el caso que nos ocupa, si las acciones de los expertos están disponibles pero no son capaces de explicarlas, entonces, es posible utilizar técnicas de aprendizaje automático para extraer su conocimiento.

Existen en la literatura numerosos trabajos cuyas soluciones se obtienen a partir de información de los expertos. Por ejemplo, el trabajo [3] propone un modelo para detectar vertidos de petróleo a partir de información experta. Los expertos debían observar imágenes para detectar regiones sospechosas. En [4] se presenta una estrategia para optimizar la calidad de recuperación de un motor de búsqueda. Un usuario al hacer clic sobre un documento relacionado con una consulta proporciona al motor de búsqueda la información del ranking de los resultados para ese usuario, puesto que el usuario manifiesta que prefiere el documento sobre el que hace clic con respecto al resto de documentos. Esta información alimenta el sistema que genera un modelo capaz de clasificar documentos según las preferencias del usuario. En [5], se genera un modelo que ordena ganado vacuno según su calidad como productores de carne. El ganado se describe mediante medidas de su cuerpo relevantes para los expertos. Las preferencias de los expertos se capturaron y unificaron en una función de ordenación. También, [6] desarrolla una estrategia similar para analizar la información sensorial de un panel de consumidores con el fin de ordenar sus preferencias sobre ciertos productos. De la misma forma, [7] propone un método de aprendizaje automático para obtener los factores más relevantes que afectan a la empleabilidad y el empleo. Para ello, algunos académicos de diferentes campos definieron las competencias que podrían ser importantes para el empleo utilizando los datos de las universidades españolas y cuestionarios de los estudiantes. Los objetivos de este estudio fueron predecir si una persona tendría un empleo o no y extraer los factores más relevantes para conocer la forma más efectiva de preparar a los estudiantes para el mercado laboral. En otro estudio relacionado con la educación [8] se ajusta una rúbrica de una actividad académica a partir de las respuestas de los estudiantes y de las preferencias de los profesores en las respuestas. El objetivo es determinar el peso de cada elemento a partir de rankings parciales generados

por las lecturas de varias respuestas de los estudiantes a la actividad.

III. CAPTURA DEL CONOCIMIENTO EXPERTO EN LA PLANIFICACIÓN DE LA RECOGIDA DE RESIDUOS

Antes de profundizar en la obtención de una función objetivo que capte el conocimiento experto, hay que mencionar algunos aspectos para comprender mejor el proceso de recogida de residuos que actualmente se está llevando a cabo en la empresa. Los expertos han ido planificando una serie de rutas bajo demanda, optimizadas de forma local para el área demandada en cada momento. Cada ruta comienza y finaliza en el mismo punto, un garaje. Además, cada ruta tiene un grupo de puntos geográficos de recogida que pueden incluir más de un contenedor de la misma capacidad o diferente (si hay más de un contenedor en el mismo punto de recogida, la capacidad de ese punto de recogida es la suma de las capacidades de los contenedores de ese punto). Cada ruta tiene asignado un camión y un equipo humano. Cada equipo humano está formado por recolectores y conductores y ninguno de ellos puede superar las 38 horas de trabajo semanales. Las rutas tienen forma de ramillete porque suelen constar de un área central con una alta frecuencia de recogida (el núcleo del ramillete) y otras con una frecuencia de recogida más baja (las ramas). Esto quiere decir que las rutas, aunque suelen tener la misma periodicidad, cada una tiene sus propios días de ejecución, de forma que los puntos con alta frecuencia de recogida son puntos de intersección de varias rutas y forman el núcleo del ramillete, siendo los puntos de baja frecuencia los que no forman intersección de varias rutas.

Uno de los principales problemas de la planificación actual es que las rutas tienen en general diferente duración, debido básicamente a la forma en que han sido diseñadas, por concejos y bajo demanda (aunque algunas rutas cubren más de un concejo si las áreas son pequeñas). La consecuencia inmediata de ello es que existen diferencias de uso de los camiones y diferencias en las horas de trabajo de los recolectores y conductores. Además, otros factores que dificultan el proceso de recogida son las condiciones climáticas adversas o las posibles demoras en la recogida en empresas privadas por el tiempo empleado en el acceso a los contenedores que tengan en su recinto privado. Otras dificultades son el rango de horas de recogida permitidas, la existencia de vehículos que excedan el peso permitido así como las limitaciones de altura o la dimensión del contenedor en las pequeñas poblaciones. Por otro lado, los trabajadores tienen sus propias preferencias cuando trabajan en pendiente. Por ejemplo, los conductores prefieren subir por una carretera en peores condiciones a cambio de bajar por otra que esté en mejores condiciones y los recolectores prefieren recoger los contenedores cuesta abajo. Otro tema a tener en cuenta es el tiempo de recogida ya que, dependiendo del tipo de camión, éste puede cambiar o el tiempo de descarga en las estaciones de transferencia o el tiempo que tarda el conductor en ir desde el garaje hasta el primer contenedor en la ruta y desde el último contenedor hasta el garaje. También sucede que, por ejemplo, en las



áreas rurales no hay límites de tiempo para la recogida y que en algunos lugares la lateralidad del contenedor no es una característica esencial ya que a veces los contenedores pueden haber sido cambiados. Así mismo, son los gobiernos locales quienes determinan la cantidad de contenedores y la frecuencia de recogida por superficie y población de cada área. Debido a eso, cada contenedor podría tener diferente frecuencia dependiendo del área y podrá variar según la temporada del año (por ejemplo, en verano en las zonas de playa se generan más residuos).

El objetivo de este trabajo es obtener una medida que evalúe la calidad de una planificación teniendo en cuenta, en la medida de lo posible, las restricciones y características del proceso de recogida que se acaba de describir y sirviéndose también del conocimiento de los expertos, para lo cual, nuestra propuesta consiste en utilizar aprendizaje de preferencias. En este marco, el proceso ideal sería disponer de varios pares de planificaciones de recogida de residuos sobre los cuales los expertos indicasen qué miembro de cada par sería, a su juicio, el mejor. Sin embargo, debido a la alta complejidad que presenta la planificación, ni siquiera los expertos serían capaces de decidirse entre los miembros de cada par de planificaciones. Por esta razón, se propone simplificar el problema al nivel de ruta, en lugar de considerar planificaciones completas. Por tanto, se establecerán KPIs que evalúen la calidad de una ruta en vez de la calidad de una planificación, aunque se verá más adelante que también permitirán evaluar una planificación. La descripción y el diseño de estos KPIs se detalla en la sección III-A. Una dificultad acaecida de este planteamiento es la necesidad de disponer de un número suficiente de pares de rutas sobre los cuales los expertos puedan decantarse por un miembro de cada par. Sin embargo, las únicas rutas disponibles son precisamente las que forman la planificación actual, que no son suficientes y, por tanto, surge la necesidad de crear rutas alternativas. Esta tarea se explica en la sección III-B.

A. Diseño de evaluación de indicadores de calidad (KPIs) para una ruta de recogida

En esta sección se proponen varios KPIs que permiten evaluar la calidad de una ruta recogiendo, en la medida de lo posible, los factores más relevantes para los expertos en recogida cuando estos diseñan una ruta. La mayoría de los KPIs por los que los expertos se inclinan están relacionados con las propiedades geográficas y se detallan y discuten a continuación.

- 1) Distancia recorrida: Uno de los KPIs más básicos que proponen los expertos es la distancia recorrida. Para obtener su valor, se considera $\{p_1, p_2, ..., p_n\}$ un conjunto de puntos de recogida de una ruta cuyo garaje inicial y final sea g y se obtiene a partir de otras distancias (D) más pequeñas en el mapa, a saber:
 - i) Distancia desde el garaje g al primer punto de recogida p_1 , $D(g, p_1)$, y desde el último punto de recogida p_n al garaje g, $D(p_n, g)$.
- ii) Distancia entre puntos de recogida calculada como la suma de cada distancia entre el punto de recogida actual

 p_i y el siguiente punto de recogida $p_{i+1},$ es decir, $D(p_1,p_n)=\sum_{i=1}^{n-1}D(p_i,p_{i+1})$

Por lo tanto, la distancia total de viaje de una ruta es la suma de dichas distancias.

$$D(g,g) = D(g,p_1) + D(p_1,p_n) + D(p_n,g)$$
(1)

- 2) Tiempo empleado: El tiempo empleado es uno de los KPIs más importantes que tenemos que tener en cuenta, debido al tiempo máximo de trabajo de los trabajadores y de uso de los camiones, así como a las restricciones existentes en los horarios de recogida. Debido a que solamente se dispone del tiempo empleado en las rutas diseñadas localmente por los expertos, la obtención de dicho KPI es más compleja de lo que parece, de hecho, no es posible calcularlo con la información facilitada. Por lo tanto, a partir de la información local disponible, se propone obtener un modelo de regresión que sea capaz de estimar este tiempo. En esta línea, y para facilitar el proceso de aprendizaje, se propone dividir el tiempo en dos partes:
 - i) Tiempo transcurrido desde el garaje g al primer punto de recogida p_1 y desde el último punto de recogida p_n al garaje g. El sistema de regresión se alimenta con la distancia y el tiempo de cada uno de estos trayectos. El resultado es una función de regresión T_g que estima el tiempo transcurrido en los tramos de la ruta que involucran el garaje.
- ii) Tiempo transcurrido entre los puntos de recogida (distancia entre el primer punto p_1 y el último punto p_n). En este caso se usa el número de puntos de recogida y el tiempo para alimentar el sistema de regresión y así obtener otra función de regresión T_p .

