

TESIS DEFENDIDA POR
Dairazalia Sánchez Cortés
Y APROBADA POR EL SIGUIENTE COMITÉ

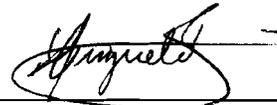
1-10

Dr. Jesús Favela Vara
Director del Comité



Dra. Ana Isabel Martínez García

Miembro del Comité



Dr. Carlos Alberto Brizuela
Rodríguez

Miembro del Comité



Dr. Héctor Escamilla Taylor

Miembro del Comité



Dr. Gilberto López Mariscal

*Coordinador del programa de
posgrado en Ciencias de la
Computación*



Dr. Edgar Gerardo Pavía López

Director de Estudios de Posgrado

6 de septiembre de 2007

**CENTRO DE INVESTIGACIÓN CIENTÍFICA Y DE EDUCACIÓN SUPERIOR
DE ENSENADA**



**PROGRAMA DE POSGRADO EN CIENCIAS
EN CIENCIAS DE LA COMPUTACIÓN**

**ESTIMACIÓN DE ACTIVIDAD DE TRABAJADORES HOSPITALARIOS CON
MODELOS OCULTOS DE MARKOV**

TESIS

que para cubrir parcialmente los requisitos necesarios para obtener el grado de
MAESTRO EN CIENCIAS

Presenta:

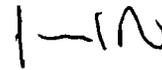
DAIRAZALIA SÁNCHEZ CORTÉS

Ensenada, Baja California, México, Septiembre de 2007.

RESUMEN de la tesis de **DAIRAZALIA SÁNCHEZ CORTÉS**, presentada como requisito parcial para la obtención del grado de **MAESTRO EN CIENCIAS** en **CIENCIAS DE LA COMPUTACIÓN**. Ensenada, Baja California. Septiembre del 2007.

Estimación de actividad de trabajadores hospitalarios con modelos ocultos de Markov

Resumen aprobado por:



Dr. Jesús Favela Vara
Director de Tesis

El cómputo consciente del contexto ofrece muchas ventajas para la interacción humano computadora, apoyando el desarrollo de inteligencia ambiental con artefactos computacionales que pueden responder a las necesidades de los usuarios. Uno de los principales retos en el cómputo consciente del contexto es el reconocimiento del contexto. Mientras algunas variables contextuales como ubicación, pueden ser reconocidas con relativa facilidad, otras, como la actividad, son más difíciles de estimar.

Un ambiente apropiado para el uso de aplicaciones conscientes del contexto es el hospitalario. Los hospitales son ambientes ricos en tecnología, cuyos trabajadores experimentan un alto nivel de movilidad resultando en infraestructuras de información con artefactos distribuidos. De hecho, algunos elementos de cómputo consciente del contexto están siendo gradualmente introducidos en hospitales (éstos varían desde PDAs, etiquetas RFID para el seguimiento de pacientes, dispositivos de comunicación activados por voz y sensores para monitoreo de pacientes). No obstante, experiencias en el desarrollo de aplicaciones conscientes del contexto en hospitales han enfatizado que las aplicaciones deben proveer “confianza en la acción” para la adopción exitosa de tales aplicaciones. Esto ha motivado el desarrollo de aplicaciones conscientes de la actividad de trabajadores hospitalarios.

Trabajos previos han buscado inferir la actividad de las personas utilizando diferentes técnicas. Estas técnicas varían desde enfoques que estiman actividades de baja abstracción (por ejemplo masticando o sentado) hasta enfoques para estimar actividades más complejas. Nuestra base de trabajo relacionado propone un enfoque que utiliza redes neuronales de retropropagación (RN) la cual fue entrenada para hacer corresponder la información contextual con actividades realizadas por los trabajadores hospitalarios. Los resultados indicaron que se puede predecir la actividad de los trabajadores hospitalarios el 75% de las veces. Aunque la precisión obtenida con este enfoque es suficiente para el desarrollo de muchas aplicaciones conscientes del contexto, no es suficiente para apoyar la naturaleza del trabajo hospitalario. De aquí, que decidimos centrar nuestros esfuerzos en mejorar la precisión obtenida utilizando modelos ocultos de Markov.

La metodología seguida incluyó el análisis de la colección de datos, la representación de dicha información, seguida de un estudio de relevancia de las variables contextuales que como resultado redujo la dimensión del vector de entrada utilizado por RN un 38%.Y finalmente el diseño y pruebas del modelo para estimar la actividad utilizando modelos ocultos de Markov.

