


40.^a JORNADAS DE AUTOMÁTICA 4-6 SEP 2019



Universidade da Coruña
Escuela Universitaria
Politécnica. Ferrol



XL JORNADAS DE AUTOMÁTICA: LIBRO DE ACTAS

Ferrol, 4-6 de septiembre de 2019

A Coruña, 2019
Universidade da Coruña
Servizo de Publicacións

XL Jornadas de Automática: libro de actas: Ferrol, 4-6 de septiembre de 2019
José Luis Calvo Rolle [et al.] (eds.)
A Coruña, 2019
Universidade da Coruña, Servizo de Publicacións

Nº de páxinas: 899
210x297mm
Índice: pp.xiii-xxvi

ISBN: 978-84-9749-716-9
Depósito Legal: C 761-2019
DOI: doi.org/10.17979/spudc.9788497497169

CDU: 681.5(063)
IBIC: TJFM | TJF

ORGANIZAN:

Comité Español de Automática
Universidade da Coruña, Escola Universitaria Politécnica

COLABORA:

Universidade da Coruña, Vicerreitoría de Política Científica, Investigación e Transferencia

EDITORES:

José Luis Calvo Rolle
José Luis Casteleiro Roca
María Isabel Fernández Ibáñez
Óscar Fontenla Romero
Esteban Jove Pérez
Alberto José Leira Rejas
José Antonio López Vázquez
Vanesa Loureiro Vázquez
María Carmen Meizoso López
Francisco Javier Pérez Castelo
Andrés José Piñón Pazos
Héctor Quintián Pardo
Juan Manuel Rivas Rodríguez
Benigno Rodríguez Gómez
Rafael Alejandro Vega Vega

DISEÑO DE CUBIERTA:

Julia Núñez Calo

©de esta edición: Universidade da Coruña

©de los textos: los autores



ÍNDICE DE CONTENIDOS

Automar

| | |
|---|----|
| OPTIMIZACIÓN HEURÍSTICA CON CRITERIOS DE ERROR DE CONTROL TMD EN TURBINAS MARINAS FLOTANTES | 1 |
| <i>Juan Almenara Ahijón, Matilde Santos and María Tomás-Rodríguez</i> | |
| ANÁLISIS Y PLANIFICACIÓN DE MISIONES DE BÚSQUEDA Y RESCATE EN EL ENTORNO MARÍTIMO | 8 |
| <i>Eva Besada-Portas, José L. Risco-Martín, José A. López-Orozco and Juan J. Navarro-Corcuera</i> | |
| REDUCCIÓN DE LA CARGA DE TRABAJO DEL OPERADOR EN UN CENTRO DE CONTROL ADAPTATIVO MULTI-VEHÍCULO | 16 |
| <i>Juan Antonio Bonache-Seco, José Antonio López-Orozco, Eva Besada-Portas, Juan Francisco Jiménez-Castellanos and José María Girón-Sierra</i> | |
| MODELIZACIÓN, SIMULACIÓN Y EVALUACION TECNICO-ECONOMICA DE UNA TURBINA DE MAR | 24 |
| <i>Daniel Lillo, Matilde Santos, Segundo Esteban, Rafael López and María Guijarro</i> | |
| EXPERIENCIAS EN EL DISEÑO DE ROBOTS EDUCACIONALES SUBMARINOS | 32 |
| <i>Antonio Peñalver, Josep Marín, Javier Ponce, Raúl Marín, José Vicente Martí, Gustavo Casañ and Pedro Sanz</i> | |
| MODELO DINÁMICO Y CONTROL NO LINEAL PARA UN CONVERTIDOR DE ENERGÍA DE LAS CORRIENTES MARINAS DE PRIMERA GENERACIÓN Y DOS GRADOS DE LIBERTAD | 42 |
| <i>Eva Segura, Rafael Morales and Jose A Somolinos</i> | |

Bioingeniería

| | |
|---|----|
| DEEP LEARNING FOR THE AUTOMATIC CLASSIFICATION OF TISSUE TYPES IN BREAST BIOPSIES | 48 |
| <i>Javier Córdoba Romero, Maria Gloria Bueno García and Oscar Deniz Suarez</i> | |

| | |
|--|-----|
| NUEVOS MÉTODOS PARA LA DETECCIÓN DE OBSTÁCULOS INESPERADOS DURANTE LA MARCHA NORMAL A TRAVÉS DE SEÑALES EEG | 55 |
| <i>María Elvira, Eduardo Iáñez, Vicente Quiles, Mario Ortiz and Jose M. Azorín</i> | |
| ARQUITECTURA PARA LA INTEGRACIÓN DE MOTORES DE VIDEOJUEGOS EN APLICACIONES BASADAS EN INTERFACES CEREBRO-COMPUTADOR..... | 63 |
| <i>Jose Estevez, Jonay Toledo and Leopoldo Acosta</i> | |
| APLICACIÓN DE TÉCNICAS DE AGRUPAMIENTO A CORREDORES DE RESISTENCIA PARA LA ESTIMACIÓN DEL UMBRAL DE LACTATO | 71 |
| <i>Urtats Etxegarai, Eva Portillo Pérez, Jon Irazusta, Itziar Cabanes and Asier Zubizarreta</i> | |
| EXOESQUELETO DE BAJO COSTE CONTROLADO POR SEÑALES EMG Y EEG ORIENTADO A TERAPIAS DE REHABILITACIÓN DE MANO | 79 |
| <i>Óscar Fernández-Ballesteros, Javier Belmar, Jose M. Azorín and Eduardo Iáñez</i> | |
| DESARROLLO DE APLICACIONES MULTITAREA PARA EL ESTUDIO DE LA MEJORA DEL RENDIMIENTO COGNITIVO EN PACIENTES CON ENFERMEDADES NEURODEGENERATIVAS..... | 87 |
| <i>Eduardo Garbayo Herce and Montserrat Gil-Martínez</i> | |
| SISTEMA DE VISIÓN PARA EL GUIADO DE UN ASISTENTE ROBÓTICO EN OPERACIONES DE CIRUGÍA ENDONASAL..... | 94 |
| <i>Ander Loidi Yarza, Rafael Estop Remacha, Eusebio de la Fuente López, Juan Carlos Fraile Marinero and Javier Pérez Turiel</i> | |
| ALGORITMO PARA LA ESTIMACIÓN DEL ÁNGULO ANTEROPSTERIOR DE UNA MULETA SENSORIZADA..... | 101 |
| <i>Iñigo Sesar-Gil, Asier Zubizarreta and Itziar Cabanes</i> | |
| EVALUACIÓN DE UN ESQUEMA DE CONTROL MIOELÉCTRICO BIDIMENSIONAL PARA PRÓTESIS ROBÓTICAS | 107 |
| <i>Ángela Sánchez Pérez, José Miguel Torres, Carlos A. Jara, Jorge Pomares, Gabriel J. García and Andrés Úbeda</i> | |

OBTENCIÓN NO INVASIVA DE LA ONDA DE PRESIÓN ARTERIAL
EN LA CARÓTIDA 113
*David Zambrana, Vicente Esteve, Jose Maria Vicente and Jose Maria
Sabater-Navarro*

Computadores y Control

EL SEGMENTO DE TIERRA DEL SATÉLITE UPMSAT-2 119
*Alejandro Alonso, Raúl Torres, Juan Zamorano, Jorge Garrido and Juan
Antonio de la Puente*

PLANIFICACIÓN DESCENTRALIZADA BASADA EN SISTEMAS
MULTIAGENTE PARA ORQUESTADORES EN LA NIEBLA 126
*Oskar Casquero, Aintzane Armentia, Isabel Sarachaga, Darío Orive and
Marga Marcos*

HACIA UNA PLATAFORMA GENÉRICA DE GESTIÓN DE
APLICACIONES DINÁMICAMENTE RECONFIGURABLES 133
*Unai Gangoiti, Aintzane Armentia, Elisabet Estévez, Oskar Casquero
and Marga Marcos*

USING THE OPEN SOURCE LIBRARY LIBNODAVE FOR
MONITORING TASKS IN THE SMART GRID SCENARIO 141
*Isaías González, Antonio José Calderón, José María Portalo and Manuel
Calderón*

HACIA LA PUESTA EN MARCHA VIRTUAL DE CÉLULAS
ROBOTIZADAS BASADA EN GEMELO DIGITAL 147
Darío Orive, Nagore Iriondo, Marga Marcos and Oskar Casquero

INTEGRACIÓN END-TO-END A TRAVÉS DEL MODELO DEL
PRODUCTO 4.0 155
*Isabel Sarachaga, Arantza Burgos, Nagore Iriondo, Maria Luz Alvarez
and Marga Marcos*