Una vez que están disponibles las dos funciones de regresión T_g y T_p , el tiempo de predicción utilizado en una determinada ruta será la suma de tres partes: i) del garaje g hasta el primer punto de recogida p_1 que utiliza T_g , ii) del primer punto de recogida p_1 hasta el último punto de recogida p_n usando T_p y finalmente iii) del último punto de recogida p_n al garaje g utilizando T_g nuevamente. Por lo tanto, el tiempo total del trayecto de una ruta es la suma de los tiempos anteriores:

$$T(g,g) = T_g(g,p_1) + T_p(p_1,p_n) + T_g(p_n,g)$$
 (2)

Una casuística que puede darse es que el tiempo predicho sea menor que el real, en cuyo caso se superaría el tiempo de turno de trabajo. Para poder evitar este comportamiento, se propone aplicar un factor de corrección, el cuál solo podrá calcularse a partir de las rutas disponibles, que son las rutas de la planificación actual diseñadas localmente por el experto. Con este propósito, se evalúa la diferencia entre los valores reales y predichos y se supone que la muestra resultante debe seguir una distribución normal. El valor de corrección será el valor para el cual la diferencia es positiva a cierto nivel significativo. Por contra, si el tiempo predicho es mayor, no presenta ningún problema, ya que el tiempo de turno de trabajo se respetaría.



3) Altitud acumulada: Otro factor que los expertos consideraron relevante es el relieve del terreno. Esto es así porque, por ejemplo, un terreno escarpado complica el acceso de los camiones a los contenedores. Además, no es igual de costoso que un camión vaya cuesta arriba con una mayor carga que vaya cuesta abajo, no solo por mantener el buen estado de los camiones, sino por el consumo de combustible. Por ello, el KPI que se propone para considerar el relieve del terreno es la altitud acumulada. Se puede pensar en utilizar el porcentaje de pendiente como un KPI, sin embargo, los expertos descartaron esta opción debido a que no contempla la distinción entre subir un tramo largo con pendiente más baja o subir un tramo corto con pendiente más alta.

A partir de un conjunto de puntos de la ruta 2 , $t_1,...,t_m$ se obtienen sus respectivas altitudes $A(t_1),...,A(t_m)$. El KPI de altitud acumulada para una ruta que comienza en un garaje g y termina en el mismo garaje se evalúa de la siguiente manera.

$$A(g,g) = \sum_{i=1}^{m-1} \max(0; A(t_{i+1}) - A(t_i))$$
 (3)

Este KPI solo contempla la diferencia de altura en los tramos de subida, pues al tratarse de rutas circulares, la diferencia de altura en los tramos de bajada es idéntico al correspondiente a los tramos de subida.

4) Tipo de carretera: El tipo de carretera es también un KPI relevante para los expertos, ya que conducir por una autopista difiere considerablemente con respecto a conducir por carreteras locales. Por ejemplo, el consumo de combustible, la comodidad o el tiempo que dura el trayecto son aspectos que cambian según el tipo de la carretera. Los tipos de carreteras se clasifican según su relevancia (de mayor a menor) como autopista, autovía, carreteras regionales, carreteras locales y otras (avenida, calle, camino, plaza...).

Para tener en cuenta estos tipos de carretera, se consideran dos KPIs adicionales, a nombrar, la distancia por carreteras menos importantes (D_b) , que incluye plazas, calles, caminos, avenidas y carreteras locales, entre otros y la distancia por carreteras menos importantes y de importancia intermedia (D_i) , que incluye, además de las anteriores, carreteras regionales. Por lo tanto, $D_b(g,g)$ y $D_i(g,g)$ se calculan para una ruta.

5) Carga del camión: La carga del camión es otro aspecto por el cual los expertos mostraron gran interés ya que probaron estadísticamente que conducir muchos kilómetros con una carga pesada afecta en gran medida al consumo de combustible y al desgaste del camión. Por ello, si la recogida de residuos se realiza en el trayecto de ida y luego se regresa al garaje se estaría cargando con la carga durante todo el trayecto de vuelta. Por este motivo, parece preferible ir en primer lugar al punto de recogida más alejado de la ruta sin carga en el camión y regresar recogiendo los residuos.

No es fácil indicar de forma directa en un KPI la carga del camión, ya que el consumo de combustible o el desgaste del camión son prácticamente imposibles de estimar. Por esta

TABLE I RESUMEN DE KPIS CONSIDERADOS PARA EVALUAR UNA RUTA

Tramo/KPI	Distancia	Tiempo	Altitud	Distancia carr. poco importantes	Distancia carr. poco imp. + imp intermedia	Carga
Primer tramo.	$D(g, p_1)$	$T_g(g, p_1)$	$A(g, p_1)$	$D_b(g, p_1)$	$D_i(g, p_1)$	-
Segundo tramo.	$D(p_1, p_n)$	$T_p(p_1, p_n)$	$A(p_1, p_n)$	$D_b(p_1, p_n)$	$D_i(p_1, p_n)$	-
Tercer tramo.	$D(p_n, g)$	$T_g(p_n, g)$	$A(p_n, g)$	$D_b(p_n, g)$	$D_i(p_n, g)$	-
Ruta completa.	D(g,g)	T(g,g)	A(g,g)	$D_b(g, g)$	$D_i(g,g)$	C(g,g)

razón, este factor se tendrá en cuenta no a través de la propia carga del camión, sino con una medida relacionada con el consumo de combustible (ni siquiera el propio consumo de combustible). Nuestra propuesta para considerar este factor C consiste en suponer que el punto de recogida actual es el último punto de recogida de la ruta. Por lo tanto, si D_q es la distancia desde el punto de recogida actual p_i hasta el garaje final g y L es la carga del camión de los residuos recogidos desde el garaje origen g hasta el punto de recogida actual p_i , el KPI para el punto de recogida actual p_i será el producto de la carga de residuos y la distancia restante que lleva la carga hasta el final de la ruta, es decir, $C(p_i) = L(p_i) \cdot D_q(p_i)$. La principal dificultad llegado este punto es que no se dispone ni del volumen ni del peso de los residuos que se recogen, por lo que podría parecer que la solución más directa consistiría en estimarlo. Sin embargo, los expertos descartaron esta opción, ya que argumentaron que el ruido que puede conllevar la estimación no compensaría la posible mejora del KPI. En consecuencia, el experto recomendó establecer $L(p_i) = 1$ para todos los puntos de recogida, dando lugar a una versión más simplificada del KPI, $C(p_i) = D_q(p_i)$. Finalmente, la carga del camión de toda la ruta se considera a través de la media de todos los puntos de recogida.

$$C(g,g) = \frac{\sum_{i=1}^{n} C(p_i)}{n}$$
(4)

El numerador está relacionado proporcionalmente con el consumo de combustible. Sin embargo, debido a que en general las rutas tienen un número diferente de puntos de recogida, se propone promediar precisamente por el número de puntos de recogida con el fin de hacer las rutas comparables.

Consideraciones finales: Dada la existencia de tres tramos claramente diferentes en cada ruta (garaje-primer punto de recogida, primer-último punto de recogida y último punto de recogida-garaje), se obtuvieron los KPIs tanto para la ruta completa (21 KPIs) como para cada uno de los tres tramos (el KPI relativo a la carga del camión únicamente se obtiene para la ruta completa). La Tabla I muestra un resumen de los KPIs que se han obtenido. Finalmente, mencionar que los KPIs diseñados, no solo permiten describir una ruta, si no también una planificación.

B. Creación de pares de preferencias

Como se mencionó anteriormente, solamente se dispone de rutas diseñadas de forma local de un determinado área. Sin embargo, con el fin de poder aplicar un algoritmo de aprendizaje de preferencias, es necesario construir rutas alternativas

²Estos puntos incluyen los puntos de recogida y otros puntos del recorrido del camión para conseguir una mejor estimación de la altitud.



que sirvan de comparación con las existentes. En esta línea, para cada ruta existente, se obtienen otras rutas con pequeñas variaciones aleatorias y se calculan los KPIs para todas ellas, tanto para la existente como para las obtenidas a partir de ella. Si los valores de todos los KPIs de la ruta original son mejores que los de una de las rutas obtenidas a partir de ella, entonces se tomará automáticamente como mejor ruta la ruta original. En caso contrario, se tomará como mejor ruta la obtenida a partir de ella. Por tanto, los pares de rutas (para cada ruta, se generó una única ruta con variaciones aleatorias) se dividen en tres conjuntos:

- i) Los pares de rutas donde todos los KPIs de la ruta existente son mejores que los de la ruta obtenida a partir de ella.
- ii) Los pares de rutas donde todos los KPIs de la ruta existente son peores que los de la ruta obtenida a partir de ella.
- iii) Los pares de rutas con algunos KPIs mejores en la ruta existente y el resto de KPIs mejores para la ruta obtenida a partir de ella.

De las 64 rutas ya existentes, solo hubo un par de rutas que cumplió la condición i) y otro par que cumplió la condición ii), siendo los 62 pares restantes del grupo de pares de rutas los que cumplen la condición iii). La decisión para los pares de rutas del grupo i) y ii) es obvia. Sin embargo, los pares de rutas que cumplen iii) se mostraron al experto para que manifestase sus preferencias.

Una vez que están disponibles los pares de rutas y establecida la preferencia por parte del experto, se lleva a cabo el proceso de aprendizaje. A este respecto, se prefiere una ruta con KPIs x a una ruta con KPIs y si la función de evaluación es mayor para x que para y.

$$x \succ y \Rightarrow f(x) > f(y) \Rightarrow f(x) - f(y) > 0$$
 (5)

En nuestro caso, se necesitaría que f sea lineal, es decir, que se cumpla que f(x) - f(y) = f(x - y). Y por lo tanto:

$$x \succ y \Rightarrow f(x - y) > 0 \tag{6}$$

En nuestro caso, la función f sería la función objetivo que pondere los KPIs y sirva para evaluar una ruta, que como se comentó anteriormente, dado el diseño que se ha hecho de los KPIs, también servirá para evaluar una planificación. Cada par de rutas se transforma en un par de ejemplos que alimentará el sistema que genere dicha función. Los atributos x_i e y_i serían el i-ésimo KPI para las rutas x e y respectivamente y las clases serían +1 y -1, dependiendo de si se prefiere la primera ruta del par o la segunda. Si $x \succ y$, el par de ejemplos generados serían $(x_1-y_1)...(x_n-y_n) \to +1$ (positivo) y $(y_1-y_1)...(y_n-y_n) \to +1$ $(x_1)...(y_n-x_n) \rightarrow -1$ (negativo). A partir de este conjunto de ejemplos, se generará un modelo de clasificación lineal, que permitirá inducir la función objetivo f. Particularmente, el valor numérico obtenido por el modelo lineal aplicado a una ruta o planificación nos proporcionará la posición en el ranking de dicha ruta o planificación.

