

Algoritmos para la Modelización y el Reconocimiento de Actividades de la Vida Diaria

Resumen: El crecimiento de la cantidad de adultos mayores en la composición total de una población ha demostrado ser en las últimas décadas un proceso que ocurre con una velocidad considerable. Las tecnologías de detección de actividades basadas en redes de sensores constituyen una solución global para brindar autonomía y calidad de vida a personas adultas. La técnica de simulación permite generar datos sintéticos correspondientes a años de vida de un individuo con esfuerzo y tiempo mínimos y así lograr el entrenamiento inicial de los algoritmos de aprendizaje presentes en los sistemas de monitoreo. El agregado de las influencias climáticas al modelo de simulación mediante lógica difusa permite contemplar las variaciones en las actividades de una persona. El reconocimiento de las actividades diarias con dichas influencias puede ser realizado mediante una red neuronal artificial manteniendo un alto nivel de precisión.

Palabras Claves: adultos mayores; actividades diarias; lógica difusa; redes neuronales artificiales.

Abstract: The growth of the number of elderly people in the total composition of a population has proven to be in the last decades a process that occurs with a considerable speed. Activity monitoring technologies based on sensors networks constitute a global solution to provide autonomy and quality of life for adults. The simulation allows to generate synthetic data sets corresponding to years of life of a person with minimum effort and time and thus to achieve the initial training of the algorithms of machine-learning present in the systems of monitoring. The addition of climatic influences to the simulation model through diffuse logic allows to contemplate the variations in the activities of a person. The recognition of daily activities with these influences can be realized through an artificial neural network maintaining a high level of precision.

Keywords: elderly people; activities of daily living; fuzzy logic; artificial neural networks.

Franco Lianza, Maria, Juan P. Nant, Nicole Schmidt

Departamento Ingeniería en Sistemas de Información (Zeballos 1348, Rosario), Facultad Regional Rosario, UTN.

Mail: aflianza@frro.utn.edu.ar, dmaria@frro.utn.edu.ar, jnant@frro.utn.edu.ar, nschmidt@frro.utn.edu.ar

Este trabajo ha sido realizado bajo la dirección del Ing. Mag. Ing, Darío Weitz.

INTRODUCCIÓN

El crecimiento de la cantidad de adultos mayores en la composición total de una población ha demostrado ser en las últimas décadas un proceso que ocurre con una velocidad considerable y numerosos estudios en materia de demografía lo evidencian sin importar cuál sea la región o el área geográfica bajo estudio. Argentina ya cuenta con una población envejecida y, si bien la tasa con la que se da dicho fenómeno es menor que en otros países de América Latina, las proyecciones hacia el año 2040 dejan ver que el proceso de envejecimiento continuará provocando significativos ensanchamientos en la parte superior de la pirámide demográfica e impactando en ciertos fenómenos sociales (INDEC, 2013).

Como respuesta al aumento de la cantidad de adultos mayores muchas soluciones informáticas actualmente en desarrollo buscan dar apoyo al deterioro cognitivo y físico de los ancianos en pos de brindarles una mejor calidad de vida, al mismo tiempo que se anticipan a las problemáticas en las que derivará tener una población envejecida. Una de las alternativas es el monitoreo mediante la implementación de una red hogareña de sensores destinados a la recolección de datos que luego son procesados mediante algoritmos de inteligencia artificial a fin de generar conocimiento sobre la persona monitoreada en base a sus actividades de la vida diaria (AVD).

Las 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 (Katz, S.; Ford, A. B.; Moskowitz, R. W.; Jackson, B. A.; Jaffe, M. W., 1963). Numerosos profesionales del área salud consideran que la identi-

ficación de cambios en las AVD es una de las maneras para detectar la aparición de enfermedades en sus primeras fases.