Control Inteligente

IDENTIFICACIÓN DE CARRETERAS CONVENCIONALES
MEDIANTE TÉCNICAS DE SOFT COMPUTING 162
Felipe Barreno Herrera, Matilde Santos and Manuel Romana García

| | |
|---|-----|
| GENERACIÓN DE DATOS SINTÉTICOS CON OBJETOS DE COCINA PARA ENTRENAR REDES NEURONALES DE CONVOLUCIÓN | 170 |
| <i>Luis Benages-Pardo, Rubén Sagüés-Tanco, Gonzalo López-Nicolás and Sergio Llorente</i> | |
| CENTRALIZED AND DISTRIBUTED MODEL-BASED PREDICTIVE CONTROL APPLIED TO A SEWER NETWORK..... | 178 |
| <i>Antonio Cembellín, Mario Francisco and Pastora Isabel Vega</i> | |
| ANÁLISIS DE VIBRACIONES EN UNA ESTRUCTURA UTILIZANDO ECHO STATE NETWORKS | 186 |
| <i>Ignacio Díaz Blanco, Diego García Pérez, Ana González Muñiz and Abel Alberto Cuadrado Vega</i> | |
| DETECTION SYSTEM OF FAILURE ALARMS IN THE MECHANICAL TRAIN OF A WIND TURBINE..... | 192 |
| <i>David Lopez, Luis Pantoja and Eloy Irigoyen</i> | |
| SISTEMA HÍBRIDO PARA LA PREDICCIÓN DEL FUNCIONAMIENTO DE UNA CELDA DE COMBUSTIBLE BASADA EN HIDRÓGENO, EMPLEADA EN EL ALMACENAMIENTO DE ENERGÍA..... | 200 |
| <i>Juan Aurelio Montero-Sousa, Esteban Jove, José-Luis Casteleiro-Roca, Héctor Quintián, José Luis Calvo-Rolle, Héctor Aláiz-Moretón and Tomás González-Ayuso</i> | |
| COMPARACIÓN DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO PARA LA CLASIFICACIÓN DE POSTURAS DE LA MANO Y DEDOS..... | 211 |
| <i>Enaitz Otazua, Eloy Irigoyen, Eukene Imatz-Ojanguren and Thierry Keller</i> | |
| EVALUACION DE UN ALGORITMO DE TORQUE VECTORING CON CAPACIDAD DE FRENADO REGENERATIVO | 218 |
| <i>Alberto Parra, Asier Zubizarreta and Joshué Pérez</i> | |
| DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA DE DETECCIÓN DE OBSTÁCULOS PARA ROBOTS AUTÓNOMOS BASADO EN LÓGICA BORROSA..... | 226 |
| <i>Daniel Vicente Rodrigo Muñoz and Matilde Santos</i> | |
| MONITORIZACIÓN DEL ESTADO DE RODAMIENTOS BASADA EN TÉCNICAS DE APRENDIZAJE AUTOMÁTICO..... | 234 |
| <i>Alberto Villalonga, Fernando Castaño, Gerardo Beruvides, Rodolfo Haber and Fernando Matia</i> | |

Educación en Automática

| | |
|--|-----|
| DESPLIEGUE AUTOMÁTICO DE LABORATORIOS REMOTOS EXTENDIENDO LAS CAPACIDADES DE DE EJSS | 242 |
| <i>Iñigo Aizpuru-Rueda, Eva Besada-Portas, Jesús Chacón and José Antonio López-Orozco</i> | |
| RENEWABLE ENERGY SYSTEMS AND SMART GRIDS: PLATFORM TO DEVELOP FINAL YEAR PROJECTS ON AUTOMATION AND SUPERVISION..... | 250 |
| <i>Antonio José Calderón, Isaías González and Manuel Calderón</i> | |
| EDUCACIÓN EN SOSTENIBILIDAD Y PROMOCIÓN DE VOCACIONES CIENTÍFICO-TÉCNICAS EN ESTUDIANTES PREUNIVERSITARIOS A TRAVÉS DE LA CONSTRUCCIÓN DE UN VEHÍCULO SOLAR | 257 |
| <i>Yolanda Ceada-Garrido, Antonio Javier Barragán, Juan Manuel Enrique, Ramón Tirado-Morueta and José Manuel Andújar</i> | |
| MEJORA DE SISTEMA DE CONTROL COORDINADO DE ROBOTS MÓVILES MEDIANTE LA UTILIZACIÓN DE UN SISTEMA DE LOCALIZACIÓN POR VISIÓN | 263 |
| <i>David Gallarta, Pablo Álvarez, Javier Rico-Azagra and Montserrat Gil-Martínez</i> | |
| LABORATORIO DE MANUTENCIÓN E INFORMÁTICA INDUSTRIAL RICARDO MARÍN DE LA UNIVERSIDAD DE VIGO: 25 AÑOS DE AUTOMATIZACIÓN INDUSTRIAL | 270 |
| <i>Julio Garrido Campos, Juan Sáez López, José Ignacio Armesto Quiroga, Angel Manuel Espada Seoane and David Santos Esterán</i> | |
| REMOTE RESEARCH LABORATORY DEVELOPMENT BY USING MULTICONNECTED INDUSTRIAL TECHNOLOGIES | 277 |
| <i>Amaro González García, Manuel Domínguez González and Ignacio Diaz Blanco</i> | |
| DUINO-BASED LEARNING (DBL) : UN PROYECTO PARA FACILITAR EL USO DE ARDUINO Y MATLAB..... | 288 |
| <i>Eneko Lerma, Robert Griñó, Ramon Costa Castelló and Carlos Sanchis</i> | |
| LAS VENTAJAS DEL IoT EN EL DISEÑO DE LABORATORIOS REMOTOS: myGATEWAY | 294 |
| <i>Marco A. Marquez Sanchez, Reyes Herrera, Andres Mejias Borrero and José Manuel Andújar</i> | |

| | |
|---|-----|
| APRENDIZAJE DE SENSORIZADO DE ENTORNOS IoT MEDIANTE BEAGLEBONE | 302 |
| <i>Alejandro Millan Del Rio, Jose Alberto Benitez Andrades, Carmen Benavides Cuellar, Bruno Fernandes, Fabio Silva, Jose Luis Casteleiro Roca, Isaias Garcia Rodriguez and Hector Alaiz Moreton</i> | |
| RECONSTRUCCIÓN DEL SISTEMA DE CONTROL DE UN EQUIPO DE LABORATORIO CLASIFICADOR DE PIEZAS POR PESO | 309 |
| <i>Eduardo Moya, Alfonso Poncela, Javier García and Mario Blázquez</i> | |
| PLATAFORMA GIROSCÓPICA REALIZADA MEDIANTE IMPRESIÓN 3D PARA EL CONTROL DE ACTITUD Y ORIENTACIÓN DE UAVS MULTI-ROTOR | 317 |
| <i>Silvano Nájera, Javier Rico-Azagra, Carlos Elvira and Montserrat Gil-Martínez</i> | |
| EXPERIENCIA DE APRENDIZAJE BASADO EN PROYECTOS CON EVALUACIÓN COMPETITIVA-COLABORATIVA PARA REGULACIÓN AUTOMÁTICA | 324 |
| <i>Luis Orihuela</i> | |
| EQUIPO DE PRÁCTICAS PORTÁTIL PARA APRENDIZAJE SOBRE MANEJO Y PROGRAMACIÓN DE AUTÓMATAS PROGRAMABLES ... | 331 |
| <i>Alfonso Poncela Mendez and Jesus Aguado Laguna</i> | |
| CONTROL ACTIVO DE VIBRACIONES EN ESTRUCTURAS CIVILES ESBELTAS | 339 |
| <i>Alfonso V. Poncela Méndez, Eduardo J. Moya de La Torre, F. Javier García Ruíz and Alberto de Domingo de La Rubia</i> | |
| USO DEL ESTÁNDAR LTI PARA INTEGRAR SISTEMAS DE GESTIÓN DE APRENDIZAJE Y LABORATORIOS ONLINE | 347 |
| <i>Ildefonso Ruano, Elisabet Estévez, Juan Gómez and Javier Gámez</i> | |
| DESARROLLO DE LABORATORIOS HÍBRIDOS DE SISTEMAS INDUSTRIALES PARA EL APRENDIZAJE INTERACTIVO DE AUTOMATIZACIÓN Y CONTROL | 354 |
| <i>Alberto Torres, Carlos A. Jara, Jorge Pomares, Gabriel J. García, José L. Ramón, Andrés Úbeda and Carolina S. Díaz</i> | |
| EJEMPLO DE INTEGRACIÓN DE ALEXA CON UN ROBOT UR | 360 |
| <i>Jose Maria Vicente-Samper, Irene Campos, Benjamin Sanz Worrell, Adrian Rodriguez, Juna Miguel Onate Tevar and Jose Maria Sabater-Navarro</i> | |

