

# Sistema de Inteligencia Ambiental para el Monitoreo Remoto de Adultos Mayores

Darío Weitz<sup>1</sup>, Nicole Schmidt<sup>1</sup>, Denis Ezequiel María<sup>1</sup>, Franco Lianza<sup>1</sup>, Juan Pablo Nant<sup>1</sup>, Sara Feldman<sup>2</sup>

*Departamento Ingeniería en Sistemas de Información*

<sup>1</sup>*Facultad Regional Rosario – Universidad Tecnológica Nacional*

<sup>2</sup>*Facultad de Ciencias Médicas – Universidad Nacional de Rosario*

*E. Zeballos 1341, 2000 Rosario, Santa Fe*

*dar.wtz@gmail.com*

## Resumen

*Una alternativa para afrontar los problemas derivados del envejecimiento de la población mundial radica en la utilización de sistemas de inteligencia ambiental. Las actividades de la vida diaria (AVD) son aquellas tareas que el ser humano realiza de forma cotidiana y cuya no realización supone mayor o menor grado de discapacidad lo que le lleva a depender de terceras personas. Los sistemas de inteligencia ambiental permiten hacer un seguimiento automático de un cierto número de AVD; se busca detectar cambios en la frecuencia o en la duración de las mismas para actuar como sistema de alerta temprana. El reconocimiento de las AVD de adultos mayores mediante datos aportados por redes de sensores inalámbricos es una tarea de clasificación supervisada. Se describe la incorporación a un sistema de inteligencia ambiental de un algoritmo de aprendizaje supervisado utilizado para entrenar una función de clasificación para el reconocimiento automático de AVD de un adulto mayor que vive solo en su residencia habitual. Además, el sistema incluye un algoritmo de lógica difusa para modelizar las variaciones en la frecuencia y duración de algunas AVD con la temperatura y humedad ambiente, con el objetivo de permitir un mejor entrenamiento de la función de clasificación.*

## 1. Introducción

Los adultos mayores se han convertido en las últimas décadas en un grupo etario de alto crecimiento demográfico. Estimaciones de las Naciones Unidas pronostican que la población adulta mayor a 65 años aumentará 181% entre los años 2010 al 2050; en el mismo período, la población del rango 15 – 65 años sólo aumentará aproximadamente un 33% [1]. Suele definirse

al envejecimiento como un proceso biológico caracterizado por un desarrollo progresivo inversamente proporcional entre la funcionalidad y la vulnerabilidad.

Una alternativa para afrontar los problemas derivados del envejecimiento de la población consiste en la utilización de los denominados sistemas de inteligencia ambiental. Se define a un ambiente inteligente como aquel capaz de adquirir y aplicar conocimientos sobre el ambiente y sus residentes con el objetivo de mejorar las experiencias de los mismos en tal ambiente [2]. En el caso de adultos mayores, en particular de aquellos que sufren de enfermedades crónicas, los sistemas de inteligencia ambiental cumplen una doble función: (i) aumentar la seguridad y la sensación de protección de las personas para que las mismas vivan de forma independiente; (ii) permitir a las personas mayores disfrutar de autonomía durante más tiempo, mejorando su calidad de vida.

Las actividades de la vida diaria (AVD) son parámetros que se utilizan para estimar el nivel de autonomía e independencia de un individuo. Son aquellas tareas que el ser humano realiza de forma cotidiana, y cuya no realización supone mayor o menor grado de discapacidad (pérdida de funcionalidad) lo que le lleva a depender de terceras personas [3]. Numerosos profesionales del área salud consideran que la identificación de cambios en las AVD es una de las maneras para detectar la aparición de enfermedades en sus primeras fases.

Las actividades que habitualmente realizan los seres humanos se clasifican en tres grupos claramente diferenciados: i) AVD Básicas (AVDB), relacionadas al autocuidado y movilidad —dormir, alimentarse, higiene, desplazarse por el ambiente, salir al exterior—; ii) AVD Instrumentales (AVDI), realizadas para interactuar con el entorno más inmediato —uso de electrodomésticos, conversaciones telefónicas, prendido del televisor,

limpieza general del hábitat—; iii) AVD Avanzadas (AVDA), aquellas relacionadas con el trabajo y el tiempo libre [4]. Estas actividades (principalmente las básicas e instrumentales) se realizan un número significativo de veces a lo largo del día.

Los sistemas de inteligencia ambiental, conformados por componentes físicos y entidades de software, permiten hacer un seguimiento automático de un cierto número de AVD. Se busca detectar cambios en la frecuencia o en la duración de las mismas para actuar como sistema de alerta temprana, y así prevenir la ocurrencia de un evento severo de salud.