Las soluciones de monitoreo cuyo pilar básico está constituido por una red de sensores presentan, pese a sus múltiples ventajas, una ardua y extensa tarea a la hora de la puesta a punto debido a que la naturaleza de las AVD cambia considerablemente de persona a persona. Las mencionadas dificultades se han sorteado anteriormente por medio de modelos de simulación que permiten flexibilidad y bajos costos a la hora de diseñar y estudiar dichos sistemas. La técnica de simulación permite además generar datos sintéticos correspondientes a años de vida de un individuo con esfuerzo y tiempo mínimos y así lograr el entrenamiento inicial de los algoritmos de aprendizaje presentes en los sistemas de monitoreo.

Dada la notable influencia que tienen los factores climáticos en las actividades de los adultos mayores es habitual que estos dejen de realizar ciertas actividades, como por ejemplo un paseo por la tarde, si en el exterior se tienen temperaturas ambientes tanto muy altas como muy bajas. Estos cambios en la rutina no deben considerarse como síntoma de algún tipo de deterioro o pérdida de autonomía, motivo por el cual es necesario contemplar el estado del clima, así como su impacto en las AVD del individuo al momento de utilizar un modelo de simulación.

El objetivo de este trabajo es incorporar al modelo de simulación utilizado para generar datos 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 de una Red Neuronal Artificial (RNA).

METODOLOGÍA

Modelo de simulación

El modelo de simulación fue desarrollado utilizando el lenguaje de programación C#. Es un lenguaje de programación de propósito general orientado a objetos desarrollado y estandarizado por Microsoft como parte de su plataforma .NET. Además, es un lenguaje diseñado para la infraestructura de lenguaje común (Common Language Infrastructure, CLI), una especificación estandarizada que describe un entorno virtual para la ejecución de aplicaciones. Se utilizó Microsoft Visual Studio 2012 como Entorno de Desarrollo Integrado (IDE).

Para la construcción de gráficos y curvas se utilizaron las librerías ZedGraph y Charting (DataVisualization). Se trata de librerías de clases, control de usuario y control web escritas en C# que permiten crear gráficos en proyectos .NET (Licencia: GNU Library o Lesser General Public License). El modelado de la vista 3D se realizó mediante el software SketchUp Pro 2015, utilizando 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 (Evans, J. R.; Olson, D. L., 1998). Es una clase de modelo de simulación dinámico, discreto y estocástico. La dimensión dinámica involucra el pasaje del tiempo simulado y una representación explícita de la

secuencia de actividades que realiza el residente del hábitat simulado. La dimensión discreta indica que los eventos de interés cambian en puntos separados en el tiempo. La dimensión estocástica permite modelar la conducta relativamente impredecible que tienen los seres humanos en sus actividades diarias. 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. Cada actividad consta de 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.

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. 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 inalámbricos se encargan de registrar el conjunto de Actividades de la Vida Diaria (AVD) que desarrolla el habitante virtual de la residencia simulada. Se consideraron dos tipos de actividades diarias: i) actividades de tiempo específico (desayunar, almorzar, dormir a la noche, etc.), las cuales se realizan solo una vez por día y en horario acotado; ii) actividades que se repiten (ir al baño, tomar mate, ver televisión, etc.) que pueden realizarse más de una vez por día y en horario libre. Se seleccionaron aquellas AVD que podían ser registradas mediante sensores inalámbricos simples y económicos, y cuyos cambios significativos podrían ser un indicador de deterioro en las condiciones de salud del residente y así servir como alerta temprana.

Red Neuronal Artificial

En 1943, los neurólogos Warren McCulloch y Walter Pitts crearon los primeros modelos de redes neuronales. El aprendizaje neuronal llegó años más tarde, en 1949, de la mano de Donald Hebb. Rosenblatt desarrolló el perceptron simple como una aproximación a una neurona biológica real. Funciona como una unidad básica de inferencia capaz de generar un criterio para seleccionar un subgrupo de un grupo de componentes más grandes. La limitación de esta unidad es que solamente puede separar conjuntos de datos que son linealmente separables. Para poder superar esta limitación, se utilizan varios perceptrones simples en distintas capas conectadas entre sí. Surge así la red neuronal artificial (RNA) denominada "Perceptron multicapa". La idea es que está compuesta por neuronas de entrada (sensores) conectadas a una compleja red de neuronas "calculadoras" (neuronas ocultas), las cuales, a su vez, están conectadas a las neuronas de salidas.