Ingeniería de Control

| | |
|---|-----|
| SISTEMA DE CONTROL BASADO EN ARDUINO PARA UNA CALDERA DE BIOMASA | 366 |
| <i>Martín Balboa, Serafin Alonso, Juan Jose Fuertes, Antonio Moran and Miguel Angel Prada</i> | |
| GESTIÓN ENERGÉTICA DE UN CICLO DE REFRIGERACIÓN CON ALMACENAMIENTO DE ENERGÍA | 374 |
| <i>Guillermo Bejarano, João M. Lemos, Manuel G. Ortega and Francisco R. Rubio</i> | |
| OBSERVADOR DE ALTA GANANCIA CON ZONA MUERTA PARA PILAS DE COMBUSTIBLE PEM | 382 |
| <i>Andreu Cecilia and Ramon Costa Castelló</i> | |
| NUEVAS TECNOLOGÍAS EN MANIPULADORES INGRÁVIDOS: MANIPULADOR INGRÁVIDO 4.0 (MINIon 4.0) | 389 |
| <i>Antonio Corral and Eduardo Moya</i> | |
| CONTROL ROBUSTO QFT DE UN SISTEMA DE REFRIGERACIÓN ... | 397 |
| <i>Rocío Del Campo Pedrosa, Montserrat Gil-Martínez and Javier Rico-Azagra</i> | |
| DISEÑO DE UNA MAQUETA DE BAJO COSTE PARA SHM | 405 |
| <i>Diego García Pérez, Ignacio Díaz Blanco, Ana González Muñiz and Abel Alberto Cuadrado Vega</i> | |
| CONTROL PREDICTIVO LINEAL DEL PH EN UN FOTOBIORREACTOR RACEWAY | 414 |
| <i>Ángeles Hoyo, José Luis Guzmán, José Carlos Moreno and Manuel Berenguel</i> | |
| CONTROL DE UN RECUPERADOR DE SALES EN UNA PLANTA TERMOSOLAR HÍBRIDA | 421 |
| <i>Pablo Otálora, Jose Luis Guzman, Lidia Roca and Javier Bonilla</i> | |
| COMPARATIVA DE ENTORNOS OPEN-SOURCE PARA SISTEMAS DE SUPERVISIÓN APLICABLES A SMART GRIDS/SMART MICRO-GRIDS | 428 |
| <i>José María Portalo Calero, Isaías González, Antonio José Calderón and Manuel Calderón</i> | |

ESTIMACIÓN DISTRIBUIDA DE SISTEMAS LTI BASADA EN
CONFIANZA 435

Álvaro Rodríguez Del Nozal, Luis Orihuela and Pablo Millan

UNA REGLA DE SINTONÍA NO ESTÁNDAR PARA
CONTROLADORES PI POR EVENTOS 442

*José Sánchez Moreno, María Guinaldo Losada and Sebastián Dormido
Bencomo*

BANCO DE ENSAYO PARA MOTORES DE VEHÍCULOS ELÉCTRICOS 450

*Jose Luis Torres-Moreno, Galo Heredia, Antonio Gimenez-Fernandez
and Antonio Visioli*

Modelado, Simulación y Optimización

CREACIÓN DE CASOS DE ESTUDIO PARA LA GESTIÓN
ENERGÉTICA DE SISTEMAS HVAC EN EDIFICIOS BASADOS EN
TRNSYS 458

*Adrian Cardona Ruiz, Daniel Limon Marruedo, Juan Francisco Coronel
Toro and Luis Perez-Lombard*

MODELOS EMPÍRICOS DEL CAMPO SOLAR EN PLANTAS
TERMOSOLARES DE CONCENTRACIÓN. APLICACIÓN A LA
PLANIFICACIÓN 466

*Emilian Gelu Cojocar, José Manuel Bravo Caro, Manuel Vasallo and
Manuel Emilio Gegundez-Arias*

MODELO DE SISTEMA DE REFRIGERACIÓN DE EDIFICIOS
ORIENTADO AL CONTROL Y GESTIÓN DE LA EFICIENCIA
ENERGÉTICA 475

*Joaquín García Ordonez, Juan Moreno Nadales, Daniel Limon
Marruedo, Luis Perez-Lombard Martín de Oliva, Juan Francisco Coronel
Toro and Adrian Cardona Ruiz*

AJUSTE DE UN MODELO DE REDES DE CONTAGIO DE VARICELA
MEDIANTE ALGORITMOS DE OPTIMIZACIÓN HEURÍSTICOS EN
UN ENTORNO DE CÁLCULO DISTRIBUIDO 483

José Gabriel García Caro and Matilde Santos

| | |
|--|-----|
| MODELLING A SOLAR TRACKER WITH HIGH CONCENTRATION PANELS | 491 |
| <i>Manuel Garrido Satue, Fernando Castaño Castaño, Manuel Gil Ortega Linares and Francisco Rodriguez Rubio</i> | |
| DISEÑO DE UN GEMELO DIGITAL PARA EL GESTOR DE OPERACIONES DE UNA LAVANDERÍA INDUSTRIAL | 499 |
| <i>Germán González Rodríguez, José Manuel González Cava, Esteban Jove, José Luis Calvo Rolle and Juan Albino Méndez Pérez</i> | |
| INTERFAZ PARA UN OPTIMIZADOR QUE GESTIONA LA PRODUCCIÓN DE ELECTRICIDAD EN UNA FÁBRICA AZUCARERA . | 506 |
| <i>Sergio Hernández, Cristian Pablos and Felipe Acebes</i> | |
| REAL-TIME OPTIMISATION FOR A HEAT-RECOVERY SECTION WITH EQUIPMENT DEGRADATION | 513 |
| <i>Maria P. Marcos, José Luis Pitarch and Cesar De Prada</i> | |
| FRAMEWORK FOR MOTION PREDICTION OF VEHICLES IN A SIMULATION ENVIRONMENT | 520 |
| <i>Juan Felipe Medina Lee, Vinicius Trentin and Jorge Villagra</i> | |
| ESTUDIO DEL MODELO DE COMBATE DE LANCHESTER COMO SOPORTE PARA LA CONSTRUCCIÓN DE UN DECISOR ESTRATÉGICO OPERACIONAL MILITAR MEDIANTE BLOQUES RETROALIMENTADOS | 528 |
| <i>Gerardo Minguela Castro, Carlos Cerrada and Jose Antonio Cerrada</i> | |
| DETECCIÓN Y SUPRESIÓN DE ARMÓNICOS DE BAJO ORDEN EN LA CORRIENTE ELÉCTRICA | 535 |
| <i>Pablo Montero and Francisco Gordillo</i> | |
| DISEÑO EN SOLIDWORKS DE PLATAFORMA DEL SISTEMA CARDIOVASCULAR PARA ENSAYO DE ROBOTS DE NAVEGACIÓN AUTÓNOMA | 544 |
| <i>Cristina Nuevo-Gallardo, José Emilio Traver, Ines Tejado, Javier Prieto-Arranz, Miguel A. López and Blas M Vinagre</i> | |
| MEJORAS DEL SIMULADOR DE DISPERSIÓN DE GASES GADEN PARA DESARROLLOS DE ROBÓTICA OLFATIVA | 552 |
| <i>Pepe Ojeda, Javier Monroy and Javier González-Jiménez</i> | |
| SCHEDULING ÓPTIMO DE PROCESOS BATCH DE DURACIÓN INTERDEPENDIENTE..... | 560 |
| <i>Carlos Gómez Palacín, Pablo Riquelme and Cesar De Prada</i> | |

| | |
|--|-----|
| DETECCIÓN DE FALLOS EN REDES DE PRESIÓN PERTENECIENTES A REDES DE SUMINISTRO DE AGUA MEDIANTE FILTROS ESTÁTICOS LINEALES BASADOS EN PCA | 568 |
| <i>Mario Pereira Martin, Joaquim Blesa, Vicenç Puig and David Muñoz De la Peña Sequedo</i> | |
| MODELADO Y OPTIMIZACIÓN DE MISIONES DE BÚSQUEDA MEDIANTE UAVs | 574 |
| <i>Sara Pérez-Carabaza, Eva Besada-Portas, José Antonio López-Orozco and Gemma Blasco</i> | |
| MODELO DE TEMPERATURA PARA REACTORES ABIERTOS DE MICROALGAS | 582 |
| <i>Enrique Rodríguez Miranda, Francisco Gabriel Acién Fernández, José Luis Guzmán Sánchez, Manuel Berenguel Soria and Antonio Visioli</i> | |
| COMPARACIÓN DE ESTRATEGIAS DE CONTROL PARA SISTEMAS MPPT: OPTIMIZACIÓN DE LA POTENCIA ENTREGADA A LA CARGA VS OPTIMIZACIÓN DE LA POTENCIA EXTRAÍDA DEL GENERADOR FOTOVOLTAICO | 589 |
| <i>Juan Ríos Gutiérrez, Juan Manuel Enrique Gómez, Antonio Javier Barragan Piña and José Manuel Andújar</i> | |
| LOW LEVEL CONTROL ACTUATED SYSTEM MODELLING APPROACH FOR HIGHLY AUTOMATED VEHICLES | 596 |
| <i>Joseba Sarabia, Jose Angel Matute-Peaspan and Asier Zubizarreta</i> | |
| DESIGN AND DEVELOPMENT OF A LOW COST AUTOMATIC STRINGED INSTRUMENT TUNER | 604 |
| <i>Javier Sevilla Salcedo, Diego Manuel Martínez Gila, Idefonso Ruano Ruano, Alejandro Sánchez García, Elisabet Estévez Estévez, Juan Gómez Ortega and Javier Gámez García</i> | |
| INFLUENCIA DE LA LATENCIA EN EL CONTROL DE AGVS A TRAVÉS DE REDES 5G | 611 |
| <i>Jesus Enrique Sierra Garcia and Matilde Santos Peñas</i> | |
| MODELADO Y VERIFICACIÓN MEDIANTE LÓGICA LINEAL TEMPORAL DE UN GRUPO DE DOS ASCENSORES CON SISTEMA DE CONTROL DE DESTINO | 617 |
| <i>Manuel Toscano-Moreno, Alberto Arregui, Anthony Mandow and Alfonso García-Cerezo</i> | |