IV. EXPERIMENTOS

En esta sección se describen los experimentos realizados para obtener sendos modelos i) de regresión que estime el tiempo empleado en una ruta y ii) de ranking para evaluar la calidad de la ruta. Sin embargo, previamente, se discute sobre los sistemas de información geográfica empleados para el cálculo de los KPIs.

A. Sistemas de información geográfica para obtener los KPIs

Los KPIs se calcularon mediante un sistema de información geográfica (GIS) llamado *Open Source Routing Machine* (OSRM) (https://map.project-osrm.org/) y basado en *OpenStreetMap* (www.openstreetmap.org). Hay una variedad de proyectos que han utilizado OSRM³ y OSM⁴.

A pesar de que OSRM no incluye datos de altitud y ofrece información bastante incompleta en algunas áreas de baja densidad de población porque son los usuarios los que incorporan los datos, es una buena opción ya que además de no tener coste alguno, su documentación y su comunidad es muy extensa. Otras alternativas a OSMR son Google Maps (https://www. google.com/maps) que incorpora datos de elevación e información geográfica muy completa, Mapbox (https://www. mapbox.com/) que está equipado con un módulo de enrutamiento orientado al tráfico, GraphHopper (https://www. graphhopper.com/) que dispone de una API de optimización de rutas y también de datos de elevación, Mapzen Valhalla (https://mapzen.com/) que además de permitir diferentes tipos de vehículos, también calcula la forma más eficiente de visitar múltiples destinos y tiene datos de elevación. Sin embargo, todos presentan la desventaja de no ser libres para una elevada cantidad de solicitudes a sus servidores.

Por otro lado, para paliar la carencia de OSRM de proporcionar datos de altitud, proponemos utilizar el modelo de elevación global denominado GMTED2010 (https://lta.cr.usgs.gov/GMTED2010), debido a que el número de solicitudes no está limitado. Este sistema fue desarrollado por el Servicio Geológico de los EE. UU. (USGS) y la Agencia Nacional de Inteligencia Geoespacial (NGA). Así, OSRM proporciona un conjunto de puntos de un tramo que alimentan al sistema GMTED2010 para obtener la altitud de los mismos.

B. Regresión

Los modelos T_g y T_p se crearon utilizando la librería Caret4 (classification and regression training) en R. Se compararon los métodos Linear Regression (LiR), Bagged CART (BC), Bayesian Generalized (BG), Boosted Tree (BT), Random Forest (RF) y Bayesian Ridge Regression (BRR). Los valores de los parámetros fueron maxdepth=2 y mstop=50 para BT y mtry=1 para RF. La Tabla II muestra el error cuadrático medio (RMSE, Root Mean Square Error) y su desviación estándar (RMSE SD) obtenidos en validación cruzada con 10

³ I Bike Cph (https://www.ibikecph.dk/en), Cycle.Travel (http://cycle.travel/) y MAPS.ME (https://maps.me/)

⁴Waymarked Trails (http://www.waymarkedtrails.org/), Open Topo Map (https://opentopomap.org/), MTBmap (https://openmtbmap.org/es/) o Thunderforest (http://www.thunderforest.com/)



TABLE II ${\rm RMSE~Y~RMSE~SD~para~los~modelos~de~regresi\'on} \ T_g \ {\rm Y} \ T_p$

	Mo	delo T_g	Modelo T_p		
Algoritmo	RMSE	RMSE SD	RMSE	RMSE SD	
LiR	489,65	82,18	525,72	163,41	
BC	530,91	83,69	693,10	285,93	
BG	489,65	82,18	525,72	163,41	
BT	498,67	75,34	665,98	273,68	
RF	542,87	78,55	521,35	156,71	
BRR	489,50	83,00	520,70	167,14	

TABLE III C-Index de los atributos

Algoritmo	5KPIs	6KPIs	15KPIs	16KPIs	21KPIs
SVM	0,4857	0,7429	0,7714	0,8000	0,7714
LoR	0,7714	0,8857	0,7714	0,8000	0,8000

folds y 3 repeticiones, siendo BRR el método que mejores resultados ofrece para ambos modelos T_g y T_p .

C. Preferencias

En el aprendizaje de preferencias se utilizó regresión logística (LoR, *Logistic Regression*) y máquinas de vectores soporte (SVM, *Support Vector Machines*) [9] con *kernel lineal*. Se trata de sendos sistemas de clasificación que proporcionan una puntuación que sirve como valor de ordenación y que han sido aplicados con anterioridad en otros ámbitos [5], [6] o [8]. En el ámbito que nos ocupa, se varió el número de atributos (KPIs): 5 KPIs (KPIs de la ruta completa sin la carga del camión), 6 KPIs (KPIs de la ruta completa), 15 KPIs (5 KPIs por cada uno de los tres tramos), 16 KPIs (KPIs por tramos junto con la carga del camión) y 21 KPIs (todos los KPIs, los 5 KPIs de cada tramo junto con los 6 KPIs de la ruta completa).

Como medida de evaluación del modelo se utilizó el Cindex, que se estimó mediante validación cruzada por bloques. Cada bloque está formado por una ruta y su variante modificada aleatoriamente. Para cada bloque se calculó el CIndex y finalmente se promediaron los C-Index de todos los bloques. C-index es la probabilidad de concordancia entre los valores predichos y los valores reales, es decir, $C-Index=\frac{1}{|\epsilon|}\sum_{\epsilon_{ij}}1_{f(x_i)< f(x_j)}.$

La tabla III muestra el C-Index de todas las variantes, siendo LoR mejor o igual que SVM. El mejor resultado se obtiene cuando se considera la carga del camión, resultado, en cierta medida, esperable, ya que los expertos auguraban la relevancia de este factor. Sin embargo, la separación en tramos con recogida de contenedores y tramos de salida y llegada al garaje no resulta adecuada, puesto que el mejor resultado se obtiene cuando no se realiza dicha separación. Es, por tanto, el uso de 6 KPIs la elección preferible.

V. CONCLUSIONES Y TRABAJO FUTURO

En este artículo se propone una medida que evalúe la calidad de una ruta o planificación de recogida de residuos de la empresa COGERSA. Para ello se ha tenido en cuenta, en la medida de lo posible, las restricciones y características del

proceso que los expertos nos han proporcionado. Se diseñó una serie de KPIs que describen las rutas y se aplicó un sistema de aprendizaje de preferencias para obtener una función objetivo que capturase el conocimiento de los expertos. Para ello, fue necesario crear rutas con pequeñas variaciones aleatorias para que los expertos pudiesen decidir qué ruta preferían (su ruta o la variada aleatoriamente). También fue necesario inducir dos modelos de regresión para poder estimar uno de los principales KPIs de gran interés para los expertos, el tiempo de recorrido de una ruta. Las rutas fueron divididas en tres tramos claramente diferenciados (garaje a primer punto de recogida, primer a último punto de recogida y último punto de recogida a garaje) y los KPIs también fueron obtenidos para dichos tramos. Sin embargo, la meior función obietivo se obtuvo cuando se consideran exclusivamente los KPIs de la ruta completa. Además se puede concluir que la carga del camión es uno de los factores relevantes en la recogida, algo que los expertos ya intuían. Como trabajo futuro se podrían incorporar nuevos KPIs utilizando un sistema de red vial o establecer cambios en las rutas si las carreteras estuvieran cerca de áreas con problemas de tráfico.

AGRADECIMIENTOS

Esta investigación ha sido parcialmente financiada por el Ministerio de Economía y Competitividad español a través del proyecto TIN2015-65069 y por el Instituto de Desarrollo Económico del Principado de Asturias (IDEPA) a través del proyecto RDI *Smart Waste Collection* (SWC), desarrollado por el consorcio COGERSA, SADIM S.A., S.M.E-grupo HUNOSA y ABAMobile (IDE/2015/000863, IDE/2015/000864 e IDE/2015/000865).

REFERENCIAS

- [1] P. Toth and D. Vigo, "The vehicle routing problem, ser. siam monographs on discrete mathematics and applications," *Society for Industrial and Applied Mathematics*, 2002.
- [2] A. L. Samuel, "Some studies in machine learning using the game of checkers," *IBM Journal of Research and Development*, vol. 3, no. 3, pp. 210–229, July 1959.
- [3] M. Kubat, R. C. Holte, and S. Matwin, "Machine learning for the detection of oil spills in satellite radar images," *Machine learning*, vol. 30, no. 2-3, pp. 195–215, 1998.
- [4] T. Joachims, "Optimizing search engines using clickthrough data," in Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining. ACM, 2002, pp. 133–142.
- [5] A. Bahamonde, G. F. Bayón, J. Díez, J. R. Quevedo, O. Luaces, J. J. Del Coz, J. Alonso, and F. Goyache, "Feature subset selection for learning preferences: a case study," in *Proceedings of the twenty-first international conference on Machine learning*. ACM, 2004, p. 7.
- [6] A. Bahamonde, J. Díez, J. R. Quevedo, O. Luaces, and J. J. del Coz, "How to learn consumer preferences from the analysis of sensory data by means of support vector machines (svm)," *Trends in food science & technology*, vol. 18, no. 1, pp. 20–28, 2007.
- [7] F. J. García-Peñalvo, J. Cruz-Benito, M. Martín-González, A. Vázquez-Ingelmo, J. C. Sánchez-Prieto, and R. Therón, "Proposing a machine learning approach to analyze and predict employment and its factors," *International Journal of Interactive Multimedia and Artificial Intelligence*, no. In Press, 2018.
- [8] J. Quevedo and E. Montañés, "Obtaining rubric weights for assessments by more than one lecturer using a pairwise learning model." *International Working Group on Educational Data Mining*, 2009.
- [9] D. Fradkin and I. Muchnik, "Support vector machines for classification," DIMACS Series in Discrete Mathematics and Theoretical Computer Science, vol. 70, pp. 13–20, 2006.