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: desde el punto de vista matemático, 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. Esta idea se utiliza en varias aplicaciones del mundo real, como por ejemplo, en varios programas de reconocimiento de patrones. Para estos casos se utilizan redes del tipo Feed-forward; ii) Predicción: la RNA puede ser entrenada para producir salidas que son las esperadas frente a una entrada particular. Si dicha red modela correctamente una secuencia de valores conocidos, esta puede utilizarse para predecir resultados futuros.

Una aplicación muy conocida es la predicción de la cotización de acciones en la bolsa de valores. En estos casos también se utilizan redes de tipo Feed-forward; iii) Clustering: Esta técnica es la más aplicada 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. Los tipos de redes utilizados son las de Aprendizaje Competitivo, Teoría de Resonancia Adaptativa (Adaptive Resonance Theory, ART) y Mapas Auto-Organizados (Self-Organizing Maps, SOM); iv) Asociación: Ciertas RNA pueden diseñarse para "recordar" distintos patrones y, ante una determinada entrada, asociarla con el patrón más cercano en su memoria y responder con el patrón original. La utilidad más común es la corrección de datos con ruido utilizando Redes de Hopfield.

El reconocimiento de las actividades humanas, en particular de adultos mayores, mediante una red de sensores inalámbricos puede enmarcarse como una tarea de clasificación supervisada debido a su carácter rutinario. 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 descrito.

La arquitectura feed-forward presenta las siguientes características: i) Las neuronas están organizadas en capas: La primera capa recibe los datos de los sensores y la última emite las salidas, mientras que las capas intermedias no tienen interacción con el exterior; ii) Cada una de las neuronas que se encuentran en una capa están conectadas con cada una de las siguiente capa 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 los patrones de las mediciones de los sensores y la actividad que fue 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 de tiempo específico (dormir, siesta, baño, desayunar, almorzar, merendar, cenar, salir) y AVD repetitivas (uso de computadora, TV, teléfono, mate, baño).

Siguiendo el mencionado esquema de tres tipos de capas se logra tener una arquitectura funcional, pero para funcionar correctamente, se deben establecer los valores para ciertos parámetros cómo el número de capas de cada tipo y el número de neuronas en cada capa: i) Capa de entrada: Cada RNA tiene exactamente una capa de este tipo, sin excepción. En cuanto al número de neuronas, depende de los datos de entrenamiento, específicamente del número de atributos en los datos; ii) Capa de Salida: Como ocurre con la capa de entrada, la RNA posee solo una capa de este tipo y el número de neuronas se determina según el modo de configuración. Si la RNA es de Modo Regresión devuelve un único valor, por lo que la capa tiene sólo una neurona; si es de Modo Clasificador, esta devuelve la etiqueta de una clase o categoría y también tendrá una sola neurona excepto que se utilice la codificación softmax, en cuyo caso habrá una neurona por clase; iii) Capa Oculta: Cada RNA posee al menos una capa oculta cuando los datos no son linealmente separables. La

mayoría de los problemas pueden ser resueltos con una única capa oculta. Debido a que esta capa no interactúa directamente con el ambiente externo, la cantidad de neuronas tiene una gran influencia sobre la salida final. Utilizar pocas neuronas resultará en un underfitting. Por el contrario, utilizar excesivas neuronas resultará en un overfitting. Si bien no existe una fórmula para calcular el número óptimo de neuronas en esta capa, existen varias reglas empíricas que indican la cantidad de neuronas que debe poseer; siendo la más utilizada: “el tamaño óptimo de la capa oculta es generalmente entre el tamaño de la Capa de Entrada y el tamaño de la Capa de Salida” (Heaton, 2008).