AN OPERATIONAL MODEL FOR THE OPTIMAL OPERATION OF
THE FREEZE-DRYING PROCESS 623

*Carlos Vilas, Antonio Alonso, Eva Balsa-Canto, Estefanía
López-Quiroga and Cristian Trelea*

ANÁLISIS DE OBSERVABILIDAD E IDENTIFICABILIDAD
ESTRUCTURAL DE MODELOS NO LINEALES: APLICACIÓN A LA
VÍA DE SEÑALIZACIÓN JAK/STAT 631

Alejandro F. Villaverde and Julio Banga

RED NEURONAL ESTRUCTURADA EN EL ESPACIO DE ESTADOS
COMO MODELO DE CAJA GRIS 639

Jesús M. Zamarreño and Alejandro Merino

Robótica

DISEÑO Y DESARROLLO DE UN ROBOT AÉREO PARA LA
INSPECCIÓN DE COLECTORES DE SANEAMIENTO 647

*Jose Luis Andrade Pineda, Honorio Romero Rodriguez, Angel Rodriguez
Castaño, Francisco Javier Pérez Grau, Graciano Carpes Hortal and
Anibal Ollero Baturone*

CONTROL DE FORMACIONES SOBRE REGIONES OBJETIVO DE
SISTEMAS MULTI-AGENTE LAGRANGIANOS CON RETARDO 655

*Ernesto Aranda-Escolástico, Maria Guinaldo, Leonardo J. Colombo and
Sebastián Dormido*

COLECCIÓN DE JUPYTER NOTEBOOKS PARA CURSOS DE
ROBÓTICA MÓVIL 663

*Samuel-Felipe Baltanas-Molero, Jose-Raul Ruiz-Sarmiento and Javier
Gonzalez-Jimenez*

DESIGN OF A NOVEL VARIABLE-STIFFNESS GRIPPER USING
JAMMING FINGERS 671

Daniel Cardin-Catalan, Angel P. Del Pobil and Antonio Morales

EXPERIENCIAS EDUCATIVAS BASADAS EN EL SISTEMA
MARPAIBOT 679

*Gustavo Casañ, Jose Vicente Martí, Raul Marín, David Fornás and
Pedro Sanz*

| | |
|---|-----|
| USO DE TÉCNICAS DE MACHINE LEARNING PARA REALIZAR MAPPING EN ROBÓTICA MÓVIL | 686 |
| <i>Sergio Cebollada, Vicente Román, Luis Payá, María Flores, Luis Miguel Jiménez and Oscar Reinoso</i> | |
| TELEOPERATING A MOBILE MANIPULATOR USING A UAV CAMERA WITHOUT ROBOT SELF-OCCLUSIONS | 694 |
| <i>Josep-Arnau Claret and Luis Basañez</i> | |
| ALGORITMO DE GENERACIÓN DE TRAYECTORIAS EN EL INTERIOR DE CHAPAS PARA LA SUBSANACIÓN DE DEFECTOS | 702 |
| <i>Álvaro Fernández García, Sara Roos Hoefgeest Toribio, Ignacio Álvarez García and Rafael Corsino González de Los Reyes</i> | |
| EVALUACION MULTI-ZMP PARA TAREAS DE TRANSPORTE DE OBJETOS EN ROBOTS HUMANOIDES | 710 |
| <i>Juan Miguel Garcia-Haro, Santiago Martinez, Juan Hernandez Vicen and Carlos Balaguer</i> | |
| DESARROLLO DE UNA VERSIÓN DE BAJO COSTE DEL ROBOT SOCIAL MINI..... | 718 |
| <i>Carlos Manuel Gomez Jimenez, Carlos Juan De Dios Ursua, Jose Carlos Castillo Montoya, Alvaro Castro Gonzalez, Fernando Alonso Martin, Maria Malfaz Vazquez, Marcos Maroto Gomez and Miguel Angel Salichs Sanchez-Caballero</i> | |
| OBTENCION DEL MODELO CINEMATICO INVERSO DE SISTEMAS ROBOTIZADOS DE CADENA CINEMATICA ABIERTA EMPLEANDO BASES DE GROEBNER. APLICACION A UN ROBOT HEXAPODO | 726 |
| <i>Jose Guzman-Gimenez, Ángel Valera, Vicente Mata and Miguel Ángel Díaz-Rodríguez</i> | |
| UNA RED DE SENSORES INALÁMBRICA BASADA EN HARDWARE Y SOFTWARE ABIERTO PARA COLABORACIÓN CON APLICACIONES DE ROBÓTICA A MISIONES DE BÚSQUEDA Y RESCATE | 735 |
| <i>Francisco José Lara Hurtado, Jesus Fernandez-Lozano and Ricardo Vázquez Martín</i> | |
| MÉTODO DE PLANIFICACIÓN DE TRAYECTORIAS MÚLTIPLES PARA ENJAMBRE DE UAVS..... | 741 |
| <i>Ángel Madridano, Abdulla Al-Kaff, David Martin, Arturo de la Escalera and Jose María Armingol</i> | |

| | |
|--|-----|
| HERRAMIENTA PARA VISUALIZACIÓN GRÁFICA DE FUERZAS DE CONTACTO Y DE MOVIMIENTOS DE UNA MANO ROBÓTICA CON SENSORES TÁCTILES..... | 749 |
| <i>Andrés Montaña and Raúl Suárez</i> | |
| HACIA UNA ESTRATEGIA ASISTIDA POR ROBOT PARA LA RECUPERACION DE FUNCION MOTORA DE EXTREMIDAD SUPERIOR CON ASPECTOS COGNITIVOS..... | 756 |
| <i>Edwin Daniel Oña, Bartek Lukawski, Alberto Jardón and Carlos Balaguer</i> | |
| PLANIFICACIÓN DE TRAYECTORIAS DE UN ROBOT MÓVIL MODULAR CON UN ÚNICO ACTUADOR..... | 764 |
| <i>Adrián Peidro Vidal, Julio Gallego, Luis Paya, José María Marín and Oscar Reinoso</i> | |
| DETECCIÓN DE PALLETS MEDIANTE TÉCNICAS DE VISIÓN POR COMPUTADOR..... | 772 |
| <i>David Ramos and Jesus Enrique Sierra Garcia</i> | |
| CONTROL DINÁMICO DE MANIPULADORES MÓVILES CON REALIMENTACIÓN VISUAL..... | 779 |
| <i>Jose L. Ramón, Álvaro Belmonte, Jorge Pomares, Gabriel J. García, Carlos A. Jara, Andrés Úbeda, Ester Abad and María Ángeles Rueda</i> | |
| INTEGRACIÓN DE UN PLANIFICADOR DE TRAYECTORIAS PARAMETRIZADO EN LA ARQUITECTURA ROBÓTICA ROS..... | 787 |
| <i>Mario A. Rueda-Castro, Javier Monroy, Francisco-Angel Moreno and Javier Gonzalez-Jimenez</i> | |
| DISEÑO DE UNA PINZA SUBACTUADA HÍBRIDA SOFT-RIGID CON SENSORES HÁPTICOS PARA INTERACCIÓN FÍSICA ROBOT-HUMANO..... | 795 |
| <i>Trinidad Sánchez-Montoya, Juan M. Gandarias, Francisco Pastor, Antonio J. Muñoz-Ramírez, Alfonso J. García-Cerezo and Jesús M. Gómez-de-Gabriel</i> | |
| GENERACIÓN EFICIENTE DE MOSAICOS PARA INSPECCIÓN DE INFRAESTRUCTURAS LINEALES MEDIANTE ROBOTS AÉREOS..... | 802 |
| <i>Raúl Tapia, José Ramiro Martínez de Dios and Aníbal Ollero</i> | |

| | |
|--|-----|
| ASISTENCIA AL APARCAMIENTO BASADO EN UNA CÁMARA DE TIEMPO DE VUELO | 810 |
| <i>Myriam Vaca Recalde, Luis Paarup Peláez, Enrique Martí Muñoz, Ray Lattarulo and Xabier Udaeta</i> | |

Visión por Computador

| | |
|---|-----|
| IDENTIFICACIÓN Y CONTEO DE ACEITUNAS EN IMÁGENES DIGITALES TOMADAS EN EL OLIVAR MEDIANTE MORFOLOGÍA MATEMÁTICA Y REDES NEURONALES CONVOLUCIONALES | 818 |
| <i>Arturo Aquino, Juan Manuel Ponce, Borja Millán, Diego Tejada-Guzmán and José Manuel Andújar</i> | |
| ENHANCING TEXT RECOGNITION ON TOR DARKNET IMAGES | 828 |
| <i>Pablo Blanco-Medina, Enrique Alegre, Mhd Wesam Al-Nabki, Deisy Chaves and Eduardo Fidalgo Fernandez</i> | |
| PARALLEL COMPUTING TECHNOLOGIES IN VIDEO STABILIZATION FOR TEACHING PURPOSES | 836 |
| <i>César Gabriel Márquez Rodríguez, Matías García Rivera, Miguel Diaz-Cacho Medina and José Luís Camaño Portela</i> | |
| EVALUACIÓN DE NUEVOS MODOS DE EMPLEO DE LOS DESCRIPTORES DE APARIENCIA GLOBAL EN TAREAS DE LOCALIZACIÓN | 842 |
| <i>Vicente Román Erades, Sergio Cebollada Lopez, Luis Paya, María Flores Tenza, Arturo Gil Aparicio and Oscar Reinoso</i> | |
| LOCALIZACIÓN DE ROBOTS MÓVILES EN ENTORNOS INDUSTRIALES USANDO UN ANILLO DE CÁMARAS | 849 |
| <i>Sara Roos Hoefgeest Toribio, Álvaro Fernández García, Ignacio Álvarez García and Rafael Corsino González de Los Reyes</i> | |
| ¿ES POSIBLE ENTRENAR MODELOS DE APRENDIZAJE PROFUNDO CON DATOS SINTÉTICOS? | 859 |
| <i>Noelia Vallez, Alberto Velasco-Mata, Juan José Corroto and Oscar Deniz</i> | |