En trabajos previos, Weitz et al. [5], [6] proponen una red de sensores inalámbricos para el monitoreo de las AVD de un adulto mayor que vive solo en su residencia habitual. Se seleccionó un conjunto de sensores de bajo costo, fácil instalación, mínimos requerimientos de mantenimiento y bajo consumo energético. La arquitectura del sistema corresponde a una topología de tres capas: capa de percepción, capa de procesamiento y capa de aplicación. Los sensores se conectan mediante una topología malla y se comunican mediante el protocolo ZigBee (IEEE 802.15.4). La evaluación del sistema propuesto se realizó mediante un modelo de simulación dada la natural dificultad de realizar experimentos intrusivos y de larga duración en domicilios de adultos mayores con enfermedades crónicas. El sistema permite generar resúmenes gráficos a partir de enormes cantidades de datos de sensores y presentar información resumida a familiares y proveedores de salud mediante aplicaciones web.

El objetivo del presente trabajo es ampliar las propuestas descritas en [5] y [6], relacionadas con tecnologías para el monitoreo y la asistencia remota de adultos mayores con enfermedades crónicas, mediante la incorporación de un algoritmo de aprendizaje supervisado utilizado para entrenar una función de clasificación para el reconocimiento automático de AVD de un adulto mayor que vive solo en su residencia habitual. Dada la notable influencia que tienen los factores climáticos en las AVD de los adultos mayores, se incorporó en el modelo de simulación un algoritmo de lógica difusa para modelizar las variaciones en la frecuencia y duración de algunas AVD con la temperatura y humedad ambiente, con el objetivo de permitir un mejor entrenamiento de la función de clasificación.

## 2. Modelo de Simulación

El modelo de simulación fue desarrollado utilizando el lenguaje de programación C#. El framework de desarrollo utilizado fue Microsoft Visual Studio 2012. Para la construcción de gráficos y curvas se utilizó la librería ZedGraph. El modelado de la vista 3D se realizó

mediante el software SketchUp Pro 2015, utilizando componentes de la galería 3D Warehouse. El renderizado del modelo se realizó con el software SU Podium V2.5 Plus. Las líneas de redes de sensores se dibujaron mediante Visual Basic Power Packs Line and Shape controls. El motor de base de datos para el almacenamiento de datos y resultados fue Microsoft SQL Server 2008.

El algoritmo de simulación se desarrolló según el esquema de modelado de simulación de eventos discretos que utiliza el enfoque exploración de actividades [7]. Es una clase de modelo de simulación dinámico, discreto y estocástico. El enfoque exploración de actividades enfatiza una revisión de todas las actividades presentes en la simulación para determinar cuál puede iniciarse o finalizar al siguiente avance del reloj de la simulación. Se define a la actividad con un par de eventos: uno que inicia y otro que completa una operación que transforma el estado de una entidad. Las actividades tienen duraciones finitas y los cambios de estado se observan al comienzo o al final de la misma.

El modelo de simulación consta de tres componentes principales: i) el habitante de la residencia cuyas actividades diarias son monitoreadas; ii) la residencia simulada; iii) redes de sensores inalámbricos. El modelo está restringido a la simulación de una sola persona; no se considera una restricción importante debido a que la coexistencia de dos o más personas en una residencia permite una mutua evaluación del estado de salud superior al de cualquier sistema de información. La residencia simulada consta de un dormitorio, un baño, un estudio con computadora, un living con televisor y una cocina equipada que incluye una mesa y silla. Las redes de sensores inalámbricas se encargan de registrar el conjunto de AVD que desarrolla el habitante virtual de la residencia simulada (Figura. 1).



Figura 1. Residencia simulada.

Un módulo de gestión de sensores permite la incorporación de diversos tipos, marcas, modelos y

proveedores de sensores de movimiento, temperatura, humedad, ocupación de cama y/o sillón. También sensores magnéticos de apertura de puertas, de sonido, fotocontrol y detectores de humo, gas natural y monóxido de carbono. El sistema permite configurar la probabilidad de ocurrencia de un siniestro (incendio, pérdida de gas, etc.), distribuyendo esa probabilidad entre las diferentes habitaciones de la residencia.

La simulación procede según un mecanismo de cuatro etapas: i) generación de la secuencia de actividades; ii) avance del tiempo simulado al tiempo de ocurrencia de la próxima actividad; iii) activación de los correspondientes sensores; iv) almacenamiento en base de datos del tiempo simulado, actividad y sensores activados. Una de las suposiciones fundamentales del modelo propuesto es que la secuencia de actividades se genera a partir de distribuciones de probabilidad específicas para cada AVD. Tales distribuciones de probabilidad se obtuvieron analizando datos empíricos y ajustando esos datos mediante el software Cristal Ball [7]. Se recolectó información de AVD mediante el llenado de un formulario de actividades que realizó durante seis meses una mujer de 81 años que vive sola en su residencia habitual [5]. Si el tiempo de ocurrencia de una o más actividades se solapan con otra actividad en proceso, el algoritmo coloca a las primeras en una cola de espera y procede a ejecutarlas según un esquema FIFO. Se incluyó un esquema de animación para mejorar la representación de la secuencia de actividades que realiza el residente del hábitat simulado.