Data science for building energy management: A review

M. Molina-Solana*, M. Ros[†], M.D. Ruiz[†], J. Gómez-Romero[†] and M.J. Martin-Bautista[†]

*Data Science Institute, Imperial College London, United Kingdom

Email: m.molina-solana@imperial.ac.uk

[†]Department of Computer Science and Artificial Intelligence, Universidad de Granada, Spain

Email: marosiz@ugr.es, mdruiz@decsai.ugr.es, jgomez@decsai.ugr.es, mbautis@decsai.ugr.es

Summary of published paper: M. Molina-Solana, M. Ros, M. Dolores Ruiz, J. Gómez-Romero, M.J. Martin-Bautista, *Data science for building energy management: A review*, **Renewable and Sustainable Energy Reviews**, Volume 70, 2017, Pages 598-609, ISSN 1364-0321, doi: 10.1016/j.rser.2016.11.132. IF: 9.184. (original source)

Abstract—The energy consumption of residential and commercial buildings has risen steadily in recent years, with expected energy loads, transportation, storage and user behaviour influencing the quantity and quality of the energy consumed daily in buildings. Technology is now available that can accurately monitor, collect, and store the huge amount of data involved in this process, as well as analyzing and exploiting such data in meaningful ways. Our paper [1] reviewed how Data Science has been applied to address the most difficult problems faced by practitioners in the field of Building Energy Management. It also discussed the challenges and opportunities that will arise with the advent of fully connected devices and new data processing technologies.

I. INTRODUCTION

Residential and commercial buildings are currently responsible for up to 40% of the energy consumption in the world [2]. Increasing energy efficiency is a two-fold process. Not only does it involve the use of affordable energy sources, but also the improvement of current energy management procedures and infrastructures. The latter includes the optimization of energy generation and transportation based on user demand [3]. In this regard, computer-aided approaches have recently come into the spotlight. In the area of building energy management, Data Science is now used to address problems in different areas, ranging from energy demand prediction to operation optimization and energy fraud detection.

Our paper [1] analyzes the application of Data Science methods to these problems. Although there are other reviews on automatic techniques for building efficiency assessment [4], [5] and classification methods for load and energy consumption prediction [6], this work examined and discussed a broader set of data science techniques and their applications to the different aspects of building energy management. We present here a brief summary of the most relevant techniques identified by our study, some reflections on the possible evolution of the area in the near future and the main conclusions of the work.

II. APPLICATIONS OF DATA SCIENCE FOR BUILDING ENERGY MANAGEMENT

Prediction of building energy load. Energy demand, or energy load, refers to the amount of energy required at a certain time period. Detecting building load patterns can be complex because of the number of interrelated factors. In the literature, we can find different proposals for customer profiling using unsupervised learning, e.g. clustering and association rules, and classification models, such as decision trees. For peak demand anticipation, anomaly detection techniques have been prevalent. Users' behavior and their impact in energy consumption has deserved special attention, and there are some works aiming at activity recognition for automatic energy management (heating/cooling, lighting) and load shifting.

Building operation. Operational data acquired by the building energy management system can be analyzed and exploited to extract patterns describing building operation. In most cases, these patterns are in the form of IF-THEN rules, which can help to generate recommendations for control strategies. Decision trees and association rules have been mostly used in this regard. Similarly, other studies have focused on the improvement of specific components of the building by investigating the relations between control settings and energy usage; e.g. by using regression and neural networks.

Analysis of infrastructures. The latest energy efficiency regulations have fostered the study of architectural aspects related to energy use of new and existing buildings. Clustering algorithms have been applied to discover non-obvious factors of energy loss in building infrastructures. Similarly, classification methods have been applied to estimate relevant indicators of thermal behavior and to support decision-making for retroffiting. Some of these works consider time series analysis to enhance the operation of the infrastructures by extracting trends and episodic relationships.

Economic analysis of electric consumption Numerous companies have resorted to Data Science in an effort to discover and understand how and when their customers use energy. The techniques traditionally used for this task are classification—to identify common consumption categories—, clustering—for segmenting buildings by their use of the energy—, and pattern analysis —mostly by means of association rules.



Streaming data processing has been also considered for realtime analysis and summarization of energy consumption data.

Energy fraud detection Sometimes, energy consumption and services are not appropriately billed because of failures in the measurement equipment. Such failures can either be accidental or the product of fraudulent manipulation. These deviations are commonly referred to as non-technical losses (NTLs), and different techniques have been successfully applied to distinguish legit and fraudulent operation; e.g. tree-based classification, expert systems, association rule extraction and anomaly detection.

III. DISCUSSION

As extensively discussed in our original paper, the techniques that enable an easy visualization of results, such as classification methods or association rules, have been widely used because they are intuitive and easy to understand. This sometimes leads to a sub-optimal selection of techniques for specific problems (e.g. tree-based classification is the most used method by large), or even to a misuse of the techniques (e.g. clustering instead of classification despite the availability of labelled data). In general, the best results have been achieved by using ensambles. Less used techniques often involve processing streaming data, which are more difficult to process with out-of-the-box algorithms.

As a matter of fact, our revision found that the most frequently used data science algorithms in the energy field are those found in commercial toolboxes, such as *Intelligent Miner*, *SPSS*, *Clementine*, *RapidMiner* and *SAS*. Open platforms, such as *WEKA* and *KNIME*, and programming frameworks, such as *Matlab*, *R* or *Python* are not very popular, because they require specific technical skills and knowledge of the underlying algorithms. Still, they would deserve more attention from the community. We also believe that it is necessary to incorporate to building energy management solutions capabilities for managing big data, particularly by relying on the Apache Spark/Hadoop ecosystem.

IV. CURRENT TRENDS AND FUTURE CHALLENGES

Smart metering and Internet of Things. Smart metering is the continuous monitoring of energy consumption with a view to gaining a better understanding of the energy consumption, generation, and transportation stages. As a result, bills are no longer an aggregated value of energy consumption over a long period of time; they are obtained from real-time measurements. This also enables users to better understand their own energy behavior, which can help to reduce energy waste, and encourages users to modify underperforming habits. It is expected that smart meters, as well as other appliances, will soon be connected to the Internet of Things, and equipped with additional intelligent features. At the same time, device hyperconnection brings security and privacy concerns: a hacker could remotely control the devices and get private details of a home (number of occupants, daily routines, etc.)

Big Data and Cloud Computing. The huge amount of data generated by building energy equipment can be exploited to increase energy efficiency, and particularly, smart meters data. This information requires smarter processing, as well as larger and more flexible computational infrastructures. Cloud computing, offering flexible and scalable computational resources, can help to implement Big Data solutions for energy management. It is thus not surprising that large technology corporations are taking an interest in this field, either for the development of energy management solutions for the industry (e.g. Siemens) or to improve their internal energy management procedures (e.g. Google's data centers).

Privacy and security issues. New technological advances in massive data processing naturally lead to security and privacy issues. Therefore, it is necessary to develop mechanisms that ensure that the information remains under control according to the legal framework (i.e. the General Data Protection Regulation) and ethical principles. A first step has already been taken by the European Commission regarding smart grids and smart metering in their "Recommendation on the Data Protection Impact Assessment Template for smart grid and smart metering systems", which provides guidelines on how to support the security of the implementation of smart grids and smart metering by data controllers.

V. Conclusion

Our paper reviewed recent developments in Data Science and their influence on Building Energy Management. We examined the usefulness of data science techniques aimed at improving building energy efficiency. Given the progress and the challenges in this area, it is evident that data science techniques will play a key role in the near future.

ACKNOWLEDGMENT

This work was supported by the University of Granada under the Young Researchers Fellowships Programme (No. P9-2014-ING); the Spanish Ministry for Economy and Competitiveness under the project grant TIN2015-64776-C3-1-R; and the European Union under the project grant Energy IN TIME EeB.NMP.2013-4 (No. 608981).

REFERENCES

- M. Molina-Solana, M. Ros, M. D. Ruiz, J. Gómez-Romero, and M. J. Martín-Bautista, "Data Science for Building Energy Management: A Review," *Renewable and Sustainable Energy Reviews*, vol. 70, pp. 598– 609, 2017.
- [2] WBCSD, "Transforming the market: Energy efficiency in buildings," The World Business Council for Sustainable Development, Tech. Rep., April 2009. [Online]. Available: http://www.wbcsd.org/transformingthemarketeeb.aspx
- [3] H. Allcott and S. Mullainathan, "Behavior and energy policy," Science, vol. 327, no. 5970, pp. 1204–1205, 2010.
- [4] Z. Li, Y. Han, and P. Xu, "Methods for benchmarking building energy consumption against its past or intended performance: An overview," *Applied Energy*, vol. 124, pp. 325–334, 2014.
- [5] T. Nikolaou, D. Kolokotsa, and G. Stavrakakis, "Review on methodologies for energy benchmarking, rating and classification of buildings," *Advances in Building Energy Research*, vol. 5, no. 1, pp. 53–70, 2011.
- [6] K. Zhou, S. Yang, and C. Shen, "A review of electric load classification in smart grid environment," *Renewable and Sustainable Energy Reviews*, vol. 24, pp. 103–110, 2013.