USO DE TÉCNICAS DE MACHINE LEARNING PARA REALIZAR MAPPING EN ROBÓTICA MÓVIL

Sergio Cebollada, Vicente Román, Luis Payá, María Flores, Luis M. Jiménez, Oscar Reinoso
 Departamento de Ingeniería de Sistemas y Automática
 Universidad Miguel Hernández, Avda. de la Universidad s/n, 03202 Elche (Alicante), España
 {sergio.cebollada, vicente.roman, lpaya, m.flores, luis.jimenez, o.reinoso}@umh.es

Resumen

El trabajo presentado consiste en un estudio de diversos clasificadores basados en machine learning como herramienta para llevar a cabo la tarea de mapeo y localización en robótica móvil. En concreto, estos clasificadores son utilizados para solventar la tarea de localización "gruesa", la cual forma parte de los procesos a realizar para resolver la localización jerárquica. El proceso de localización llevado a cabo por el robot consistiría en (1) capturar una imagen desde una posición desconocida, (2) calcular su correspondiente descriptor de apariencia global, (3) introducir dicha información al clasificador y obtener la estancia en la cual se encuentra el robot en ese instante. Tras esto, (5) el robot realizará el problema de image retrieval con toda la información visual de entrenamiento contenida en la estancia seleccionada (localización fina). Este trabajo evalúa el uso de tres clasificadores (Naïve Bayes, SVM y clasificador basado en red neuronal) los cuales se entrenan con tres posibles descriptores de apariencia global (HOG, gist y un descriptor obtenido a partir de una CNN). Los experimentos se llevan a cabo mediante el uso de un dataset que contiene imágenes omnidireccionales capturadas en entornos de interior y que presenta cambios dinámicos (personas andando, cambios de mobiliario, etc.). Los resultados obtenidos demuestran que el método propuesto es una alternativa eficiente para realizar la tarea de localización jerárquica en cuanto error de localización y tiempo de cómputo.

Palabras clave: Mapping, Localización Jerárquica, Imágenes Omnidireccionales, Descriptores de Apariencia Global, Machine Learning

1. INTRODUCCIÓN

En la actualidad, la información visual desempeña un papel fundamental para solventar tareas en robótica móvil. En concreto, el robot debe crear un mapa (mapping) y posteriormente estimar su posición dentro de dicho mapa (localización). Si bien en el estado del arte se puede encontrar una amplia variedad de sensores para llevar a cabo di-

chas tareas, el uso de información visual resulta interesante puesto que presenta una alternativa económica y proporciona resultados eficientes para las tareas desempeñadas. Entre los sensores visuales, las cámaras omnidireccionales presentan una solución robusta puesto que dichas cámaras aportan información en 360 grados alrededor del robot.

Generalmente, para utilizar la información visual aportada por la cámara, es necesario extraer información característica de la imagen para así poder solventar de manera más efectiva las tareas de mapeo y localización. Una de estas técnicas es conocida como descripción de apariencia global. Mediante este método se extrae información relevante en un único vector que contiene información global sobre la imagen. Podemos encontrar varios ejemplos de sus uso en la bibliografía, como por ejemplo, Korrapati y Mezouar [5], quienes utilizan los descriptores de apariencia global para crear mapas topológicos y llevar a cabo posteriormente la tarea de detección de lazo cerrado. Más recientemente, Zhou *et al.* [17] propone el uso del descriptor *gist* para solventar la tarea de localización a través de un emparejamiento entre el dataset obtenido durante la fase de mapeo y la imagen proporcionada por el robot en el instante actual. Por otro lado, Román *et al.* [12] llevó a cabo una evaluación de la robustez de diferentes descriptores de apariencia global ante cambios de iluminación. Estos trabajos se basan en el uso de descriptores que se calculan de manera analítica, sin embargo, en los últimos años ha emergido el uso de descriptores de apariencia global basados en técnicas de deep learning. Por ejemplo, Xu *et al.* [14] propuso de auto-encoders para obtener descriptores de apariencia global que le permitiesen detectar tumores de pecho; Payá *et al.* [10] utiliza los vectores obtenidos de capas intermedias de una red neuronal convolucional (CNN) como descriptores de apariencia global y a partir de esta información lleva a cabo la creación de mapas jerárquicos.

Dada la potencia de las técnicas de inteligencia artificial desarrolladas durante las últimas décadas, este trabajo pretende estudiar algunas de las herramientas más destacadas dentro del área conocida como *Machine Learning* (aprendizaje au-

tomático) para llevar a cabo de manera mas eficiente la tarea de mapeo en robótica móvil. En concreto, este trabajo analiza el uso de clasificadores como herramienta para llevar a cabo el mapeo jerárquico. Dichos clasificadores tendrán como información de entrada el descriptor de apariencia global de una imagen capturada y a la salida indicarán en qué estancia se capturó la imagen con mayor probabilidad de acierto. Por tanto, a través de este trabajo se lleva a cabo una evaluación de diferentes tipos de clasificadores.

El resto de artículo se estructura de la siguiente manera: la sección 2 explica las herramientas de *machine learning* utilizadas para llevar a cabo los experimentos. Después, en la sección 3, se explica el uso de éstas herramientas para llevar a cabo el proceso de mapeo. La sección 4 presenta la información utilizada así como los experimentos llevados a cabo. Finalmente, en la sección 5 se discuten las conclusiones alcanzadas a través de los resultados obtenidos.

2. HERRAMIENTAS DE MACHINE LEARNING

El aprendizaje profundo o *machine learning* es un método de análisis de datos que automatiza la construcción de modelos analíticos. Esta técnica está incluida dentro de la rama de inteligencia artificial y se sustenta en la idea de que el sistema puede aprender a identificar patrones partiendo exclusivamente de los datos aportados. Para su uso, es necesario seleccionar previamente la información que se utilizará para entrenar el modelo y posteriormente llevar a cabo el proceso de entrenamiento, el cual, dependiendo de los requerimientos establecidos, puede llevar un mayor o menor tiempo. En la bibliografía podemos encontrar trabajos donde se utilizan algunas de estas herramientas para llevar a cabo tareas de visión por computador como por ejemplo, Zhang y Wu [15], que utilizan kSVM (Kernel Support Vector Machine) para clasificar imágenes de frutas. Dentro de la visión por computador, también encontramos trabajos para solventar tareas de robótica móvil, por ejemplo, Tribel [13] propone el uso del clasificador IVM (Informative Vector Machine) para crear mapas semánticos en robots autónomos; por otro lado, Duguleana y Mogan [4] proponen un algoritmo de planificación de trayectorias basado en Q-learning y utilizan redes neuronales para evitar obstáculos durante el camino. En este trabajo se propone el uso de clasificadores para llevar a cabo el mapeo jerárquico en la capa de alto nivel.

2.1. CLASIFICADORES

Un clasificador es básicamente una herramienta que se utiliza para predecir la clase o categoría a la que pertenece un dato. Previamente a poder utilizar esta herramienta, se necesitará llevar a cabo un entrenamiento. Dicho entrenamiento consistirá en introducir datos (x_{train}) etiquetados (y_{train}). De esta manera, se llevará a cabo un mapeo de aproximación de funciones para alcanzar un correcto ajuste de los parámetros. Finalmente, el modelo estará preparado para recibir datos de entrada (x_{in}) y estimar su categoría (y_{est}).

Este trabajo estudia tres tipos de clasificadores para utilizarlos en el proceso de mapeo.

- **Clasificador Naïve Bayes (NB).** Basado en el teorema de Bayes con independencia de suposición entre datos de entrada, este clasificador fue introducido por Maron [8] como método para categorizar correos de entrada (como spam, deportes, política, etc.) utilizando frecuencia de palabras como información de descripción.
- **Clasificador basado en red neuronal.** Este tipo de red neuronal se basa en el reconocimiento de patrones. Este sistema “aprende” a realizar tareas basándose en ejemplos (datos de entrenamiento) sin necesidad de ser programado ni de aprender ninguna regla específica.
- **Clasificador Support Vector Machine (SVM).** Introducido por Cortes y Vapnik [3], estos clasificadores no solo han sido utilizados para solventar tareas de clasificación, si no también han sido utilizados para propósitos de regresión. El algoritmo marca cada dato en un espacio n-dimensional (donde n es el número de características) con el valor de cada característica como situado en una coordenada particular. Después, la clasificación se lleva a cabo encontrando el hiper-plano o hiper-planos que mejor diferencia las categorías.