### 3. Modelo de Actividades Diarias

Los sistemas de inteligencia ambiental se enfocan en las necesidades de los seres humanos, para lo cual requieren de información relacionada con las actividades que los mismos realizan. El reconocimiento de actividades es la metodología computacional más utilizada para el monitoreo de pacientes con enfermedades crónicas. Existen diferentes alternativas metodológicas dependiendo de las tecnologías de sensores utilizadas, de los algoritmos de aprendizaje empleados para modelar a las actividades y de la complejidad de las actividades humanas que se pretende modelizar [8].

Las actividades que los seres humanos realizan en su vida diaria pueden ser segmentadas y caracterizadas con diferentes niveles de detalle. La elección del correspondiente nivel depende fundamentalmente de las herramientas tecnológicas y de las aplicaciones informáticas que se dispongan para tal fin. Cierta tipo de actividades pueden ser determinadas con relativa precisión a través de la información suministrada por sensores sencillos, aunque los datos generados por los mismos suelen ser ruidosos y presentar comportamientos

no determinísticos. Además, las actividades humanas exhiben una naturaleza muy compleja: actividades intercaladas, simultáneas, ambiguas, duración desconocida, realización de un modo personal y diferente a otros, etc.

Pese a lo anterior, se han desarrollado diversos modelos de actividad que permiten interpretar los datos de sensores para inferir actividades desarrolladas por seres humanos. Los modelos de actividad se construyen a partir de los siguientes métodos [9]: i) métodos data-driven que involucran la creación de modelos estadísticos o probabilísticos a partir de conjuntos de datos representativos de las actividades de los usuarios, seguido de procesos de entrenamiento y aprendizaje. Estos métodos utilizan técnicas de minería de datos y de aprendizaje automatizado para inferir la actividad a partir de la información que proveen los diferentes sensores. Tienen la ventaja de manejar información temporal y con incertidumbre, pero sufren problemas de escalabilidad y reusabilidad; ii) métodos knowledge-driven caracterizados por explotar el conocimiento previo del dominio de interés para construir de manera directa modelos de actividad a partir de técnicas de ingeniería del conocimiento. Tienen la ventaja de ser semánticamente claros, lógicamente elegantes y fáciles para iniciar, pero tienen severas debilidades en lo que concierne al manejo de información temporal y con incertidumbre, y se los considera estáticos e incompletos [10].

Los métodos data-driven se clasifican en dos grupos: i) aprendizaje generativo; ii) aprendizaje discriminativo [9]. Los métodos de aprendizaje generativo tienen como objetivo la obtención de un esquema que contenga la descripción del espacio de características del problema; los modelos ocultos de Markov (HHM, Hidden Markov Models) constituyen la técnica más popular en este tipo de métodos que incluyen información temporal. Por su parte, los métodos de aprendizaje discriminativo tienen como objetivo desarrollar un modelo que establezca una correspondencia entre los datos de los sensores y la actividad a reconocer; las redes neuronales artificiales (RNA), las máquinas de soporte vectorial (SVM, Support Vector Machines) y los campos aleatorios condicionales (CRF, Conditional Random Fields) son los algoritmos más utilizados en este grupo de métodos.

Ordoñez [11], en su análisis del modelado ubicuo del comportamiento para la asistencia de personas mayores en el hogar, indica que las redes neuronales artificiales proporcionan un aprendizaje de tipo discriminativo muy superior al de sus equivalentes generativos basado en los siguientes motivos: i) los métodos discriminativos reducen la posibilidad de realizar clasificaciones incorrectas; ii) modelan vectores de gran dimensionalidad; iii) no requieren asumir independencia entre los atributos; iv) al considerar los datos de entrada

en su conjunto, se los utiliza para formular un modelo no paramétrico de las correspondientes distribuciones de probabilidad; v) las salidas son valores que representan probabilidades, por lo cual pueden combinar datos diferentes mediante técnicas apropiadas de integración; vi) son robustos a pesar de un número insuficiente de datos muestreados. Por otra parte, las redes neuronales han sido utilizadas en redes de sensores inalámbricos para tareas de aproximación, fusión y clasificación de datos [12]. Habitualmente se emplea la técnica backpropagation, con un significativo conjunto de muestras de entrenamiento unido al tiempo de evolución necesario para mapear exhaustivamente los datos hasta obtener una aproximación relativamente precisa.

#### **4. Reconocimiento de AVD con Redes Neuronales Artificiales**

Las RNA se utilizan en una amplia variedad de aplicaciones. Desde el punto de vista del dominio de aplicación, se las puede agrupar en cuatro categorías generales: i) clasificación: consiste en dividir un espacio n-dimensional en varias regiones y al darle un punto del espacio, la RNA responde con la región a la que pertenece; ii) predicción: la RNA se entrena con una secuencia de valores conocidos para producir salidas que son las esperadas frente a una entrada particular; iii) agrupamiento (clustering): se utiliza cuando se necesita clasificar datos para los cuales no se tiene a priori categorías obvias. Las RNA son capaces de agrupar los datos en diferentes categorías sin tener conocimiento previo sobre ellas; iv) asociación: ciertas RNA se diseñan para “recordar” distintos patrones, y ante una determinada entrada, se las asocia con el patrón más cercano en su memoria.