Nuestros resultados indican que la actividad de los trabajadores hospitalarios puede ser estimada correctamente el 92.6% de las veces utilizando un modelo oculto de Markov en paralelo. Se realizó la comparación de los resultados obtenidos con los de redes neuronales y observadores expertos familiarizados con las prácticas laborales en un ambiente hospitalario resultando que la precisión de estimación de actividades con el modelo en paralelo propuesto es superior un 17% comparada con RN y un 56% comparada con observadores expertos. Adicionalmente se mostró la robustez del modelo ante la estimación de actividad con ruido en el vector de entrada.

Palabras clave: modelos ocultos de Markov, estimación de actividad, cómputo consciente del contexto, inteligencia ambiental.

ABSTRACT of the Thesis of **DAIRAZALIA SÁNCHEZ CORTÉS**, presented as partial requirement to obtain the **MASTER in SCIENCES** degree in **COMPUTER SCIENCE**. Ensenada, Baja California. September 2007.

Estimating Hospital Workers Activities using Hidden Markov Models

Context-aware computing can be used to augment working and living environments with computational artifacts that can be responsive to the needs of users. One of the main challenges in context-aware computing is context recognition. While some contextual variables, such as location, are relatively easily estimated, others, such as activity are more complex to determine.

A particular environment that could be enriched using context-aware applications are hospital settings. Not only are they technology-rich environments, but their workers experience a high level of mobility resulting in information infrastructures with artifacts distributed throughout the premises. Indeed, some elements of context-aware computing (PDAs, RFID tags for patient tracking, voice-activated communication devices, and sensors for patient monitoring) are gradually being introduced in hospitals. However, experiences in the deployment of context-aware applications in hospitals have emphasized that we must provide “confidence in action” for the successful adoption of such applications. This has motivated the development of hospital workers activity-aware applications.

Previous efforts have been made to infer the activities of people using different techniques. These techniques range from approaches that estimate activities at a low level of abstraction (e.g., chewing, sitting) to approaches that estimate more complex activities. Our base related work proposed an approach that uses a back propagation neural network (NN) which was trained to map from contextual information to activities performed by hospital workers. Their results indicate that this technique could correctly predict hospital workers’ activities 75% of the time. Although, the accuracy obtained by this approach is sufficient for the development of several context-aware applications, it is not enough to support the nature of hospital work. Hence, we decided to center our efforts on improving the accuracy obtained by using HMM.

The methodology we followed included the analysis of the data collection, the proper representation of this data, followed by a study of the relevance of the contextual variables, and finally the design and testing of the model to estimate the activity of hospital workers using HMM.

Our results indicate that the user activity can be correctly estimated 92.6% of the time, using a two level parallel layered HMM. We compare our results with the use of neural networks and human observers familiar with those work practice concluding that the accuracy of the parallel model proposed is higher 17% than neural NN and higher 56% than human observers. Additionally we probed the robustness of the model testing it with noise in the input vectors.

Keywords: HMM, activity recognition, context-aware computing, ambient intelligence.

Dedicatoria

*A mis padres, Prisca y Alejandro
por su Amor, comprensión y apoyo.*

A mis hermanas y hermanos.

A mis queridos sobrinos.

Agradecimientos

Un especial agradecimiento a mi director de tesis, Dr. Jesús Favela Vara, por los invaluable consejos e ideas con que me apoyó durante la realización de este trabajo.

A los miembros del comité Dr. Carlos Brizuela Rodríguez, Dra. Ana I. Martínez García y Dr. Héctor Escamilla por su aportación a este trabajo, así como por su tiempo para la revisión del mismo.

A mis padres por su infinito Amor y confianza. Por alentarme a seguir adelante y por su ejemplo de tenacidad y Amor a la vida. A mi hermano Ismael por sus consejos y su confianza. A mi hermana Orquídea, por escucharme y echarme porras, así como Dey, Angélica, Caro, Mac y Blanca.

A mi novio Noe Contreras por todo su Amor, comprensión y apoyo incondicional por más de un año. A mis amigas por su apoyo y por los muchos alegres momentos que compartimos, Nubia, Dalila, y en especial a Argelia por su cariño y paciencia. A los chicos de la generación y a los chicos del club de Toby por su compañerismo.

A mis otros amigos de CICESE que aunque no son de la generación también pusieron su granito de arena, cada quien a su modo: Leo, Mónica, Jorge Niebla, y Doris. A mis buenos compañeros de cubo Mario, Erika, Saúl, Adolfo y Ariel. Y a las siempre sonrientes Carito y Lydia.

A mis amigos que aun en la distancia me brindaron su apoyo, Belén, Toño, Esaú y Mike.