2.2. CLUSTERING

Los algoritmos de clustering son métodos que consisten en agrupar la información aportada en vectores de acuerdo a un criterio dado. Dicho criterio suele ser la similitud entre los vectores de información. Esta técnica ha resultado ser una buena solución para agrupar información basado en descriptores de apariencia visual ([10] y [1]). En [1], se estudiaron diversos métodos de clustering con el objetivo de comprobar su validez para crear modelos jerárquicos. Para este propósi-

to, los descriptores capturados en el proceso de mapeo (o entrenamiento) componen el dataset visual ($D = \{\vec{d}_1, \vec{d}_2, \dots, \vec{d}_N\}$). Tras esto, el algoritmo de clustering agrupa la información aportada por el dataset en clusters de acuerdo a su similitud ($C = \{C_1, C_2, \dots, C_{n_c}\}$ donde n_c es el número de clusters). Mediante el uso de clustering, se propone crear un mapa de alto nivel basado en representativos. Considerando este trabajo previo, se elige el clustering espectral [6] como el método para llevar a cabo la tarea de clustering para este estudio.

3. MAPPING

Además de las herramientas de *machine learning* mencionadas, en este trabajo también se estudia el uso de descriptores de apariencia global, los cuales han sido utilizados durante los últimos años para resolver la tarea de mapping. Por ejemplo, Payá *et al.* [10] utilizaron descripción de apariencia global para construir modelos topológicos jerárquicos. Basándonos en este trabajo, el presente estudio analiza el uso de los descriptores HOG, *gist* y un descriptor basado en deep learning. En cuanto a HOG, el cálculo de este descriptor se basa en dividir la imagen en k_1 celdas horizontales y calcular un histograma de gradientes de orientación para cada celda con b barras por histograma. Por último, los histogramas calculados se reordenan en una única fila, obteniendo así un vector del tipo $\vec{d}_{HOG} \in \mathbb{R}^{b \cdot k_1 \times 1}$. Para obtener el descriptor *gist*, primero se crean m_2 imágenes con diferente resolución partiendo de la imagen original. Después, se aplica un filtro de Gabor sobre las m_2 imágenes aplicando m_1 diferentes orientaciones. Tras esto, los píxeles de cada imagen se agrupan en k_2 bloques horizontales y por último, la información de orientación obtenida se agrupa para formar un vector del tipo $\vec{d}_{gist} \in \mathbb{R}^{m_1 \cdot m_2 \cdot k_2 \times 1}$. Se puede obtener una explicación mas detallada en [9]. Por último, en relación al descriptor basado en deep learning, el descriptor se obtiene de una capa intermedia incluida en una red neuronal convolucional (CNN), estas redes reciben un exhaustivo entrenamiento para llevar a cabo una determinada tarea (comúnmente de clasificación). Las CNNs están compuestas por varias capas ocultas, cuyos parámetros y ponderaciones se ajustan durante el proceso de entrenamiento. La idea consiste en introducir a la CNN la imagen y extraer un vector de de una de las capas intermedias, de manera que ese vector sea el descriptor de apariencia global. Esta técnica ha sido utilizada previamente por otros autores como por ejemplo Mancini *et al.* [7] para llevar a cabo una categorización de escenarios mediante un clasificador Naïve Bayes. Por otro lado, en trabajos previos ([10] y [2]) ya se ha probado el uso de estos descriptores para lle-

var a cabo tareas de mapping visual. El descriptor utilizado para este estudio es extraído de la red *places* [16] y corresponde con la capa completamente convolucional 'fc7'. este descriptor es de la forma ($\vec{d}_{fc7} \in \mathbb{R}^{4096 \times 1}$).

Por tanto, la tarea de mapping propuesta se resume en: el robot se mueve a través del entorno y captura imágenes omnidireccionales (ver fig. 1). Para cada imagen capturada, se calcula el descriptor de apariencia global (basado en alguno de los métodos propuestos). Finalmente, tras recorrer el entorno y obtener las N_{Train} imágenes, se obtiene un dataset visual formado por todos los descriptores calculados; $D = \{\vec{d}_1, \vec{d}_2, \dots, \vec{d}_{N_{Train}}\}$ donde cada descriptor es $\vec{d}_i \in \mathbb{C}^{l \times 1}$ y corresponde a la imagen im_i .

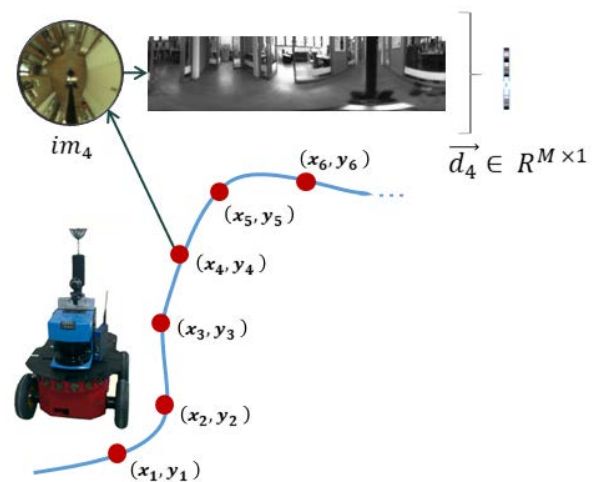


Figura 1: Proceso de mapping. El robot captura imágenes en distintas posiciones del escenario y calcula el descriptor de apariencia global.

En cuanto a la creación de modelos topológicos jerárquicos, los métodos propuestos en trabajos previos ([10] y [1]) consistieron en crear diferentes mapas con distinto nivel de detalle. De esta manera, con el mapa de alto nivel (que incorpora menos detalle) se llevaría a cabo una localización “gruesa” que determinaría el área en el cual se encuentra el robot. Tras esto, se llevaría a cabo una localización “fina” en el área seleccionada. La toma de decisión se basó en comparar la información proporcionada por el robot en la posición a estimar con respecto a un conjunto de descriptores representativos. Estos descriptores son calculados como la media de los descriptores que componen el área $R = \{r_1^-, r_2^-, \dots, r_{n_a}^-\}$ donde n_a es el número de áreas consideradas. De esta manera, se consigue una compactación del modelo que permite llevar a cabo una localización jerárquica más eficiente que mediante una comparación del dato obtenido por el robot con respecto a toda la información

recogida durante el proceso de entrenamiento.

3.1. CLASIFICADORES PARA CREACIÓN DE MAPAS DE ALTO NIVEL

Este trabajo pretende presentar una alternativa al uso de descriptores representativos para la creación de mapas de alto nivel en los modelos topológicos jerárquicos. De esta forma, los clasificadores estarían entrenados con la información visual (descriptores de apariencia global) y el etiquetado correspondiente a la habitación donde se capturó cada imagen. Una vez entrenado el clasificador, para solventar la localización gruesa bastaría con introducir en el sistema el descriptor calculado en la posición a estimar y éste devolvería la categoría (habitación) más probable.

En resumen, el proceso de localización consistiría en los siguientes pasos: (1) el robot captura una imagen desde una posición desconocida (im_{test}) y (2) calcula el descriptor de apariencia global (\vec{d}_{test}). (3) El descriptor obtenido es introducido en un sistema clasificador (previamente entrenado), el cual predecirá el área más probable donde se encuentra el robot (C_i). (4) Tras esta predicción, el descriptor \vec{d}_{test} es comparado con todos los descriptores que componen el área seleccionada ($D_i = \{\vec{d}_{i,1}, \vec{d}_{i,2}, \dots, \vec{d}_{i,N_i}\}$). Finalmente, se estima la posición del robot como la posición que corresponde al descriptor que presenta la mínima distancia entre \vec{d}_{test} y $\vec{d}_{i,j}$. La fig. 2 muestra el diagrama de localización propuesto.

4. EXPERIMENTOS

4.1. DATASET

El dataset empleado para llevar a cabo los experimentos es obtenido de la base de datos COLD (COsy Localization Database)[11], la cual aporta información obtenida por robots en entornos de interior ante cambios dinámicos y frente a tres posibles condiciones de iluminación. En particular se utiliza el dataset del entorno Friburgo, el cual contiene 9 habitaciones: una sala de impresoras, una cocina, cuatro despachos, un baño, una zona de escaleras y un pasillo que conecta todas las estancias. Para trabajar con la información visual aportada, en primer lugar se realiza un muestreo para retener únicamente una imagen cada 20-40 cm. Este muestreo permite por un lado establecer un dataset con una distancia entre posiciones de captura de imágenes similar a otros datasets empleados con anterioridad y por otro lado, del mismo dataset obtenemos un dataset de entrenamiento y otro dataset (dataset de test, que con-

tiene el número original de imágenes) el cual contendrá imágenes capturadas en mismas posiciones y también en distintas posiciones a las capturadas en el dataset de entrenamiento. El dataset de entrenamiento está compuesto por un total de 519 imágenes omnidireccionales y el dataset de testeo por 2595 imágenes que contiene una imagen del entorno cada 5 cm aproximadamente. Para este estudio no se tiene en cuenta los cambios de iluminación, por tanto, todas las imágenes son extraídas del dataset en condiciones de nublado, ya que es el que menos se ve afectado por la iluminación. Además, para poder utilizar los descriptores de apariencia global, se realiza una transformación de imágenes omnidireccionales a imágenes panorámicas.