El reconocimiento de las actividades humanas, en particular de adultos mayores con rutinas de escasa variabilidad, mediante datos aportados por redes de sensores inalámbricos puede enmarcarse como una tarea de clasificación supervisada. Por tal motivo se decidió utilizar una RNA con arquitectura feed-forward provista por el software Matlab®, implementando el Neural Net Pattern Recognition de dicha herramienta en el modelo de simulación previamente descripto.

Dicha arquitectura presenta las siguientes características:

1. Las neuronas están organizadas en capas: La primera capa toma los datos y la última emite las salidas, mientras que las capas intermedias no tienen interacción con el exterior por lo que se conocen como capas ocultas.

2. Una neurona en una capa está conectada con cada una de las neuronas de la capa siguiente y no existen conexiones entre neuronas de la misma capa, por lo que la información es constantemente enviada de una capa hacia la siguiente.

El aprendizaje se realiza alimentando la RNA con pares de valores de entrada-salida durante múltiples ciclos, por lo que la red aprende la relación entre las mediciones de los sensores y la actividad realizada por la persona monitoreada.

El modelo de simulación genera varios registros con los datos sensados por cada minuto simulado. El registro posee 13 columnas: día, hora, ubicación, movimiento, gas, humo, CO, temperatura, humedad, ocupación, fotocontrol, sonido, puerta de entrada, y se lo utiliza como vector de entrada para el aprendizaje de la red. El vector de salida posee 12 columnas, correspondientes a AVD básicas (dormir, siesta, baño, desayunar, almorzar, merendar, cenar, salir) y AVD instrumentales (uso de computadora, TV, teléfono, mate).

Basado en lo anterior, se utilizó una red con 13 neuronas en la capa de entrada y 12 neuronas en la capa de salida. Respecto a la capa oculta, se decidió utilizar 12 neuronas basado en la regla empírica que establece: “el tamaño óptimo de la capa oculta está generalmente entre el tamaño de la capa de entrada y el tamaño de la capa de salida” [13].

Se simularon 3 meses comenzando desde el primero de junio, obteniendo un total de 430.845 registros de sensores. Dichos registros fueron preprocesados y se utilizaron para el entrenamiento de la RNA. El conjunto de datos sensados se dividió en 3 subconjuntos: entrenamiento, validación y evaluación. Para nuestro caso, utilizamos una división del 70%, 15% y 15% respectivamente.

Para el entrenamiento se utilizó el algoritmo Scaled Conjugate Gradient Backpropagation. Se midió el rendimiento con el método Cross-Entropy (Figura 2).

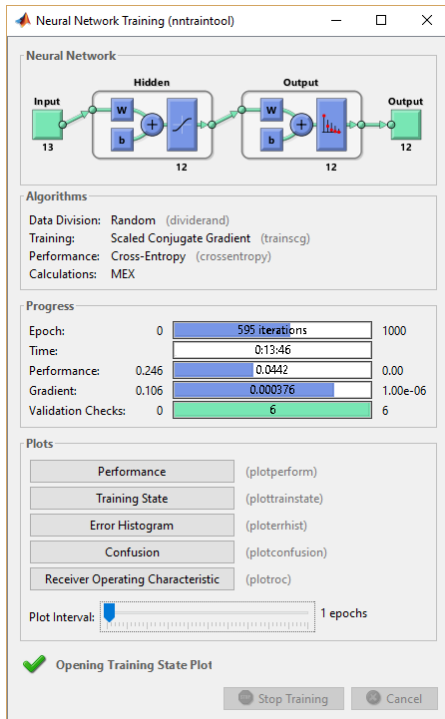


Figura 2. Arquitectura y entrenamiento de la RNA.

La matriz de confusión (Figura 3), estimador de la exactitud de la clasificación, muestra que la RNA tiene una tasa de reconocimiento global del 83.0%. Las AVD básicas muestran un alto nivel de precisión (“Sst”, AVD Siesta muestra un 78.3% de precisión y 88.5% de cobertura) pero algunas coberturas son deficientes (baño, cenar). La RNA no clasifica a las AVD instrumentales Mate y Teléfono.