Y finalmente, pero no por eso el menos importante, a CONACYT por su apoyo económico.

CONTENIDO

	Página
Capítulo I	
I Introducción	
<i>I.1. Antecedentes</i>	1
<i>I.2. Importancia de la Estimación de Actividad</i>	2
<i>I.3. Objetivos de la Investigación</i>	4
I.3.1. Objetivo General	4
I.3.2. Objetivos Específicos	4
<i>I.4. Metodología</i>	5
<i>I.5. Organización de la Tesis</i>	6
Capítulo II	
II Reconocimiento de Actividad Humana	8
<i>II.1. Cómputo Ubicuo</i>	8
II.1.1. Cómputo Consciente del Contexto	9
II.1.2. Inteligencia Ambiental (AmI)	12
<i>II.2. Reconocimiento de Actividad Humana</i>	13
<i>II.3. Estimación de Actividad en Aplicaciones Conscientes del Contexto</i>	18
II.3.1. Detección de Disponibilidad en Hospitales	20
<i>II.4. Discusión de Trabajo Previo</i>	21
<i>II.5. Resumen</i>	23
Capítulo III	
III Modelos Ocultos de Markov	24
<i>III.1. Procesos de Markov</i>	24
<i>III.2. Modelos Ocultos de Markov</i>	25
III.2.1. Algoritmos de los Modelos Ocultos de Markov	27
III.2.1.1 Algoritmo Hacia Delante	28
III.2.1.2 Algoritmo Hacia Delante-Atrás (Forward-Backward)	30
III.2.1.3 Algoritmo Baum-Welch (EM)	32
III.2.1.4 Algoritmo Viterbi	33
<i>III.3. Aplicando Modelos Ocultos de Markov Discretos</i>	35
<i>III.4. Redes Neuronales de Retropropagación</i>	39
<i>III.5. Resumen</i>	41
Capítulo IV	
IV Estimación de Actividad con Modelos Ocultos de Markov	42
<i>IV.1. Introducción</i>	42
<i>IV.2. Organización y Recolección de Datos</i>	44
<i>IV.3. Representación de los Datos</i>	46
IV.3.1. Distribución Inicial de Estados	55

CONTENIDO (Continuación)

	Página
IV.3.2. Matrices de Transición de Estados	55
<i>IV.4. Relevancia de Variables Contextuales para el Reconocimiento de la Actividad</i>	57
IV.4.1. Estimaciones usando sólo Información de Ubicación	59
IV.4.2. Estimaciones usando sólo Información de Personas (agentes)	61
IV.4.3. Estimaciones usando sólo Información de Artefactos	63
IV.4.4. Estimaciones con el Vector de Entrada Completo	64
<i>IV.5. Diseño del Modelo en Capas</i>	65
IV.5.1. Modelo Simple en dos Capas con Modelos Ocultos de Markov	66
IV.5.2. Modelo Paralelo en dos Capas con Modelos Ocultos de Markov	67
<i>IV.6. Resumen</i>	68
Capítulo V	
V Resultados y Conclusiones	69
<i>V.1. Estimaciones con Redes Neuronales</i>	69
V.1.1. Estimaciones con Actividades Secundarias con RN	71
V.1.2. Estimaciones de Actividad con el Vector Reducido con RN	73
<i>V.2. Estimaciones con Modelos Ocultos de Markov</i>	74
V.2.1. Estimaciones con el Modelo Simple en dos Capas	74
V.2.2. Estimaciones con el Modelo Paralelo en dos Capas	75
V.2.3. Comparativa de las Estimaciones de los Modelos Propuestos	76
V.2.4. Análisis de las Estimaciones con el Modelo Paralelo en dos Capas	77
V.2.5. Robustez del Modelo Paralelo en dos Capas	79
<i>V.3. Estimaciones con Observadores Expertos</i>	80
<i>V.4. Comparativa de Resultados</i>	83
Capítulo VI	
VI Conclusiones y Trabajo Futuro	86
<i>VI.1. Conclusiones</i>	86
<i>VI.2. Aportaciones</i>	87
<i>VI.3. Trabajo Futuro</i>	89
Referencias	91