4.2. EXPERIMENTO 1: EVALUACIÓN DE LOS CLASIFICADORES

Este experimento lleva a cabo la evaluación de los tres clasificadores propuestos para llevar a cabo la selección de la estancia a través del uso de descriptores de apariencia global. Previamente a testear el ratio de acierto de cada combinación “método de descripción + tipo de clasificador”. Para dicho entrenamiento, se utiliza los descriptores de las imágenes correspondientes al dataset de entrenamiento y las etiquetas correspondientes a cada imagen, las cuales se proporcionan por el *ground truth* de la base de datos y determina en qué estancia del entorno se capturó cada imagen. Una vez finalizado el entrenamiento, el clasificador ya estará preparado para recibir nueva información visual (datos de test) y obtener la categoría correspondiente.

Por tanto, el resultado que se obtiene en este experimento es el ratio de acierto de cada configuración clasificador + método de descripción. La tabla 1 muestra los resultados obtenidos. A partir de estos datos, se alcanza la conclusión de que tanto el clasificador basado en red neuronal como el clasificador SVM presentan una correcta opción para llevar a cabo la tarea de selección de estancia. Ambas opciones alcanzan valores de acierto de entorno al 98 % cuando se utilizan los descriptores *gist* o el descriptor basado en la capa *fc7* de la CNN (descriptor CNN-fc7). Por otro lado, se alcanza la conclusión de que el clasificador Naïve Bayes produce los peores resultados independientemente del tipo de descriptor utilizado. También se descarta el uso del descriptor HOG para llevar a cabo esta tarea. El clasificador SVM junto con el descriptor *gist* proporciona la configuración más óptima, la cual produce un ratio de acierto del 98.61 %. Para este resultado, se muestra la matriz de confusión obtenida a través de la fig. 3. A través de esta matriz se puede observar que la categori-

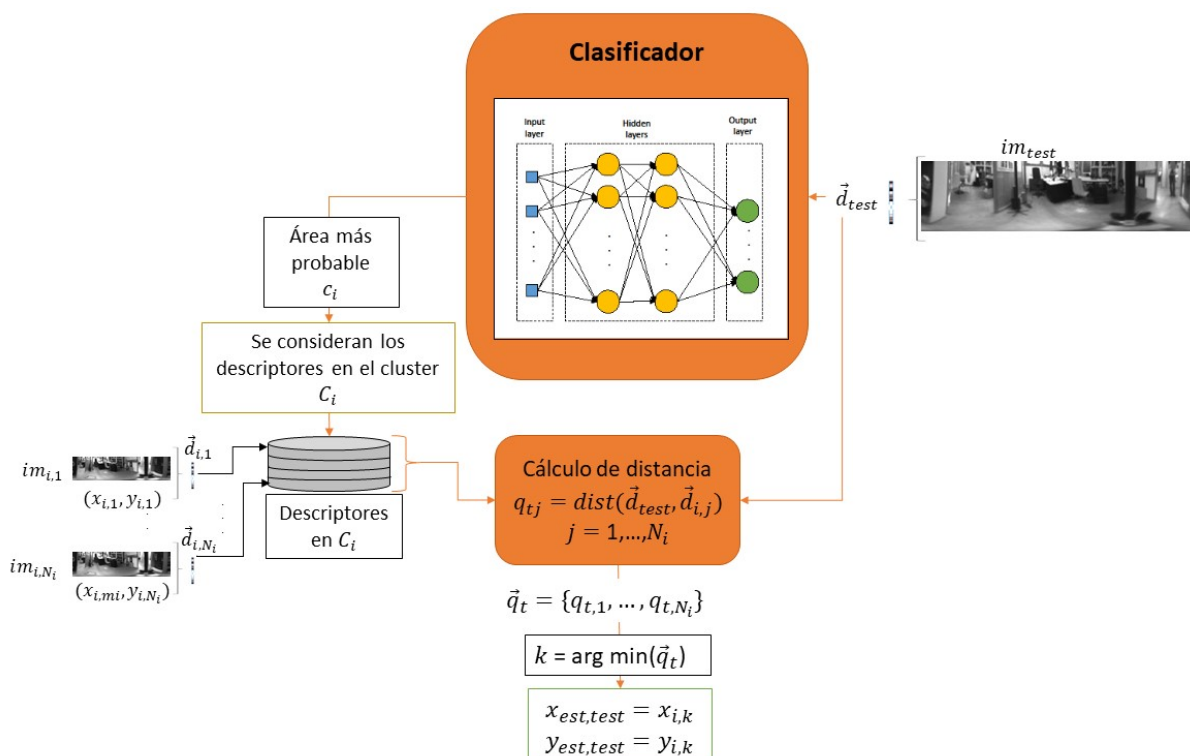


Figura 2: Diagrama de localización jerárquica. Se resuelve la localización gruesa mediante un clasificador para predecir el área más probable en el mapa. La localización fina se resuelve comparando los descriptores contenidos en el área seleccionada a través de un proceso de *image retrieval*.

Cuadro 1: Resultados experimento 1. Ratio de acierto de las configuraciones clasificador + Descriptor estudiadas respecto a datos del dataset de testeo.

| Tipo de clasificador | Descriptor | Ratio de acierto(%) |
|----------------------|------------|----------------------|
| Naïve Bayes | gist | 0,8674373796 |
| Naïve Bayes | CNN-fc7 | 0,8612716763 |
| Naïve Bayes | HOG | 0,04238921002 |
| Neural Network | gist | 0,9857418112 |
| Neural Network | CNN-fc7 | 0,9741811175 |
| Neural Network | HOG | 0,04971098266 |
| SVM | gist | 0,9861271676 |
| SVM | CNN-fc7 | 0,9849710983 |
| SVM | HOG | 0,07244701349 |

zación es correcta en la mayoría de casos y que los fallos se producen en su mayoría por el pasillo, lo cual se debe a las dimensiones y a la diferencia visual entre las imágenes que componen esta estancia.

4.3. EXPERIMENTO 2: LOCALIZACIÓN JERÁRQUICA

El experimento anterior ha demostrado que los clasificadores propuestos pueden utilizarse para

| | Estancia predicha | | | | | | | | | |
|--------------------|--------------------|---------|---------|-----------------|-----------------|-----------------|--------------|--------|-------------------|--------|
| | Sala de impresoras | Pasillo | Cocina | Despacho grande | Despacho 2-P #1 | Despacho 2-P #2 | Despacho 1-P | Baño | Zona de escaleras | |
| Sala de impresoras | 219 | 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 98,21% |
| Pasillo | 0 | 1039 | 0 | 0 | 2 | 1 | 1 | 0 | 1 | 99,52% |
| Cocina | 0 | 1 | 254 | 0 | 0 | 0 | 0 | 0 | 0 | 99,61% |
| Despacho grande | 0 | 4 | 0 | 171 | 0 | 0 | 0 | 0 | 0 | 97,71% |
| Despacho 2-P #1 | 0 | 5 | 0 | 0 | 227 | 0 | 0 | 0 | 0 | 97,84% |
| Despacho 2-P #2 | 0 | 4 | 0 | 0 | 0 | 126 | 1 | 0 | 0 | 96,18% |
| Despacho 1-P | 0 | 0 | 0 | 0 | 0 | 2 | 152 | 0 | 0 | 98,70% |
| Baño | 0 | 4 | 0 | 0 | 0 | 0 | 0 | 242 | 1 | 97,98% |
| Zona de escaleras | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 3 | 129 | 96,27% |
| | 100,00% | 97,74% | 100,00% | 100,00% | 99,13% | 97,67% | 98,70% | 98,78% | 98,47% | |

Figura 3: Matriz de confusión del clasificador SVM mediante el uso del descriptor *gist* para estimar la estancia correspondiente para las imágenes del dataset de testeo.

llevar a cabo la localización gruesa dentro del proceso de localización jerárquica propuesto (sec. 3). En este experimento se pretende implementar el proceso completo de localización jerárquica, es decir, añadir el paso de localización fina. Este proceso ya ha sido testeado en trabajos previos ([2]) y ha demostrado ser una alternativa eficiente para resolver la tarea de localización en robótica móvil. En resumen, los pasos que se llevan a cabo en este proceso de localización jerárquica son los siguientes: (1) la localización gruesa se resuelve mediante el uso de clasificadores (tal como se ha estudiado en 4.2) y se estima la estancia más proba-

ble. Tras esto, (2) la localización fina se resuelve comparando la información de la imagen a testear únicamente con la información correspondiente a las imágenes de entrenamiento contenidas en la estancia estimada (image retrieval).