		Confusion Matrix												
		Drm	Sst	Dsy	Alm	Mrn	Cnr	Baño	TV	PC	Mate	Tel	Ext	
Output Class	Drm	19874 27.7%	0 0.0%	3 0.0%	0 0.0%	0 0.0%	220 0.1%	1517 0.4%	744 0.2%	173 0.0%	0 0.0%	0 0.0%	97.8%	
	Sst	0 0.0%	14260 3.3%	0 0.0%	650 0.2%	240 0.1%	0 0.0%	214 0.0%	1429 0.3%	1283 0.3%	139 0.0%	2 0.0%	3 0.0%	78.3%
	Dsy	0 0.0%	0 0.0%	4379 1.0%	0 0.0%	0 0.0%	124 0.0%	0 0.0%	809 0.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	82.4%
	Alm	0 0.0%	513 0.1%	0 0.0%	14076 3.2%	20 0.0%	0 0.0%	304 0.1%	2431 0.6%	1311 0.3%	235 0.1%	12 0.0%	0 0.0%	74.5%
	Mrn	0 0.0%	160 0.0%	0 0.0%	9780 2.3%	50 0.0%	1 0.0%	595 0.1%	2315 0.5%	1138 0.3%	147 0.0%	204 0.1%	563 0.1%	65.4%
	Cnr	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 0.0%	16615 3.8%	493 0.1%	3090 0.7%	2294 0.5%	222 0.1%	306 0.1%	0 0.0%	72.1%
	Baño	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2409 0.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
	TV	445 0.1%	390 0.1%	4484 1.0%	342 0.1%	1741 0.4%	3073 0.7%	1238 0.3%	63948 14.8%	11704 2.7%	5696 1.3%	2575 0.6%	0 0.0%	86.9%
	PC	101 0.0%	576 0.1%	1098 0.3%	930 0.2%	618 0.1%	611 0.1%	1475 0.3%	6811 1.6%	98283 22.7%	1511 0.3%	666 0.2%	499 0.1%	36.8%
	Mate	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN%
	Tel	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN%
	Ext	0 0.0%	211 0.5%	0 0.0%	12 0.0%	1019 2.2%	0 0.0%	155 0.0%	1223 2.7%	506 1.1%	46 0.1%	0 0.0%	15912 100%	83.4%
	Global		99.5%	88.5%	43.9%	87.6%	72.8%	81.8%	33.3%	77.3%	83.2%	0.0%	0.0%	93.7%
	Coverage		0.5%	11.5%	56.1%	12.4%	27.2%	18.2%	66.7%	22.7%	16.8%	100%	6.3%	17.0%
Target Class		Drm	Sst	Dsy	Alm	Mrn	Cnr	Baño	TV	PC	Mate	Tel	Ext	

Figura 3. Matriz de confusión de la RNA.

La configuración actual de sensores no permite diferenciar AVD Mate y Teléfono de las AVD TV o Computadora. Como resultado, la matriz de confusión indica que no hay cobertura de las primeras. La baja cobertura de la AVD baño se debe a que la similitud entre registros de Baño ocupado y Baño desocupado (solo se diferencian en el valor binario de fotocontrol) no le permite a la RNA clasificarla apropiadamente.

## 5. Influencia del clima en las AVD de adultos mayores

El calor (acompañado de una alta humedad relativa ambiental) es uno de los principales factores a vigilar en los adultos mayores ya que sus mecanismos fisiológicos deteriorados pueden agravar un estado de hidratación deficiente. La manifestación más grave en este contexto es el golpe de calor, que acontece cuando los mecanismos de termorregulación del organismo se ven superados por una exposición excesiva a un ambiente caluroso unido a un consumo insuficiente de líquidos y unas pérdidas aumentadas. En estas condiciones de peligro ambiental, las actividades en el exterior suelen ser reducidas o completamente anuladas para evitar el golpe de calor.

Los adultos mayores no solo toleran mal al calor, sino que también presentan un déficit de adaptación a las bajas temperaturas externas. Al envejecer, la piel se adelgaza y se desnaturalizan los receptores cutáneos de temperatura, por lo que el anciano puede tener dificultad para percibir con certeza si tiene frío o calor [14]. Con las bajas temperaturas se observa un proceso de vasoconstricción que se traduce en un aumento de la presión arterial y consecuentemente un riesgo mayor de infarto agudo de miocardio. Diversas AVD se ven modificadas por las bajas temperaturas: aumento del tiempo de permanencia en la cama, reducción de las actividades en el exterior y correspondiente aumento de las mismas en el interior del hogar, perturbación del sueño, incremento en las idas al baño, etc.

Los sistemas de inteligencia ambiental que realizan un seguimiento automático de las AVD de adultos mayores, intentan detectar cambios en la frecuencia o en la duración de las mismas para actuar como sistema de alerta temprana, y así prevenir la ocurrencia de un evento severo de salud. Puesto que los factores climáticos también producen cambios en la frecuencia o en la duración de algunas AVD, es importante que los algoritmos de reconocimiento de actividades sean entrenados para reconocer esos cambios, de forma tal que los mismos no sean incorrectamente interpretados como el agravamiento de una enfermedad crónica. Por otra parte, puesto que el comportamiento de los seres humanos frente a los factores climáticos es confuso y variable, se decidió incorporar un algoritmo de lógica

difusa en el modelo de simulación para modelizar tales incertidumbres.

Lofti Zadeh, profesor de la Universidad de California, desarrolló en 1965 los postulados de la Lógica Borrosa o Lógica Difusa (Fuzzy Logic) para la formalización de modos de razonamiento que son aproximados y no exactos [15]. Una suposición clave en la lógica difusa es que numerosos conceptos del mundo real denotan conjuntos borrosos: clases de objetos en los que la transición de la pertenencia a la no pertenencia es gradual y no abrupta. Hay una graduación entre los niveles de verdad, incorporando un continuo infinito de estados intermedios entre proposiciones absolutamente falsas (0) y absolutamente verdaderas (1), dando lugar a proposiciones parcialmente ciertas con algún valor entre 0 y 1.