Inteligencia Artificial para la Inteligencia Urbana

Sistema de Ayuda a la Decisión para la predicción de la vulnerabilidad social

Francisco Javier Abarca-Alvarez

Departamento de Urbanística y Ordenación del Territorio
Universidad de Granada
Granada, España
fcoabarca@ugr.es

Francisco Sergio Campos-Sánchez

Departamento de Urbanística y Ordenación del Territorio

Universidad de Granada

Granada, España

scampos@ugr.es

Resumen— La vulnerabilidad social desde un punto de vista socio ambiental se enfoca en la identificación de grupos desfavorecidos o vulnerables y de las condiciones de los entornos en los que habita, tratando de determinar los factores que explican la dificultad para afrontar situaciones de desventaja social. Por su complejidad, ligada a la multidimensionalidad, no siempre es sencillo identificar los estratos sociales y urbanos afectados. La investigación pretende evaluar la conexión entre ciertas dimensiones de la vulnerabilidad social y su contexto residencial, creando un Sistema de Ayuda a la Decisión (DSS), útil para la planificación de acciones sociales y urbanas. Para ello se realiza una aproximación holística a la información censal y demográfica habitual en estos estudios, proponiendo la construcción de (i) un modelo de conocimiento basado en Redes Neuronales Artificiales (ANN) del tipo Mapa Auto-organizado (SOM) con el que se identifica y caracteriza un perfil demográfico susceptible de presentar vulnerabilidad social, y (ii) un modelo predictivo de tal perfil basado en reglas a partir de variables residenciales, construido mediante árboles de inferencia condicional. Tales modelos combinados con Sistemas de Información Geográfica (SIG) hacen viable un DSS para la predicción de la Vulnerabilidad Social a partir de información residencial.

Palabras clave— Vulnerabilidad Social; Mapa Autoorganizado; árbol de decisión condicional; DSS; Smart City.

INTRODUCCIÓN

Se suele definir la vulnerabilidad como el potencial de sufrir pérdidas o daños [1], físicos o económicos y localizados en un territorio específico. Cuando se aborda la vulnerabilidad desde un punto de vista social, se enfoca nítidamente en su vertiente humana de aplicación poblacional [2]. En torno al concepto de vulnerabilidad social han aparecido en los últimos años multitud de líneas de trabajo, unas más vinculadas a los riesgos naturales y desastres [3], [4], otras a los factores ambientales [5] y otras más próximas concepto de pobreza [4]. De un enfoque que consideraba fundamentalmente los acontecimientos naturales, se pasó paulatinamente a uno que admitía que los efectos sobre la población estaban condicionados por su capacidad de mitigación [6], en la capacidad de una persona o comunidad para anticipar, resistir y sobreponerse al impacto de acontecimientos imprevistos [7], abriéndose en este sentido a un enfoque que pone en el centro a las personas, siendo aquellas las que tienen o no capacidad de sobreponerse [8] o adaptarse a las vicisitudes, no

exclusivamente vinculadas a los riesgos ambientales, e incluso incorporando una vertiente espacial [9].

La vulnerabilidad social presenta diversos retos como son la multidimensionalidad [4], [5], [10]–[12],[11], [12] o el hecho de que muchas de las variables o dimensiones a evaluar no son directamente observables [10]. Entre las investigaciones que han tratado de identificar indicadores de la vulnerabilidad social destaca el trabajo de Cutter, et al. en el que incorpora como variables del llamado *SoVI*, toda una serie de indicadores como son factores socio-económicos, de edad, indicadores de desarrollo comercial o industrial, desempleo, indicadores de ruralidad, propiedad residencial, nivel de infraestructuras, nivel de rentas, ocupación, acceso a servicios médicos, factores de género, raza y etnia, estructura familiar, nivel educativo, crecimiento vegetativo, dependencia a servicios sociales y presencia de población con necesidades especiales [5].

Con el reto de realizar un Sistema de Ayuda a la Decisión (DSS) en relación a la vulnerabilidad social, se plantea como herramienta necesaria el uso de un Sistema de Información Geográfica (SIG). Tales sistemas han sido usados asiduamente por gobiernos, investigadores y empresas como herramienta de decisión en las que alcanza cierta repercusión e influencia la dimensión espacial [13]. Los SIG surgieron a finales de la década de 1960 desarrollándose especialmente a partir de los 80 [14], y generalizándose su uso a partir de 1990 y especialmente ante el compromiso de convertir tanto a ciudadanos como urbanistas, en actores importantes de la planificación. Es preciso tener presenta que los GIS no siempre han estado preparados para cumplir como un DSS en cuanto que deberían integrar realidades y problemas complejos para el apoyo de determinadas decisiones [15], consolidándose como unos sistemas flexibles y resilientes.

Desde su origen la realidad informacional sobre la que se apoyan estos sistemas ha cambiado rápidamente, proliferando la presencia de datos e información espacial de acceso libre, configurándose el campo de los SIG prácticamente como una disciplina, que algunos llaman GISciencia [16], apoyándose en la idea de una nueva Geografía Cuantitativa, fundamentalmente espacial, tendente a la planificación y gestión. Con el tiempo los SIG han pasado del énfasis en la "S" por los problemas computacionales (60-70s), pasando a dedicarse a la "I" por el interés en la información (80-90s), para a partir de 2000



enfocarse en la "G", ante una necesidad de interpretación geográfica, materializándose en la "sociedad de la información geográfica" y abriendo una nueva etapa para la historia de la Geografía [17]. Es en este punto es cuando singularmente los GIS se aproximan propiamente al concepto DSS.

Frecuentemente esta nueva Geografía Cuantitativa está elevando la granularidad de los datos geográficos hasta el extremo, en una auténtica "n-dimensionalidad" de los datos [18]. En la mayoría de los casos, según Pragya Agarwal y André Skupin, se han enfocado en el análisis estadístico tradicional para resolver problemas de autocorrelación espacial, dejando otros múltiples ámbitos totalmente por explorar. Algunos de esos espacios están siendo abordados por enfoques emergentes como son la Inteligencia Artificial o las Redes Neuronales Artificiales, el aprendizaje automático (Machine Learning) o de forma específica por la Geo-computación. Estas nuevas técnicas y enfoques están propiciando un cambio de paradigma en los DSS, considerándose que en la actualidad pueden ser útiles para la comprensión de la realidad, detección de sus problemas, y en definitiva la formulación de nuevas hipótesis y no solo como instrumento para verificar aquellas previamente establecidas.

Como objetivo principal la investigación se propone evaluar la viabilidad de la construcción de un modelo de vulnerabilidad social, a priori complejo, a partir de un modelo residencial, del que es más sencillo tener información. Para ello se utilizarán técnicas de interpretación de la realidad mediante Inteligencia Artificial y *Machine Learning* apoyados en SIG. De forma específica para la validación de la metodología propuesta se caracterizará la vulnerabilidad social de la población de Andalucía a partir de información residencial en la que reside la misma.

Para alcanzar tal objetivo la investigación se enmarca en los paradigmas de los DSS orientados al conocimiento y orientados a los modelos [19]. El primer paradigma se enfoca en la construcción de un sistema de descubrimiento de conocimiento basado en bases de datos institucionales sobre las cualidades demográficas y sociales de Andalucía (Fase de modelado 1 de la metodología); y en el segundo paradigma (Fase de modelado 2 de la metodología) se enfatiza el acceso, la manipulación y creación de un modelo cuantitativo de la realidad social, orientado a proporcionar apoyo a la decisión, elaborado a partir de la realidad residencial de los territorios en estudio. Los DSS usan datos y parámetros proporcionados por los agentes de decisión para ayudarles a analizar una situación, aunque no tienen por qué ser datos masivos [19]. En nuestro caso el modelo se construye con datos masivos (tanto demográficos como residenciales), pero puede ser usado para la toma de decisiones con una información muy limitada, incluso escasa.

La investigación, tal y como se ha avanzado, consiste en la construcción de dos modelos vinculado con herramientas procedentes de las Tecnologías de la Información [20]:

Descubrimiento de conocimiento y clasificación mediante aprendizaje no supervisado. Los Mapas Auto-organizados (SOM)

En la investigación se recurrirá a técnicas de lo que se viene a conocer como Mapas Auto-organizados, en adelante SOM. Fueron propuestos inicialmente por Teuvo Kohonen [21]–[23]. La metodología SOM es una técnica descubrimiento de conocimiento o de minería de datos consistente en una Red Neuronal Artificial. Procede del campo de conocimiento de la Inteligencia Artificial, habiéndose mostrado muy eficaz v robusta en numerosas disciplinas, presentando diversas capacidades entre las que podemos destacar inicialmente dos: (i) es capaz de mostrar y visualizar la información de partida de forma clara y ordenada, (ii) permite clasificar y por lo tanto etiquetar los sujetos en estudio en clases que no requieren su definición, caracterización o etiquetado nominativo previo (aprendizaje no supervisado). Frente a otras metodologías de descubrimiento de patrones, como por ejemplo el análisis clúster, la metodología SOM, tiene la ventaja de (i) permitir visualizar un gran conjunto de datos estadísticos [24], (ii) mostrar las relaciones topológicas de similitud o de diferencia entre los sujetos en estudio, (iii) ser interpretables gráficamente y (iv) constituir por sí mismo un sistema de conocimiento de ayuda a la decisión para el análisis y visualización de indicadores estadísticos [24].

Mediantes estas técnicas se obtendrá por un lado el etiquetado a modo de clases o perfiles de los diferentes fragmentos de territorio andaluz estudiado, atendiendo al análisis multi-variable de los atributos demográficos y sociales estudiados. Se alcanza asimismo un sistema de análisis e interpretación de las clases obtenidas, facilitado por la metodología SOM, materializado en cartografías temáticas de los diferentes atributos incluidos en la red neuronal y en diferentes tablas y datos estadísticos que permiten conocer las características diferenciadoras de cada perfil. Para facilitar su utilización como parte de un DSS se representan tales clases, y en especial la clase o categoría de vulnerabilidad social mediante GIS.