Para evaluar el proceso de localización jerárquica propuesto, se utilizan los clasificadores SVM y la red neuronal y los descriptores *gist* y CNN-fc7, dado que estas configuraciones generaron los mejores resultados en el experimento anterior. Por otro lado, para comparar con métodos llevados a cabo en trabajos previos, se propone también la localización jerárquica llevada a cabo mediante el uso de descriptores representativos para la localización gruesa (tal y como se hizo en [2]). Para este método, en primer lugar se lleva a cabo un algoritmo de clustering espectral, el cual agrupa la información de descripción con respecto a la similitud entre las imágenes. Una vez agrupada la información, se obtiene un representativo por grupo; dicho representativo se calcula como la media de los descriptores contenidos en el grupo. De esta manera, la localización gruesa también está basada en un problema de image retrieval pero a un nivel menor de precisión (a cambio de un menor tiempo de computo). Para este caso, se decide que el algoritmo de clustering agrupe la información en 9 clusters ($n_c = 9$) y así poder equiparar los resultados obtenidos. Además, se propone utilizar una de las mejores soluciones obtenidas mediante este método: clustering espectral mediante el uso del descriptor *gist* y localización mediante el uso del descriptor HOG. La evaluación de este experimento se lleva a cabo con el dataset de imágenes de test y se medirá la eficiencia de localización mediante el error medio de localización (distancia media entre la posición estimada y la posición real de la imagen test) y el tiempo medio de computo para estimar la posición del robot (calcular el descriptor, estimar la estancia/el área y estimar la posición dentro de esa estancia/área). Los experimentos se han realizado con un PC con CPU Intel Core i7-7700 ® @ 3,6 GHz y mediante el software Matlab ®.

La fig. 4 muestra los valores obtenidos para los métodos de localización jerárquica. Se muestra el error medio y tiempo medio de localización. Los métodos propuestos mediante el uso de clasificadores son (1) red neuronal con descriptor *gist* (NN+*gist*), (2) red neuronal con descriptor CNN-fc7 (NN+CNN-fc7), (3) SVM con descriptor *gist* (SVM+*gist*) y (4) SVM con descriptor CNN-fc7 (SVM+CNN-fc7). Por último, se muestra el método basado en representativos obtenidos a través de clustering espectral (Clustering Esp.+HOG) (5) y representa los resultados obtenidos cuando el número de clusters es 9. De esta gráfica se concluye

que la localización basada en clasificadores presenta soluciones más eficientes que la localización basada en descriptores representativos. Por un lado, los resultados obtenidos mediante el clasificador de red neuronal son los que proporcionan un menor tiempo de computo; por otro lado, pese a que el tiempo de computo es mucho mayor para el clasificador SVM (más que incluso los obtenidos con el método de clustering espectral), el error de localización obtenido es mucho menor, alcanzándose el mínimo para la configuración SVM+*gist* (error medio de 5,09 cm).




Figura 4: Comparación entre métodos de localización jerárquica mediante el uso de clasificadores o representativos para resolver la localización gruesa.

5. CONCLUSIONES

Este trabajo presenta un estudio llevado a cabo para resolver la tarea de localización jerárquica en robótica móvil mediante el uso de clasificadores de categorías basados en machine learning. Los clasificadores son utilizados para llevar a cabo el mapping correspondiente al mapa de alto nivel que compone el modelo topológico jerárquico. Se han evaluado tres clasificadores: Naïve Bayes, red neuronal y SVM. Además, los clasificadores reciben como entrada información visual mediante descriptores de apariencia global. Los descriptores propuestos para evaluar los clasificadores han sido: HOG, *gist* y un descriptor obtenido a partir de la capa 'fc7' de la CNN *places* (CNN-fc7). Los experimentos han sido realizados mediante el uso de un dataset que contiene imágenes panorámicas en entornos de interior con cambios dinámicos. Para medir la efectividad de acierto de los clasificadores propuestos, se calcula el ratio de acierto y para medir la eficiencia que presenta estos métodos para llevar a cabo la localización jerárquica, se utiliza el error medio de localización y el tiempo medio para estimar la pose. Los resultados obtenidos muestran que tanto el clasificador SVM como la red neuronal presentan un ratio de acierto lo suficientemente elevado para poder realizar la tarea de localización. Por otro lado, se ha probado que

el uso de los clasificadores mejora la eficiencia para realizar la localización jerárquica en comparación con otros métodos probados en anterioridad basados en el uso de descriptores representativos. Ya que, tanto el error de localización como el tiempo de cómputo se ven reducidos en comparación con los resultados recogidos mediante el método de clustering espectral (para un mismo nivel de precisión en la capa alta del mapa jerárquico).

En futuros trabajos, se extenderá este estudio comprobando la validez de estos métodos ante cambios de iluminación y efectos nocivos sobre las imágenes capturadas. Por otro lado, se estudiará el uso de otras herramientas de *machine learning* para conseguir soluciones más robustas.

Agradecimientos

Este trabajo está cofinanciado por la Unión Europea a través del Programa Operativo del Fondo Social Europeo (FSE) de la Comunitat Valenciana 2014-2020 a través de su beca predocctoral ACIF/2017/146 y ACIF/2018/224 y gracias al Ministerio de Ciencia e Innovación a través del proyecto DPI 2016-78361-R (AEI/FEDER, UE): “Creación de mapas mediante métodos de apariencia visual para la navegación de robots.”

English summary

USE OF MACHINE LEARNING TECHNIQUES TO TACKLE MAPPING IN MOBILE ROBOTICS

Abstract

This work introduces a study regarding the use of several classifiers based on machine learning tools to carry out the mapping and localization task in mobile robotics. These classifiers are used to solve the rough localization, which is part of the hierarchical localization process. Therefore, the localization tackled by the robot consists in (1) obtaining an image from an unknown position, (2) calculating its related global appearance descriptor, (3) putting this information into the classifier to estimate the current room. Afterwards, (5) the robot carries out the image retrieval problem with all the visual information provided by the training dataset contained in the selected room (fine localization step). This work evaluates the use of three types of classifiers (Naïve Bayes, SVM and a classifier based on neural networks) which are trained with three possible global appearance descriptors (HOG, gist and a descriptor calculated from a CNN). The experiments are carried out through the use of a dataset which contains omnidirectional images captured indoor under dynamic changes (people walking, furniture changes, etc.). The results obtained show that this method proposed is an efficient alternative to tackle the hierarchical localization regarding the localization error and the computing time.

Keywords: Mapping, Hierarchical Localization, Omnidirectional Images, Global Appearance Descriptors, Machine Learning.

Referencias

- [1] S. Cebollada, L. Payá, W. Mayol, and O. Reinoso. Evaluation of clustering methods

- in compression of topological models and visual place recognition using global appearance descriptors. *Applied Sciences*, 9(3):377, 2019.
- [2] S. Cebollada, L. Payá, V. Román, and O. Reinoso. Hierarchical localization in topological models under varying illumination using holistic visual descriptors. *IEEE Access*, 7:49580–49595, 2019.
- [3] C. Cortes and V. Vapnik. Support-vector networks. *Machine Learning*, 20(3):273–297, Sep 1995.
- [4] M. Duguleana and G. Mogan. Neural networks based reinforcement learning for mobile robots obstacle avoidance. *Expert Systems with Applications*, 62:104 – 115, 2016.
- [5] H. Korrapati and Y. Mezouar. Multi-resolution map building and loop closure with omnidirectional images. *Autonomous Robots*, 41(4):967–987, 2017.
- [6] U. Luxburg. A tutorial on spectral clustering. *Statistics and Computing*, 17:395–416, 2007.
- [7] M. Mancini, S. R. Bulò, E. Ricci, and B. Caputo. Learning deep nbnn representations for robust place categorization. *IEEE Robotics and Automation Letters*, 2(3):1794–1801, 2017.
- [8] M. E. Maron. Automatic indexing: An experimental inquiry. *J. ACM*, 8(3):404–417, July 1961.
- [9] L. Payá, F. Amorós, L. Fernández, and O. Reinoso. Performance of global-appearance descriptors in map building and localization using omnidirectional vision. *Sensors*, 14(2):3033–3064, 2014.
- [10] L. Payá, A. Peidró, F. Amorós, D. Valiente, and O. Reinoso. Modeling environments hierarchically with omnidirectional imaging and global-appearance descriptors. *Remote Sensing*, 10(4):522, 2018.
- [11] A. Pronobis and B. Caputo. COLD: COsy Localization Database. *The International Journal of Robotics Research (IJRR)*, 28(5):588–594, May 2009.
- [12] V. Román, L. Payá, and O. Reinoso. Evaluating the robustness of global appearance descriptors in a visual localization task, under changing lighting conditions. In *ICINCO 2018. 15th International Conference on Informatics in Control, Automation and Robotics, Porto (Portugal), 29-31 July 2018*, pages 258–265, 2018.
- [13] R. Triebel, Hugo Grimmer, Rohan Paul, and Ingmar Posner. *Driven Learning for Driving: How Introspection Improves Semantic Mapping*, pages 449–465. Springer International Publishing, Cham, 2016.
- [14] J. Xu, L. Xiang, Q. Liu, H. Gilmore, J. Wu, J. Tang, and A. Madabhushi. Stacked sparse autoencoder (ssae) for nuclei detection on breast cancer histopathology images. *IEEE Transactions on Medical Imaging*, 35(1):119–130, 2016.
- [15] Y. Zhang and L. Wu. Classification of fruits using computer vision and a multiclass support vector machine. *Sensors*, 12(9):12489–12505, 2012.
- [16] B. Zhou, A. Lapedriza, J. Xiao, A. Torralba, and A. Oliva. Learning deep features for scene recognition using places database. In *Advances in Neural Information Processing Systems*, pages 487–495, 2014.
- [17] X. Zhou, Z. Su, D. Huang, H. Zhang, T. Cheng, and J. Wu. Robust global localization by using global visual features and range finders data. In *2018 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pages 218–223, Dec 2018.



© 2019 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC BY-NC-SA 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).