El algoritmo de lógica difusa utiliza como variables de estado (variables que describen las entradas al sistema) a temperatura y humedad relativa. Se utilizaron datos de temperatura y humedad medidos en el microcentro de la ciudad de Rosario durante el período setiembre de 2013 hasta agosto de 2014 en intervalos de 15 minutos y registrados mediante termo-higrómetros digitales y almacenados en data loggers Hobo U23-003 [16]. La Figura 4 muestra las etiquetas lingüísticas para la variable de estado humedad y las correspondientes funciones grado de verdad asociadas.

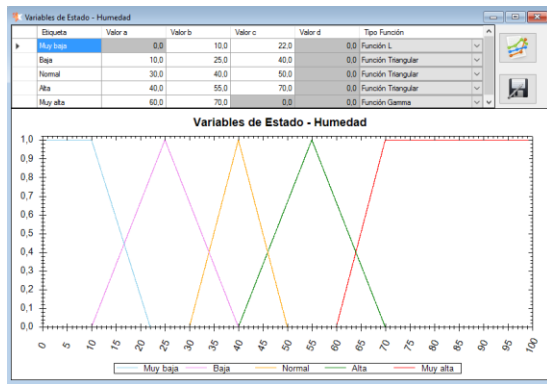


Figura 4. Variables de estado – Humedad relativa ambiente.

Las variables de control (variables que describen las salidas del sistema) corresponden a las AVD dormir y salir al exterior; se establecieron 7 etiquetas lingüísticas (con las correspondientes funciones asociadas) para cada una de ellas: Bajada Grande, Bajada Normal, Bajada Pequeña, Mantener, Subida Pequeña, Subida Normal, Subida Grande.

La Figura 5 muestra la matriz de asociación difusa para la variable de control dormir donde se vinculan las posibles combinaciones de las variables de estado (antecedentes) con una de sus etiquetas lingüísticas (consecuentes). Por ejemplo: IF (Temperatura es Muy

Baja AND Humedad es Muy Baja) THEN (AVD Dormir presenta Subida Pequeña).

Tempe	Muy baja	Baja	Normal	Alta	Muy alta
Muy baja	Subida Pequeña	Subida Normal	Subida Normal	Subida Grande	Subida Grande
Baja	Subida Pequeña	Subida Normal	Mantener	Mantener	Subida Normal
Normal	Mantener	Mantener	Mantener	Bajada Pequeña	Bajada Pequeña
Alta	Subida Pequeña	Subida Pequeña	Mantener	Bajada Pequeña	Bajada Pequeña
Muy alta	Subida Pequeña	Subida Pequeña	Subida Normal	Subida Normal	Subida Grande

Figura 5. Matriz de asociación difusa para la variable de control Dormir

Como parámetros de la inferencia difusa se utilizó Modus Ponens Difuso, operador de fuzzyficación singleton y operador de defuzzyficación centro de gravedad. El rango de variación difuso entre 0 y 1 se modificó para adaptarse a la situación de subidas y bajadas, adoptando valores entre -100% y 100% para proporcionar un valor porcentual que muestre el aumento o disminución de la duración de cada actividad. Las figuras 6 y 7 muestran que si la temperatura es 19,5°C y la humedad es 65%, entonces la AVD Dormir sufrirá una disminución de su duración en un 17% aproximadamente.

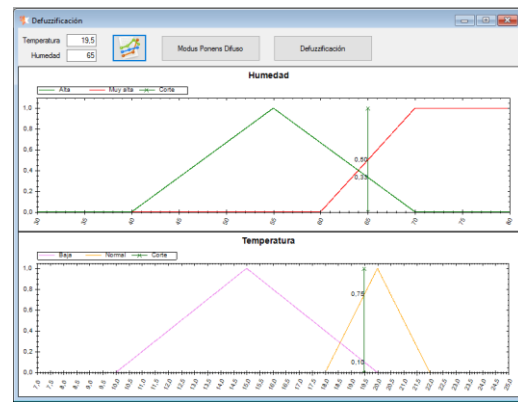


Figura 6. Defuzzyficación

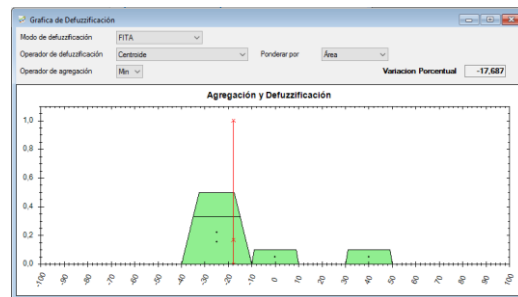


Figura 7. Defuzzyficación

El modelo de simulación se volvió a correr por 3 meses comenzando desde el primero de junio con la misma semilla pero con la agudización de los factores

climáticos. La matriz de confusión (Figura 8), obtenida a partir de entrenar la RNA con las nuevas mediciones de los sensores, muestra que la precisión global de la RNA no presenta cambios significativos con respecto a la anterior.