Basado en lo anterior, se implementó una red con 13 neuronas en la capa de entrada, 12 neuronas en la capa de salida y 12 neuronas para la capa oculta. Para el entrenamiento se utilizó el algoritmo Scaled Conjugate Gradient Backpropagation (SCGB) y se midió el rendimiento con el método Cross-Entropy (entropía cruzada).

La entropía cruzada posee 2 propiedades particulares que le permite ser identificada como una función de costo: es no negativa y, en el caso de que las salidas sean binarias (por ejemplo, en un problema de clasificación), el valor de la función tendera a 0 conforme la salida de las neuronas se acercan al valor deseado. A su vez, la entropía cruzada tiene como beneficio que evita el problema del lento aprendizaje que se da con la función cuadrática de costo (Nielsen, 2015).

El SCGB es una variante del algoritmo backpropagation considerablemente más rápido (Moller, 1993), en el cual intenta acercarse iterativamente al mínimo mediante el gradiente conjugado de la iteración anterior.

Se simularon un total de 3 meses, obteniendo un total de 430.845 registros de sensores. Dichos registros fueron preprocesados y se utilizaron para el entrenamiento de la RNA.

Para realizar el aprendizaje por parte de la RNA, se dividió al conjunto de los datos sensados en 3 subconjuntos: entrenamiento, validación y evaluación. El primero de ellos se utiliza para computar el gradiente, actualizar los pesos y las biases de la RNA. El subconjunto de validación permite si la RNA se encuentra en un proceso de overfitting o underfitting. El subconjunto de evaluación no se utiliza durante el entrenamiento, pero presenta gran utilidad para comprar diferentes modelos. Si el error de dicho subconjunto alcanza un mínimo en una iteración significativamente diferente que el error del subconjunto de validación, puede indicar una pobre división del conjunto de datos. Para nuestro caso, utilizamos una división del 70%, 15% y 15% para entrenamiento, validación y evaluación respectivamente.

Lógica difusa

La Lógica Difusa o Lógica Borrosa fue desarrollada en 1965 por el ingeniero y matemático Lotfi A. Zadeh. Esta es una extensión de la lógica Booleana tradicional basada en la teoría matemática de los conjuntos borrosos la cual es una generalización de la teoría de conjuntos clásica. Su principal característica se basa en dejar de lado la idea de que una condición sólo puede ser totalmente falsa o verdadera, dando lugar a condiciones parcialmente ciertas gracias a introducir el concepto de 'grado de verificación' de una condición. Dicho concepto le da a esta técnica la ventaja de tener la flexibilidad suficiente para formalizar el razonamiento humano, modelar situaciones en donde la información es difícil de definir con exactitud, o donde intervienen conceptos vagos como 'muy tarde', 'húmedo', 'un poco lento', etc. (Ponce Cruz, 2010).

Los adultos mayores debido a los cambios que se

producen naturalmente en el cuerpo por el envejecimiento, como adelgazamiento de la piel o la pérdida de sensibilidad cutánea a la temperatura, suelen tener dificultades para tolerar los cambios de clima. Sumado a ello existe además un riesgo para la salud de las personas mayores y es por ello que estos factores se deben vigilar de manera muy cuidadosa.

Los sistemas de inteligencia ambiental que realizan un seguimiento automático de las AVD de adultos mayores, están atentos a 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. La dificultad adicional surge del hecho de que los factores climáticos también generan cambios de frecuencia o duración en las AVD por lo que es importante que los algoritmos de reconocimiento de actividades no interpreten estas variaciones como desvíos correspondientes a el agravamiento del estado de salud del individuo. Por otra parte, puesto que la respuesta de los humanos a los cambios climáticos no sigue reglas exactamente definidas, se decidió utilizar un algoritmo de lógica difusa para modelar tales incertidumbres. Se aplicaron conjuntos difusos para definir las condiciones a evaluar sobre las variables de estado (variables de entrada del sistema) y obtener mediante dicha evaluación los valores de las variables de control (variables que describen las salidas del sistema).