Construcción de modelos predictivos mediante aprendizaje supervisado. Árboles de decisión

Mediante un proceso de Machine Learning se obtendrán una serie de reglas que permitan predecir las clases o perfiles que se determinaron con el modelo SOM, utilizando para ello únicamente atributos sobre la realidad residencial de los territorios en estudio. Estas variables residenciales no se tuvieron en consideración en la creación y constitución de la red neuronal SOM ni consecuentemente pudieron afectar o correlacionarse en la definición de los perfiles obtenidos por aquella. Se realiza una aproximación al problema de aprendizaje mediante el paradigma "divide y vencerás", que al realizarse sobre un conjunto de instancias independientes, conduce naturalmente a un estilo de representación llamado árbol de decisión [25]. En cada nodo del árbol interviene un atributo en particular, comparándose normalmente cada instancia del atributo con el valor de una constante, y generándose normalmente dos ramas atendiendo a las instancias que cumplen o no tal regla. El árbol supone una representación asequible para interpretar y usar en la



predicción de la realidad demográfica y social de un territorio y consecuentemente útil para la toma de decisiones sobre el mismo, usando para ello una información limitada y generalmente de fácil y económica obtención sobre la realidad residencial del lugar en estudio. Asimismo al evaluar el "valor" de los perfiles alcanzados en la Fase 1, en su caracterización espacial mediante SIG, se verifica la utilidad de la metodología propuesta.

MATERIALES Y MÉTODOS

Metodología de investigación

Para la óptima comprensión y para la obtención de los mejores resultados del DSS se siguen las siguientes fases [26]: (i) información y funciones de procesado, (ii) conjuntos de datos, (iii) modelos, y (iv) representaciones visuales.

1) Información y funciones de procesado:

La información utilizada en la investigación procede del Censo de Población 2001 de Andalucía obtenidos por el Instituto de Estadística y Cartografía de Andalucía (IECA). Sobre esta información se ha realizado una intensa preparación de datos con la integración y limpieza de datos, transformación de atributos mediante la creación de indicadores agregados que sinteticende forma objetiva y compacta las principales cualidades demográficas de los datos originales. Debido a la robustez de los SOM, no es necesario realizar su tipificación o normalización [27] previamente a la agregación e incorporación al modelo.

- a) Instancias: La unidad de territorio sobre la que se obtienen los datos, es la Sección Censal, alcanzándose la totalidad de las 5381 secciones censales de Andalucía, quedando representada la totalidad de la superficie y de población censada en la región andaluza, no realizándose muestreo alguno.
- b) Atributos: De los indicadores de Vulnerabilidad Social "SoVI" [5], se incorporan factores socio económicos, de edad, indicadores de desarrollo comercial o industrial (empleo por sectores), desempleo, indicadores de ruralidad (empleo sector agrario), propiedad residencial, nivel de infraestructuras, nivel de rentas (aunque conectado a nivel de ocupación), ocupación, acceso a servicios médicos, y no se incorporan factores de género, raza y etnia, estructura familiar, nivel educativo, crecimiento vegetativo, dependencia a servicios sociales o presencia de población con necesidades especiales. Los atributos que se han usado en la Fase de modelado 2 están compuestos de variables de la dimensión residencial.

2) Conjuntos de datos:

Se opera inicialmente con dos bases de datos desconectadas: una propia de la Fase de modelado 1, con dimensión principalmente demográfica y social y otra propia para la Fase de modelado 2, basada en la dimensión residencial. El funcionamiento será fundamentalmente independiente, conectándose únicamente tras el Modelado 1 para evaluar cómo se ajustan los perfiles de vulnerabilidad social y para la construcción del árbol de decisión.

3) Modelos:

Tal y como se ha avanzado distinguimos entre dos fases de modelado:

a) Fase de modelado 1: Modelo de clasificación y conocimiento. Entre sus objetivos tenemos por un lado, la clasificación y etiquetado de los datos de la dimensión demográfica y social, tal y como se han identificado anteriormente. En esta fase se usará una red neuronal artificial y específicamente un SOM. Esta metodología en cuanto que no supervisada, permite clasificar (propiamente segmentar) sin atribuir a priori una etiqueta con definiciones y significados previamente atribuidos, siendo útil para reducir la enorme complejidad de los datos [28].

Para facilitar la comprensión de los perfiles obtenidos se caracteriza a cada clúster con sus estadísticos básicos como son la Media, la Desviación Estándar, el Máximo y el Mínimo [29], tratando de conseguir principalmente dos resultados adicionales, i) el factor o variable que es más importante para el efecto y ii) el valor de tal factor [30]. Para el análisis de los perfiles además de la información estadística que los define, son valiosos los Mapas SOM monovariables ya que permiten según la distribución de valores en el mismo, evaluar relaciones y correlaciones entre variables.

Para cumplir con las recomendaciones de la *American Statistical Association* [31], para cada variable y perfil, además de la significación estadística, se calcula su tamaño del efecto [32].

- b) Fase de modelado 2: Modelo de predicción. Para la construcción del modelo que permita predecir la vulnerabilidad, se realiza in árbol de decisión basado en reglas, identificando mediante la representación de condiciones sucesivas, el grado de probabilidad de existir el patrón de vulnerabilidad obtenido en la fase de modelado 1. Para ello se ha realizado la partición de los datos en 70/30 (entrenamiento/prueba); y se han usado los árboles de inferencia condicional, basado en el test de permutación [33], utilizando pruebas no paramétricas como criterios de división de las ramas, no precisando poda de las mismas. Para ello se ha usado el paquete "rpart" del software estadístico R-Project [34], usando como parámetros: división mínima=20, profundidad máxima=2, y cubo mínimo=7.
- 4) Representaciones visuales: Una de las cualidades que presentan las cartografías SOM es la capacidad de representación de la información resultante de un modo relativamente sencillo de comprender, al mostrar una representación bidimensional de las instancias de partida, con la característica de que cada una de ellas tiene por "vecina" la instancia con cualidades más semejantes. En la misma cartografía se suele representar las agrupaciones de las instancias en los distintos perfiles conformados. Esta representación se suele completar con un mapa por cada uno de los atributos o variables que construyeron el mapa SOM. Finalmente se representarán espacialmente tales perfiles mediante GIS y se obtendrán los gráficos de los árboles de decisión.



RESULTADOS

Según la metodología se realizan las tareas propias de los apartados 1) y 2), obteniéndose dos bases de datos independientes. Se puede observar una síntesis descriptiva de tales variables de partida en las 3 primeras columnas de la Tabla 1 para los datos principalmente demográficos y de la

Tabla 1. Variables de las dimensiones demográfica, social, laboral, de los equipamientos y de los servicios. Se muestra el Perfil (4) con rasgos de vulnerabilidad social. conf: Confianza p-valor: ns: p>0.05; *: p<=0.05; ** p<=0.01; ***: p<=0.001. TE:Tamaño del Efecto. +++: Grande positivo; ++:Mediano positivo; +:Pequeño positivo; ---: Grande negativo; --:Mediano negativo; -:Pequeño negativo.

		completa		Perfil 4		
N de instancias (%)	5381	100.00		50		22%
Atributo	Media	DS	Media	DS	conf	TE
2.1_EquipSaludPor1000Hab	1.39	6.16	1.56	2.45	ns	
2.1_EquipEducacionPor1000Hab	1.14	2.36	2.16	3.20	***	+
2.1_EquipBienestarPor1000Hab	0.83	1.68	1.85	3.77	***	++
2.1_EquipCulDepPor1000Hab	0.72	1.47	1.94	3.07	***	+++
2.1_EquipamientosPor1000Hab	4.08	8.31	7.51	7.25	***	+
2.2_%NoAguaCorriente	0.91	2.84	3.16	6.47	***	++
2.2_%Gas	22.77	33.76	12.31	28.29	***	-
2.2_%Telefono	86.96	17.48	63.45	23.69	***	
2.5_%PocaLimpiezaCalles	35.10	19.82	21.23	22.00	***	
2.6_%Delincuencia	25.32	23.67	4.94	10.62	***	
3.1_Poblacion	1367	518.00 4.41	900.20		***	
3.1_EdadMediaPoblacion 3.1 %Nacimientos	38.01		42.74	4.02	***	+++
3.1_%Nacimientos 3.2 PersonasPorEdificio	11.32 14.46	3.21 22.91	9.54 2.43	2.78 3.79	***	
3.2 %Hogares1Adulto	18.80	7.55	27.87	7.37	***	+++
3.2_%Hogares1adultoYMenor	1.83	1.12	1.28	0.92	***	-
3.2 %Hogares2adulto	41.24	6.75	41.01	5.11	ns	
3.2_%Hogares3adulto	18.41	3.36	16.53	3.13	***	
3.2 %Hogares4adulto	19.71	6.64	13.32	4.70	***	
3.2 Hogares	449.20	167.50	340.20	145.70	***	
3.2_HabitantesPorHogar	3.04	0.36	2.62	0.31	***	
3.2 RatioEdifViviendasPorHogar	0.74	0.56	1.42	0.48	***	+++
3.3 %PoblacionArraigada	80.11	9.49	82.19	5.00	***	+
3.3 %PoblacionInmigranteProvincial	3.87	5.81	3.83	3.52	ns	
3.3_%PoblacionInmigranteRegional	1.35	1.28	0.97	1.09	***	-
3.3_%PoblacionInmigranteNacional	1.58	1.33	1.89	1.59	***	+
3.3_%PoblacionInmigranteExtranjero	1.32	2.79	1.13	1.95	*	
3.3_%España	97.92	4.58	98.58	2.68	***	
3.3_%EuropaUE	0.77	2.97	0.82	2.21	ns	
3.3_%EuropaNoUE	0.18	0.56	0.12	0.38	***	
3.3_%AmericaDelNorte	0.05	0.18	0.02	0.08	***	
3.3_%AmericaCentral	0.04	0.09	0.01	0.05	***	-
3.3_%AmericaDelSur	0.41	0.83	0.20	0.47	***	-
3.3_%Asia	0.08	0.34	0.02	0.12	***	
3.3_%Africa	0.54	2.01	0.23	1.05	***	
3.3_%Oceania	0.00	0.02	0.00	0.01	***	
3.3_%Apatridas	0.00	0.01	0.00	0.00	***	
3.4_%TrabajaEnProvincia	6.43	5.48	6.81	4.43	*	
3.4_%TrabajaEnRegion	0.87	1.00	0.98	0.95	**	
3.4_%TrabajaEnEspaña	0.47	0.57	1.00	1.26	***	+++
3.4_%TrabajaOtroPais	0.12	0.29	0.16	0.53	ns	
4.1_%Ocupados	33.19	6.51	27.38	7.11	***	
4.1_%Parados	10.48	5.11	12.95	7.53		+
4.1_%Inactivos	38.02	7.24	43.94	7.25	***	+++
4.2_LocalComercialPor1000Hab	26.90	98.90	19.40	20.90	***	
4.2_OficinaYServiciosPor1000Hab	10.70	44.60	8.10	12.20		
4.2_Industrial1000Hab	3.07	12.11	3.63	7.94	ns **	+
4.2_LocalAgrario1000Hab 4.2_LocalInactivoPor1000Hab	0.65 13.37	6.71	3.14	19.84 29.47	***	+
4.2_LocalinactivoPor1000Hab 4.3 EstadoConstruccionesD	0.40	20.22 0.23	19.63 0.50	0.21		+
4.4 IDH COMBINADO-	0.40	0.23	0.00	0.21		+
4.4 IDH COMBINADO+	0.00	0.00	0.00	0.00	ns	
4.4_IDH_COMBINADO	0.00	0.00	0.00	0.00	***	+
4.5 %AgriculturaGanaderia	4.16	6.06	7.28	5.74	***	++
4.5 %Pesca	0.14	0.59	0.03	0.12	***	
4.5 %Industria	3.81	2.46	2.81	2.18	***	
4.5 %Construccion	4.47	2.44	4.35	2.08	ns	
4.5 %Servicios	20.61	8.12	12.91	4.83	***	
4.5 %Paro	24.09	11.26	31.61	16.40	***	++
4.6_%ViviendaEnPropiedad	82.28	13.30	82.73	10.40	ns	-
4.6 %ViviendasEnAlquiler	9.39	11.29	5.05	5.16	***	