		Confusion Matrix												
		Drmm	Sst	Dsy	Alm	Mrm	Cnr	Baño	TV	PC	Male	Tel	Ext	
Output Class	Drmm	16657	0	1948	0	0	0	554	1803	425	108	0	0	97.2%
		39.1%	0.0%	0.5%	0.0%	0.0%	0.0%	0.1%	0.4%	0.1%	0.0%	0.0%	0.0%	2.8%
	Sst	0	14723	0	638	226	0	201	1347	1401	182	17	0	78.6%
		0.0%	3.5%	0.0%	0.1%	0.1%	0.0%	0.0%	0.3%	0.3%	0.0%	0.0%	0.0%	21.4%
	Dsy	808	0	6474	0	0	0	361	1121	1097	718	53	0	80.9%
		0.2%	0.0%	1.5%	0.0%	0.0%	0.0%	0.1%	0.3%	0.3%	0.2%	0.0%	0.0%	39.1%
	Alm	1	524	214	14157	10	0	351	2432	1424	329	45	0	72.6%
		0.0%	0.1%	0.1%	3.3%	0.0%	0.0%	0.1%	0.6%	0.3%	0.1%	0.0%	0.0%	27.4%
	Mrm	0	153	0	63	9824	0	559	2292	1477	207	220	799	83.0%
		0.0%	0.0%	0.0%	0.0%	2.3%	0.0%	0.1%	0.5%	0.3%	0.0%	0.1%	0.2%	37.0%
	Cnr	0	0	0	0	18	15194	512	2497	1560	151	203	437	73.9%
		0.0%	0.0%	0.0%	0.0%	0.0%	3.6%	0.1%	0.6%	0.4%	0.0%	0.0%	0.1%	26.1%
	Baño	0	0	0	0	0	0	2392	0	0	0	0	0	100%
		0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.6%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
TV	153	3	1231	262	1115	3901	1016	43280	6369	4846	2427	1098	85.9%	
	0.0%	0.0%	0.3%	0.1%	0.3%	0.9%	0.2%	10.2%	1.5%	1.1%	0.6%	0.3%	34.1%	
PC	213	508	97	916	718	793	1077	3971	73635	1384	708	1106	86.5%	
	0.1%	0.1%	0.0%	0.2%	0.2%	0.3%	0.9%	17.3%	0.3%	0.2%	0.3%	0.3%	13.5%	
Male	0	0	0	0	0	0	0	48	0	32	18	0	32.7%	
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	67.3%	
Tel	0	0	0	0	0	0	0	0	0	0	0	0	NaN%	
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	NaN%	
Ext	0	199	0	24	1217	0	153	1785	600	101	2	11731	74.2%	
	0.0%	0.0%	0.0%	0.0%	0.3%	0.0%	0.4%	0.1%	0.0%	0.0%	0.0%	2.8%	25.8%	
	99.3%	91.4%	85.0%	89.2%	74.8%	70.4%	33.3%	71.4%	83.7%	0.4%	0.0%	77.3%	84.1%	
	0.7%	8.6%	35.0%	11.8%	25.2%	23.6%	66.7%	28.6%	16.3%	99.6%	100%	22.7%	15.9%	
		Drmm	Sst	Dsy	Alm	Mrm	Cnr	Baño	TV	PC	Male	Tel	Ext	

Figura 8. Matriz de confusión para la nueva corrida de simulación.

El sistema genera un conjunto de resúmenes gráficos que ayudan al reconocimiento de actividades, al establecimiento de hábitos y pueden servir para la detección temprana de cambios en la conducta o en variables biomédicas. Las figuras 9 y 10 muestran los valores promedios de la ocupación de los diferentes ambientes en períodos de tres horas para una simulación de 90 días (junio, julio y agosto). Se observa en la figura 9 una mayor ocupación del dormitorio y menor tiempo de salida al exterior como resultado de las bajas temperaturas ambientales. La incorporación del algoritmo de lógica difusa mejora la modelización de las AVD incorporando la influencia de los factores climáticos en las mismas. De esta manera, se reduce la posibilidad de interpretar incorrectamente tales variaciones como un agravamiento de una enfermedad crónica.

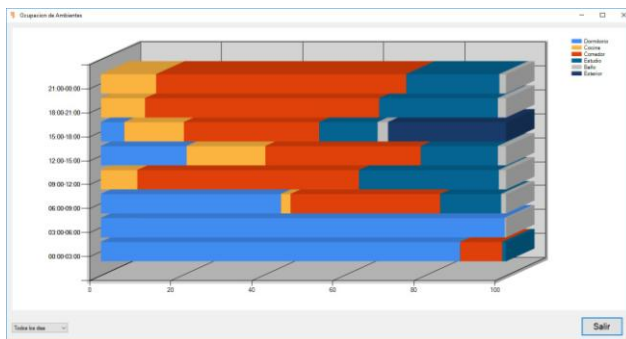


Figura 9. Ocupación ambientes sin influencia del clima .




Figura 10. Ocupación de ambientes con influencia de factores climáticos.