METODOLOGÍA

Red Neuronal Artificial

La Figura 1 muestra que el valor de la función de entropía cruzada del subconjunto de validación se alcanza en iteraciones similares al del subconjunto de

entrenamiento, lo que indica una buena división del conjunto de los datos.

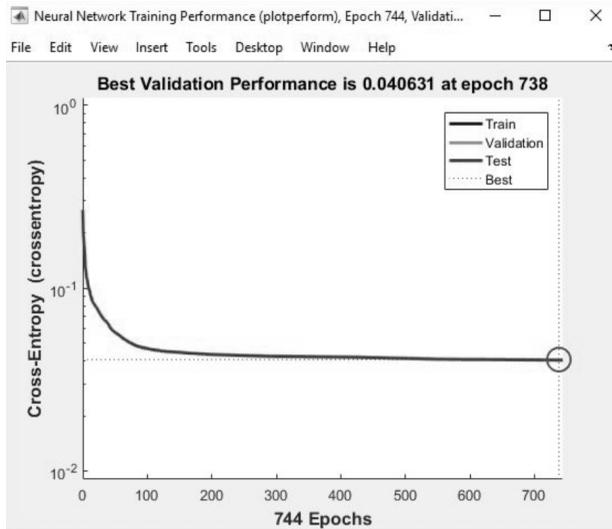


Fig. 1: Entropía cruzada a lo largo del entrenamiento.

La Figura 2 muestra la cantidad de registros pertenecientes al subconjunto de validación que se clasificaron de manera correcta a medida que el gradiente disminuye. Al ocurrir 6 validaciones, el entrenamiento se detiene.

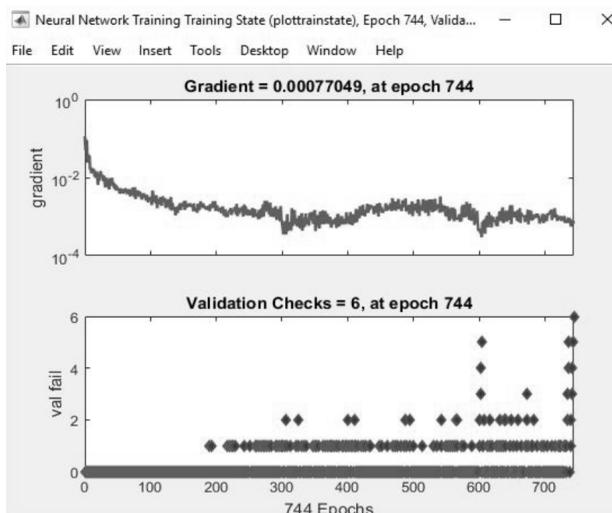


Fig. 2: Training State.

La RNA planteada presenta una precisión global del 83.9%. La curva ROC, Figura 3, muestra el ratio de verdaderos positivos frente al ratio de falsos positivos obtenido por la RNA. Las AVD repetitivas Teléfono y Mate son las que más falsos positivos presentan.

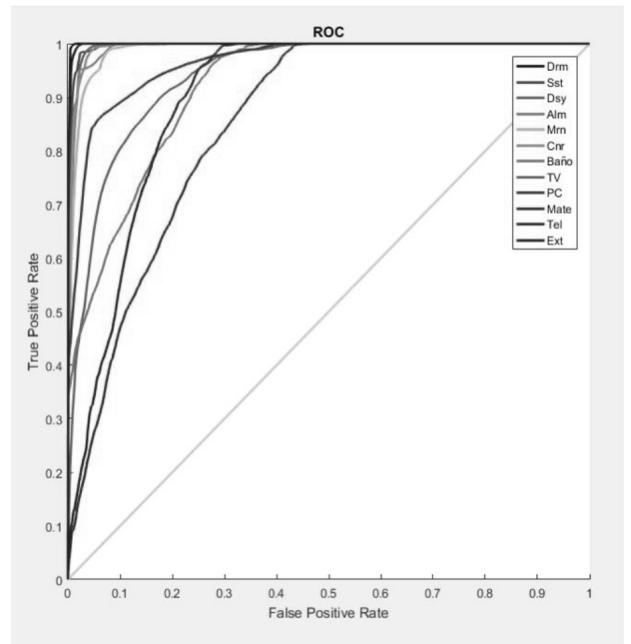


Fig. 3: Matriz de Confusión.