Tabla 2. Variables de la dimensión residencia. Se muestra el Perfil (4) con rasgos de vulnerabilidad social. Téngase en cuenta que esta información no ha intervenido en la constitución del perfil. conf: Confianza p-valor: ns: p>0.05; *: p<=0.05; ** p<=0.01; ****: p<=0.001. TE:Tamaño del Efecto. +++: Grande positivo; +:Mediano positivo; +:Pequeño positivo; ---: Grande negativo; --:Mediano negativo; -:Pequeño negativo.

	Muestra	completa	Perfil 4			
N de instancias (%)	53	81	55	50	10.2	22%
Atributo	Media	DS	Media	DS	conf	TE
2.3_%Garaje	19.03	18.79	16.70	14.07	***	
2.4_%NoAccesible	72.81	30.40	87.94	22.67	***	+
4.3_EdadMediaConstruccionesM	1963	20.00	1943	28.10	***	
4.3_EdadMediaConstruccionesD	23.38	14.79	37.01	14.78	***	+++
4.3_EstadoConstruccionesM	1.16	0.21	1.23	0.20	***	+
5.1_%RuidosExteriores	32.53	18.35	13.15	15.83	***	
5.1_%Contaminacion	19.47	14.83	8.11	11.66	***	
6.1_Altura Media Construcciones M	2.68	1.60	1.70	0.51	***	
6.1_Altura Media Construcciones D	5.46	5.27	1.94	1.34	***	
6.2_EdifViviendas	327.50	292.70	460.10	225.30	***	+
6.2_%Unifamiliares	61.10	33.88	87.48	13.05	***	++
6.2_%UnifamiliaresAgrupadas	21.66	21.86	8.52	8.70	***	
6.2_%UnifamiliaresConLocales	17.04	24.09	3.94	6.38	***	
6.2_%Plurifamiliares	0.20	0.80	0.06	0.20	***	
6.2_%EdifLocalesConAlgunaVivienda	0.80	2.59	0.24	0.74	***	-
6.2_%EdifLocales	8.93	19.87	6.95	7.79	***	
6.2_%EdifAlojamientos	0.08	1.05	0.22	1.79	ns	
6.3_%MalasComunicaciones	13.95	15.95	15.06	20.53	ns	
6.4_%PocasZonasVerdes	48.85	25.97	37.60	31.06	***	-
6.5_% Falta Ase os En VI viendas	1.32	2.95	2.20	5.11	***	+

Tabla 2 para la dimensión residencial. Siguiendo con el apartado 3) de la metodología, se lleva a cabo la Fase de modelado 1 usando para ello 63 variables de la dimensión demográfica, social, laboral, de los equipamientos y de los servicios, obteniéndose los perfiles que caracterizan la realidad demográfica y parte de las dimensiones de vulnerabilidad social.

Se puede observar lo siguiente en el Perfil 4 (Tabla 1): El análisis estadístico desvela que este perfil poblacional presenta una elevada edad media, gran cantidad de hogares con un único ocupante, abundancia de viviendas vacías y con ciertos problemas como carencia de agua corriente en proporción mayor que el resto. Curiosamente la estadística delata que habitan en asentamientos con buenos ratios de equipamientos culturales y de bienestar por población, probablemente derivado del bajo número de habitantes de tales poblaciones y una aceptable distribución de tales funciones. Espacialmente se observa que corresponden con los emplazamientos rurales más aislados y a mayor distancia de las principales ciudades. Comparando este perfil con el Perfil 2, se observa que coincide con una población rural más envejecida, que en muchas ocasiones vive sola, en entornos urbanos con poca población, con poca ocupación de las viviendas y con altos índices de analfabetismo, paro e inactividad. Mediante la representación GIS (Fig. 1), se localiza en este perfil entornos de la Hoya de Baza (Granada), los Campos de Tabernas (Almería), altos de la Sierra de Gádor (Almería), la Sierra de Aracena (Huelva), etc.

A continuación en la Fase de modelado 2 se obtiene el árbol que permite "predecir" cómo identificar el Perfil 4, es decir, se trata de identificar las cualidades residenciales del perfil poblacional con muestras de vulnerabilidad social. En



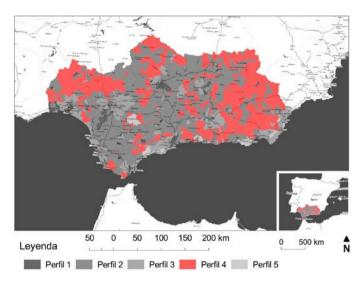


Fig. 1. Representación SIG de la clasificación generada mediante SOM. Se observa el Perfil 4 que coincide con los rasgos de vulnerabilidad.

realidad mediante los árboles de decisión se obtiene la probabilidad de identificar correctamente el Perfil 4 a partir de un número de variables muy reducido (Fig. 2). Finalmente se evalúa el rendimiento del modelo de árbol condicional de clasificación mediante la curva ROC (Fig. 3), obteniéndose un AUC=0.78.

DISCUSIÓN Y CONCLUSIONES

A partir del análisis de las experiencias bibliográficas de aplicación del modelo de clasificación y conocimiento mediante la metodología SOM y corroborado mediante la propia experiencia llevada a cabo, se puede concluir que la metodología SOM es útil para realizar un análisis exploratorio [28], con clasificaciones más potentes y robustas que las técnicas descriptivas tradicionales [35], alcanzándose una comprensión de tales patrones y su distribución espacial [29], explorándose visualmente y validándose eficazmente gracias a las consistentes propiedades geométricas de los resultados de los SOM [36], [37] y permitiendo finalmente identificar, mediante el análisis del tamaño del efecto, un perfil en el

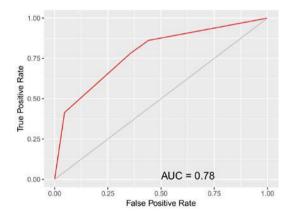


Fig. 3. Curva ROC de rendimiento del modelo Árbol de decición condicional de pertenencia al Perfil 4 de vulnerabilidad social. El Modelo obtiene un área bajo curva (AUC) de 0.78.

territorio andaluz con clara asociación con la vulnerabilidad social. Esta asociación tiene como la utilidad permitir la formación de un DSS y en lo que venimos a llamar "Inteligencia Urbana" en cuanto que facilita afrontar mejores decisiones en la planificación, el diseño y la política urbana.

Por su lado, la metodología basada en árboles de decisión a partir de una clasificación SOM se considera útil para: atribuir de forma sencilla patrones de comportamiento que pueden ser extremadamente complejos; y predecir de forma eficaz comportamientos de variables que presentan cierto coste o dificultad de evaluación, como son las variables demográficas o sociales, a partir de otras variables con menor complejidad y coste de evaluación, como las variables residenciales.

Sin embargo, es necesario tener presente ciertas precauciones y limitaciones en el uso de estas metodologías y en su implementación concreta. Entre ellas destacan que los datos usados pueden encontrarse ya obsoletos, y que no han quedado representadas absolutamente todas las dimensiones de la vulnerabilidad social [5]. Por otro lado un análisis de la población de una sección censal no es propiamente un análisis de la población, y debe extremarse la precaución y limitar la inferencia a la escala de la observación, no alcanzando directamente a los individuos [28], es decir no se debe extrapolar a individuos las conclusiones obtenidas del estudio de grupos de individuos.

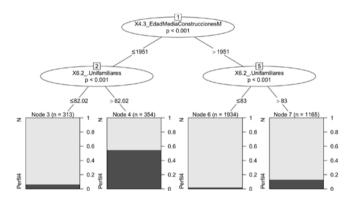


Fig. 2. Árbol de decisión. La variable que se predice es la pertenencia al Perfil 4 que se ha conectado con los rasgos de vulnerabilidad social.