## 6. Conclusiones

La posibilidad de incorporar en la residencia habitual de un adulto mayor una red de sensores inalámbricos a un costo relativamente bajo y sin la necesidad de grandes reformas estructurales, resulta en una tecnología de monitoreo y asistencia remota que puede ser utilizada para supervisar de manera automática y ubicua. Este tipo de sistemas se puede instalar de manera relativamente oculta al usuario, reduciendo significativamente la intrusividad del mismo.

Las redes de sensores deben ir acompañadas de algoritmos que permitan el reconocimiento de actividades de la vida diaria, ya que las mismas sirven para estimar el nivel de autonomía e independencia de un individuo, y se las puede utilizar como sistemas de alerta temprana para evitar el agravamiento de una enfermedad crónica.

En el presente trabajo se describe la incorporación a un sistema de inteligencia ambiental de un algoritmo de aprendizaje supervisado utilizado para entrenar una función de clasificación para el reconocimiento automático de AVD de un adulto mayor que vive solo en su residencia habitual. Adicionalmente, el sistema incluye un algoritmo de lógica difusa para modelizar las variaciones en la frecuencia y duración de algunas AVD en función de la temperatura y humedad ambiente, con el objetivo de permitir un mejor entrenamiento de la función de clasificación.

El desarrollo de este tipo de sistemas de inteligencia ambiental es ampliamente beneficioso porque se enfocan de manera creciente en el bienestar y aumento en las expectativas de vida de los adultos mayores.

## 7. Referencias

[1] United Nations, Department of Economic and Social Affairs, Population Division: World Population Prospects: The

2012 Revision, Highlights and Advance Tables, Working Paper No. ESA/P/WP.228, 2013.

[2] Cook, D.J., Das, S.K., How Smart are our Environments? An Updated Look at the State of the Art, *Journal Pervasive and Mobile Computing*, Volume 3 Issue 2, pp 53-73, 2007.

[3] Katz, S., Ford, A.B., Moskowitz, R.W., Jackson, B.A., Jaffe, M.W., Studies of illness in the aged: the index of ADL, a standardized measure of biological and psychosocial function, 185:914-9, *JAMA* 1963.

[4] Horgas, A., Wilms, H., Baltes, M., Daily life in very old age, Everyday activities as expression of successful aging, *The Gerontologist*, 38(5), 556-567, 1998.

[5] Weitz, D., Lianza, F., Nant, J.P., Schmidt, N., María, D.E., "Modelo de Simulación 3D para la Evaluación de Tecnologías de Monitoreo y Asistencia para Adultos Mayores", 3er Congreso Nacional de Ingeniería Informática / Sistemas de Información, CONAIIISI 2015, Buenos Aires, 19 y 20 de Noviembre de 2015.

[6] Weitz, D., Lianza, F., Maria, D.E., Schmidt, N., Nant, J.P., Feldman, S., Red de Sensores Inalámbricos para el Monitoreo de Adultos Mayores, Congreso Argentino de Ciencias de la Computación (CACIC 2016), San Luís, 3 – 7 de octubre de 2016.

[7] Evans, J.R., Olson, D.L., Introduction to Simulation and Risk Analysis, Prentice Hall, 1998.

[8] Acampora, G., Cook, D.J., Rashidi, P., Vasilakos, A.V., "A survey on ambient intelligence in healthcare", *Proceedings of the IEEE*, 101(12), pp. 2470 – 2488, 2013.

[9] Chen, L., Hoey, J., Nugent, C.D., Cook, D., Yu, Z., Sensor-based Activity Recognition, SMCC-11-08-0375, *IEEE SMC-C Trans*, 2012.

[10] Chen, L., Nugent, C.D., "A Logical Framework for Behaviour Reasoning and Assistance in a Smart Home", *International Journal of Assistive Robotics and Mechatronics*, vol.9, no.4, pp.20-34, 2008.

[11] Ordoñez, F.J., Modelado Ubicuo del Comportamiento para la Asistencia de Personas Mayores en el Hogar, Tesis Doctoral, Departamento de Informática, Universidad Carlos III de Madrid, Leganes, Setiembre de 2013.

[12] Jabbari, A., Jedermann, R., Muthuraman, R., Lang, W., Application of Neurocomputing for Data Approximation and Classification in Wireless Sensor Networks, *Sensors*, 9, 3056-3077, 2009.

[13] Heaton, J., Introduction to Neural Networks for Java, 2nd Edition, Heaton Research Inc, 2008.

[14] Schapira, M., El impacto de las bajas temperaturas en los adultos mayores, <http://hirsch.org.ar/en/notas-medicinas-asistenciales2/item/>

[15] Zadeh, L.A., Fuzzy sets as a basis for theory of possibility, *Fuzzy Set Systems*, pp. 3–28, 1978.

[16] Coronel, A., Feldman, S.R., Jozami, E., Kehoe, F., Piacentini, R. D., Dubbeling, M., Escobedo, F. J., "Effect of

urban green areas on air temperature in a medium size Argentine city", *Environment Science* 2(803-826), 2015.