Lógica Difusa

Un conjunto difuso queda siempre definido por una función de pertenencia de rango [0,1] que indica, para cada valor del dominio, el ‘grado’ de pertenencia de dicho valor al conjunto. El concepto de función de pertenencia permite definir sistemas borrosos expresándolos en lenguaje natural mediante el uso de variables lingüísticas. Sea V una variable, X el rango de valores de V y T_v un conjunto de conjuntos difusos, entonces una variable lingüística queda definida por la terna (V, X, T_v) . Para el modelado se utilizaron como variables de estado la temperatura y humedad rela-

tiva. 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 (Coronel, A.; Feldman, S.R.; Jozami, E.; Kehoe, F.; Piacentini, R.D.; Dubbeling, M.; Escobedo, F.J., 2015). La Figura 4 muestra la variable lingüística para la variable de estado variación de temperatura y las correspondientes funciones de pertenencia de los conjuntos difusos asociados.

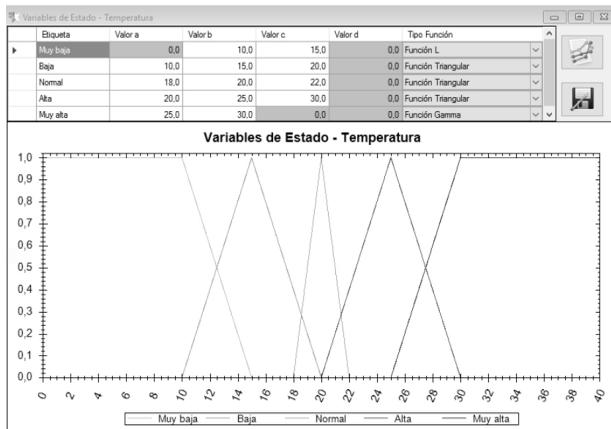


Fig. 4: Variable lingüística. V= "variación de temperatura", X= R(reales), Tv = {Muy Baja, Baja, Normal, Alta, Muy Alta}.

Podemos notar la flexibilidad del modelo observando que, por ejemplo, si bien una variación de 28° es cuantitativamente mayor que una de 24°, la de 24° "pertenece más" que la de 28° al conjunto borroso Alta mientras que esta última, la de 28°, no pertenece tanto a Alta y tiende a tener más pertenencia al conjunto Muy Alta.

Las variables de control 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	Humedad				
	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

Fig. 5: Matriz de Asociación Difusa.

La Figura 6 muestra la intersección de los grupos difusos dado 11°C temperatura y 32% humedad.

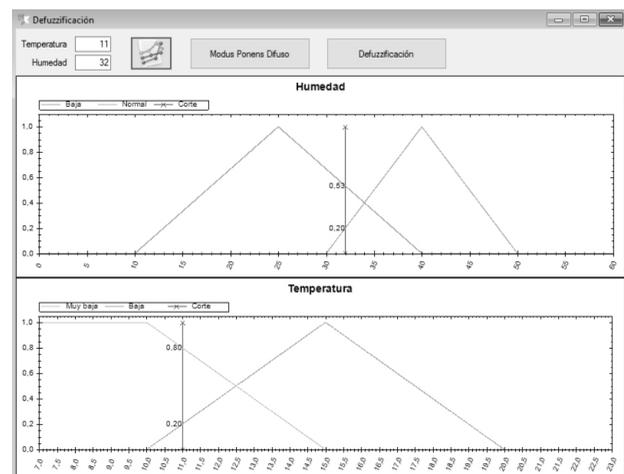


Fig. 6: Desfuzzificación.