Mediante la investigación aplicada al caso de estudio de la región de Andalucía, se ha obtenido un árbol de decisión de predicción del modelo obtenido mediante una metodología de clasificación no supervisada con Mapas auto-organizados, técnicas que han demostrado ser sencillas de usar, a la vez que útiles y capaces de predecir, con un relativo bajo error, fenómenos demográficos complejos y relevantes, como es la vulnerabilidad social. Para tal predicción se utiliza exclusivamente información de la realidad residencial.

En el caso específico de estudio, se han detectado gráficamente las áreas de Andalucía en las que se pronostica que pudieran estar afectadas por vulnerabilidad social, evidenciándose lo que podría nombrarse como "otra Andalucía", una Andalucía eminentemente rural, con signos de aislamiento frente a las oportunidades de empleabilidad, etc. que ofrecen las ciudades. Las áreas urbanas enmarcadas en el



perfil de vulnerabilidad social son ciertamente escasas. Esto podría ser una debilidad del modelo, siendo recomendable un ajuste del mismo que modifique el umbral de vulnerabilidad y que englobe así ámbitos que el estado del arte identifica como tales. Por su lado el árbol de decisión obtenido resulta interesante en cuanto que permite, de forma sencilla y con cierto nivel de precisión, predecir la probabilidad de que los habitantes de un área son vulnerables sociales, utilizando para ello un escaso número de variables. Específicamente en la región de estudio, se observa que únicamente con la edad de las edificaciones y la cantidad de vivienda unifamiliar del lugar en estudio es posible predecir la pertenencia a un perfil urbano afín a situaciones de vulnerabilidad social, con una probabilidad que se puede evaluar con el indicador AUC=0.78.

Se puede por lo tanto concluir que existe una conexión y relación entre los fenómenos demográficos y de vulnerabilidad y la configuración residencial de Andalucía, debiendo ser cauto y evitar a priori un establecimiento causa-efecto entre tales fenómenos, que requerirían otras pruebas diferenciadas que distan de ser el objetivo de esta investigación.

AGRADECIMIENTOS

Esta investigación ha sido parcialmente financiada por el Plan Propio de Investigación 2016 de la Universidad de Granada PP2016-PIP09.

REFERENCIAS

- [1] S. L. Cutter, «Vulnerability to hazards», *Prog. Hum. Geogr.*, vol. 20, n. 4, pp. 529-539, 1996.
- [2] B. Wisner, P. Blaikie, T. Cannon, y I. Davis, At Risk: Natural Hazards, People's Vulnerability, and Disasters. New York: Routledge, 2004.
- [3] A. Ebert, N. Kerle, y A. Stein, «Urban social vulnerability assessment with physical proxies and spatial metrics derived from air- and spaceborne imagery and GIS data», *Nat. Hazards*, vol. 48, n.º 2, pp. 275-294, 2009.
- [4] M. Prowse, Towards a Clearer Understanding of 'Vulnerability' in Relation to Chronic Poverty, n.º 24, 2003.
- [5] S. L. Cutter, B. J. Boruff, y W. L. Shirley, «Social vulnerability to environmental hazards», Soc. Sci. Q., vol. 84, n.º 2, pp. 242-261, 2003
- [6] D. Sánchez-González y C. Egea-Jiménez, «Enfoque de vulnerabilidad social para investigar las desventajas socioambientales. Su aplicación en el estudio de los adultos mayores», *Papeles de población*, vol. 17, n.º 69, pp. 151-185, 2011.
- [7] P. Blaikie, T. Cannon, I. Davis, y B. Wisner, «Vulnerabilidad. El Entorno Social, Político y Económico de los Desastres», *Prim. Edición Julio 1996*, p. 292, 1996.
- [8] CEPAL-ELAC, «Vulnerabilidad Sociodemográfica: viejos y nuevos riesgos para comunidades, hogares y personas.», Brasilia, 2002.
- [9] H. Gu, S. Du, B. Liao, J. Wen, C. Wang, R. Chen, y B. Chen, «A hierarchical pattern of urban social vulnerability in Shanghai, China and its implications for risk management», *Sustain. Cities Soc.*, vol. 41, n.º March, pp. 170-179, 2018.
- [10] E. Tate, «Social vulnerability indices: A comparative assessment using uncertainty and sensitivity analysis», *Nat. Hazards*, vol. 63, n.º 2, pp. 325-347, 2012.
- [11] Y. N. Maharani, S. Lee, y S. J. Ki, «Social vulnerability at a local level around the Merapi volcano», *Int. J. Disaster Risk Reduct.*, vol. 20, n.° July, pp. 63-77, 2016.
- [12] Y. N. Maharani y S. Lee, «Assessment of social vulnerability to natural hazards in South Korea: case study for typhoon hazard», *Spat. Inf. Res.*, vol. 25, n.° 1, pp. 99-116, 2017.
- [13] S. Jarupathirun y F. Zahedi, «GIS as Spatial Decision Support Systems», en Geographic information systems in business, J. B.

- Pick, Ed. Idea Group Pub, 2005.
- [14] A. G.-O. Yeh, «Urban planning and GIS», Geogr. Inf. Syst. Princ. Tech. Manag. Appl., 2005.
- [15] P. G. W. Keen, «Decision support systems: The next decade», *Decis. Support Syst.*, vol. 3, n.° 3, pp. 253-265, sep. 1987.
- [16] C. Yang, R. Raskin, M. Goodchild, y M. Gahegan, «Geospatial Cyberinfrastructure: Past, present and future», *Comput. Environ. Urban Syst.*, vol. 34, n.º 4, pp. 264-277, 2010.
- [17] G. D. Buzai, G. Cacace, L. Humacata, y S. L. Lanzelotti, *Teoría y métodos de la geografía cuantitativa: libro 1: por una geografía de lo real*, n.º 1. 2015.
- [18] P. Agarwal y A. Skupin, Self-Organising Maps: Applications in Geographic Information Science. John Wiley & Sons, Ltd, 2008.
- [19] D. J. Power, R. Sharda, y F. Burstein, «Decision Support Systems», en Wiley Encyclopedia of Management, C. L. Cooper, Ed. Chichester, UK: John Wiley & Sons, Ltd, 2015, pp. 1-4.
- [20] F. J. Abarca-Alvarez, F. S. Campos-Sánchez, y R. Reinoso-Bellido, «Methodology of Decision Support through GIS and Artificial Intelligence: Implementation for Demographic Characterization of Andalusia based on Dwelling», *Estoa*, vol. 6, n.º 11, pp. 33-51, 2017.
- [21] T. Kohonen, «The Self-Organizing Map», en *Proceeding of the IEEE*, 1990, vol. 78, pp. 1464-1480.
- [22] T. Kohonen, «The self-organizing map», *Neurocomputing*, vol. 21, n.º 1-3, pp. 1-6, 1998.
- [23] H. Ritter y T. Kohonen, «Self-organizing semantic maps», *Biol. Cybern.*, vol. 61, n.º 4, pp. 241-254, 1989.
- [24] S. Kaski y T. Kohonen, «Exploratory Data Analysis By The Self-Organizing Map: Structures Of Welfare And Poverty In The World (1996)», Neural Networks Financ. Eng. Proc. Third Int. Conf. Neural Networks Cap. Mark., pp. 498-507, 1996.
- [25] I. H. Witten, E. Frank, y M. a Hall, *Data Mining: Practical Machine Learning Tools and Techniques (Google eBook)*. 2011.
- [26] M. S. Silver, «On the Design Features of Decision Support Systems: The Role of System Restrictiveness and Decisional Guidance», en *Handbook on Decision Support Systems 2:* Variations, F. Burstein y C. W. Holsapple, Eds. Springer-Verlag Berlin Heidelberg, 2008, pp. 261-291.
- [27] P. Demartines y F. Blayo, «Kohonen Self-Organizing Maps: Is the Normalization Necessary?», *Complex Syst.*, vol. 6, n.º 2, pp. 105-123, 1992.
- [28] S. E. Spielmans y J.-C. Thill, «Social area analysisss, data mining, and GIS», Comput. Environ. Urban Syst., vol. 32, n.º 2, pp. 110-122, 2008.
- [29] L. Faggiano, D. de Zwart, E. García-Berthou, S. Lek, y M. Gevrey, «Patterning ecological risk of pesticide contamination at the river basin scale», Sci. Total Environ., vol. 408, n.º 11, pp. 2319-2326, 2010.
- [30] P. K. Wu y T. C. Hsiao, «Factor Knowledge Mining Using the Techniques of AI Neural Networks and Self-Organizing Map», Int. J. Distrib. Sens. Networks, vol. 2015, 2015.
- [31] R. L. Wasserstein y N. A. Lazar, «The ASA's statement on p-values: context, process, and purpose», *Am. Stat.*, vol. 1305, n.° April, pp. 00-00, 2016.
- [32] R. Coe y C. Merino, «Magnitud del efecto: Una guía para investigadores y usuarios», Rev. Psicol., vol. 21, n.º 1, pp. 147-177, 2003.
- [33] H. Strasser y C. Weber, «On the Asymptotic Theory of Permutation Statistics», *Math. Methods Stat.*, vol. 8, pp. 220-250, 1999.
- [34] T. Hothorn, K. Hornik, y A. Zeileis, «Unbiased recursive partitioning: A conditional inference framework», *J. Comput. Graph. Stat.*, vol. 15, n.° July, pp. 651-674, 2006.
- [35] R. Hamaina, T. Leduc, y G. Moreau, «Towards Urban Fabrics Characterization based on Buildings Footprints», en *Bridging the Geographic Information Sciences*, J. Gensel, Ed. 2012, pp. 231-248.
- [36] F. J. Abarca-Alvarez y F. Osuna-Pérez, «Cartografías semánticas mediante redes neuronales: los mapas auto-organizados (SOM) como representación de patrones y campos», EGA. Rev. expresión gráfica Arquit., vol. 18, n.º 22, 2013.
- [37] J. Yan y J.-C. Thill, «Visual data mining in spatial interaction analysis with self-organizing maps», *Environ. Plan. B Plan. Des.*, vol. 36, n.º 3, pp. 466-486, 2009.