Como parámetros de la inferencia difusa se utilizó Modus Ponens Difuso, operador de fuzzyficación singleton y operador de desfuzzyficación 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. La Figura 7 muestra que si la temperatura es 11°C

y la humedad es 32%, entonces la AVD Dormir sufrirá un aumento de su duración en un 32% aproximadamente.

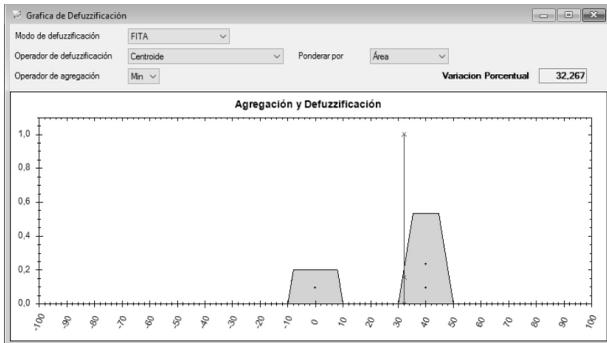


Fig. 7: Modus Ponens Difuso.

Red Neuronal Artificial junto al modelado de Lógica Difusa

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.

DISCUSIÓN

El reconocimiento de las AVD muestra un alto nivel de precisión, pero algunas coberturas son deficientes (baño, cenar). La RNA no clasifica a las AVD repetitivas Mate y Teléfono.

Output Class	Drn	Sst	Dsy	Alm	Mrn	Cnr	Baño	TV	PC	Mate	Tel	Ext
Drn	166434 39.1%	0 0.0%	2004 0.5%	0 0.0%	0 0.0%	0 0.0%	564 0.1%	1615 0.4%	395 0.1%	98 0.0%	0 0.0%	0 0.0%
Sst	1 0.0%	14839 3.5%	0 0.0%	737 0.2%	233 0.1%	0 0.0%	212 0.0%	1392 0.3%	1421 0.3%	214 0.1%	18 0.0%	0 0.0%
Dsy	944 0.2%	0 0.0%	6670 1.6%	0 0.0%	0 0.0%	0 0.0%	287 0.1%	1179 0.3%	954 0.2%	753 0.2%	48 0.0%	0 0.0%
Alm	1 0.0%	372 0.1%	190 0.0%	14048 3.3%	12 0.0%	0 0.0%	333 0.1%	2190 0.5%	1298 0.3%	279 0.1%	36 0.0%	0 0.0%
Mrn	0 0.0%	124 0.0%	0 0.0%	49 0.0%	7484 1.8%	1 0.0%	464 0.1%	747 0.2%	1096 0.3%	81 0.0%	102 0.0%	393 0.1%
Cnr	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 0.0%	17370 4.1%	517 0.1%	3335 0.8%	1412 0.3%	279 0.1%	350 0.1%	339 0.1%
Baño	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2693 0.6%	50 0.0%	0 0.0%	0 0.0%	0 0.0%	98.2%
TV	149 0.0%	27 0.0%	963 0.2%	280 0.1%	1714 0.4%	1589 0.4%	728 0.2%	43365 10.2%	6471 1.5%	4844 1.1%	2420 0.6%	1334 0.3%
PC	216 0.1%	513 0.1%	137 0.0%	916 0.2%	753 0.2%	928 0.2%	1173 0.3%	4070 1.0%	74208 17.4%	1395 0.3%	711 0.2%	1113 0.3%
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%
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%
Ext	0 0.0%	235 0.1%	0 0.0%	30 0.0%	2925 0.7%	0 0.0%	205 0.0%	2633 0.6%	733 0.2%	115 0.0%	8 0.0%	11992 2.8%
	89.2%	92.1%	66.9%	87.5%	57.0%	87.3%	37.5%	71.6%	84.3%	0.0%	0.0%	79.0%
	0.8%	7.9%	33.1%	12.5%	43.0%	12.7%	62.5%	28.4%	15.7%	100%	100%	21.0%
	15.6%											

Fig. 8: Matriz de confusión para la nueva corrida de simulación.

La muestra pares de registros correspondientes a las AVD instrumentales Mate y TV por una parte y registros correspondientes a baño ocupado y desocupado.

La similitud entre registros es debido a que, con la configuración de sensores existente, no se permite diferenciar la AVD Mate de TV. Con la AVD Teléfono sucede lo mismo. Como resultado, la matriz de confusión indica que no hay cobertura de esas AVD. La baja cobertura de la AVD baño se debe a que la similitud entre registros no le permite a la RNA clasificar apropiadamente (solo se diferencian en el valor binario de fotocontrol).

dia	horaMinuto	ambiente	movimiento	gas	humo	monoxido	temperatura	humedad	ocupacion	fotocontrol	sonido	puerta	Actividad
4	1304	2	1	0	0	0	24	40	1	1	0	0	Mate
4	1305	2	1	0	0	0	23	40	1	1	0	0	TV
26	565	2	1	0	0	0	18	66	1	1	0	0	Mate
26	566	2	1	0	0	0	18	66	1	1	0	0	TV
18	1005	5	0	0	0	0	29	31	0	0	0	0	Exterior
18	1006	5	1	0	0	0	29	31	0	1	0	0	Baño

Fig. 9: Registros de los sensores.

CONCLUSIONES

Las tecnologías de detección de actividades basadas en redes de sensores constituyen una solución global para brindar autonomía y calidad de vida a personas adultas: El reconocimiento de actividades de la vida diaria implementando algoritmos de inteligencia artificial constituye no solo una alternativa de monitoreo afectiva mediante manejables volúmenes de datos sino también una excelente fuente de información en lo concerniente al estado de salud de la persona.

El agregado de las influencias climáticas al modelo de simulación mediante lógica difusa permite contemplar las variaciones en las actividades de una persona obteniendo un modelo que se aproxima considerablemente a la realidad y aporta una mejor comprensión

del problema sin provocar efectos adversos al hecho de que la técnica de simulación ayuda a reducir costos y tiempos al momento de la puesta a punto de este tipo de soluciones.

Adicionalmente tampoco se han obtenido pérdidas de cobertura de la red neuronal artificial en el reconocimiento de las actividades al incluir las variaciones provocadas por la humedad y la temperatura, por lo que concluimos que implementarlas como parte de la inteligencia artificial interviniente en el sistema permite obtener buenos resultados al reconocer las actividades de la vida diaria, estén estas o no afectadas por el clima, aportando además una facilidad adicional en la puesta a punto de todo el sistema debido a que es posible entrenarla con los datos ya obtenidos del modelo de simulación.

REFERENCIAS

Coronel, A.; Feldman, S.R.; Jozami, E.; Kehoe, F.; Piacentini, R.D.; Dubbeling, M.; Escobedo, F.J., 2015. Effect of urban green areas on air temperature in a medium size Argentine city. *Environment Science*, pp. 2:803-826.

Evans, J. R.; Olson, D. L., 1998. *Introduction to Simulation and Risk Analysis*. Upper Saddle River: Prentice Hall.

Heaton, J., 2008. *Introduction to Neural Networks for Java*. Chesterfield: Heaton Research.

INDEC, 2013. *Estadísticas.. En: Estimaciones y proyecciones de población 2010-2040. : total del país. Ciudad Autónoma de Buenos Aires: Instituto Nacional de Estadísticas y Censos.*

Katz, S.; Ford, A. B.; Moskowitz, R. W.; Jackson, B. A.; Jaffe, M. W., 1963. Studies of illness in the aged: the index of ADL, a standardized measure of biological and psychosocial function. *JAMA*, Issue 185, pp. 914-919.

Moller, M. F., 1993. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, pp. 6:525-533.

Nielsen, M. A., 2015. *Neural Networks and Deep Learning*. Toronto: Determination Press.

Ponce Cruz, P., 2010. *Inteligencia Artificial con Aplicaciones a la Ingeniería*. Mexico D.F.: Alfaomega.