LISTA DE FIGURAS

Figura		Página
1.	Estimación de actividad por medio de sensores en la ropa.	14
2.	Guante detector de RFID, para estimación de actividad mediante interacción con objetos con etiquetas RFID.	15
3.	Arquitectura del sistema SEER, para estimación de actividad en un ambiente de oficina.	16
4.	Estimación de actividad individual y grupal, modelo general.	17
5.	Estimación de actividad, captura de la información y modelo.	18
6.	XPod - Reproducción de audio, en base a la estimación de Actividad.	19
7.	Sistema de comunicación Vocera.	21
8.	Estados de un modelo estocástico.	24
9.	Algoritmo hacia delante (Forward).	29
10.	Algoritmo atrás.	31
11.	Algoritmo hacia delante-atrás.	32
12.	Algoritmo Viterbi.	35
13.	Máquina de estados finitos para la predicción del estado del tiempo.	36
14.	Modelo oculto de Markov para la estimación del estado del tiempo.	37
15.	Red neuronal de retropropagación.	40
16.	Metodología para el desarrollo del MOM en capas.	43
17.	Reporte de observación del rol enfermera operativa.	44
18.	Distribución de las muestras de los reportes de observación.	46
19.	Vector de entrada utilizado en la estimación de actividad con redes neuronales.	47
20.	Transformación simple del vector de entrada.	48
21.	Transformación del vector de entrada a valores discretos.	49
22.	Transformación del vector de entrada con codificación agrupada.	50
23.	Vector de entrada reducido, basado en la relevancia de las variables.	54
24.	Diagrama de transición de estados para el rol médico base.	56

LISTA DE FIGURAS (Continuación)

Figura		Página
25.	Modelo oculto de Markov para estimación de actividad.	59
26.	Modelo simple de dos capas con modelos ocultos de Markov.	66
27.	Modelo paralelo en dos capas con modelos ocultos de Markov.	67
28.	Asociación de variables contextuales para estimar actividad.	71
29.	Gráfica de la influencia de los modelos (agentes, artefactos) en la salida final del modelo en paralelo.	78
30.	Gráfica de precisión en la estimación de actividad con ruido en las entradas, rol médico base.	80
31.	Esquema de codificación utilizado en la prueba con observadores expertos.	81
32.	Comparativa de resultados de estimaciones entre observadores expertos, redes neuronales y modelos ocultos de Markov.	84

LISTA DE TABLAS

Tabla		Página
I	Estimación de Actividad Humana	22
II	Matriz de transición de estados, para estimación del estado del tiempo	36
III	Matriz de emisión o matriz de observación para la estimación del estado del tiempo	37
IV	Variabes de los segmentos agentes y artefactos del vector de entrada.	47
V	Codificación agrupada propuesta para los segmentos agentes y artefactos	50
VI	Codificación para las interacciones más comunes entre agentes	51
VII	Codificación para las interacciones más comunes con artefactos	52
VIII	Sensibilidad de variables en el segmento artefactos	53
IX	Sensibilidad de variables en el segmento agentes	53
X	Porcentajes de reducción del vector de entrada	54
XI	Porcentajes de tiempos promedio en la realización de actividades por día	55
XII	Matriz de transición de actividad para el rol médico base	56
XIII	Matriz de transición de actividad para el rol médico interno	57
XIV	Matriz de transición de actividad para el rol enfermera operativa	57
XV	Matriz de confusión de la estimación de actividad para el rol enfermera operativa, utilizando sólo información de ubicación.	60
XVI	Matriz de confusión de la estimación de actividad para el rol médico interno, utilizando sólo información de ubicación.	60
XVII	Matriz de confusión de la estimación de actividad para el rol médico base, utilizando sólo información de ubicación.	61
XVIII	Matriz de confusión de la estimación de actividad para el rol enfermera operativa, utilizando sólo información de agentes.	61
XIX	Matriz de confusión de la estimación de actividad para el rol médico interno, utilizando sólo información de agentes.	62

LISTA DE TABLAS (Continuación)

Tabla		Página
XX	Matriz de confusión de la estimación de actividad para el rol médico base, utilizando sólo información de agentes.	62
XXI	Matriz de confusión de la estimación de actividad para el rol enfermera operativa, utilizando sólo información de artefactos.	63
XXII	Matriz de confusión de la estimación de actividad para el rol médico base, utilizando sólo información de agentes.	63
XXIII	Matriz de confusión de la estimación de actividad para el rol médico interno, utilizando sólo información de agentes.	64
XXIV	Matriz de confusión de la estimación de actividad para el rol enfermera operativa, utilizando sólo información de agentes, sin la actividad clases y capacitación (CC)	64
XXV	Estimaciones con redes neuronales sin la variable hora. Rol enfermera operativa, error de estimación 24.93%	70
XXVI	Estimaciones con redes neuronales sin la variable hora. Rol médico de base, error de estimación 35.31%	70
XXVII	Estimaciones con redes neuronales sin la variable hora. Rol médico interno, error de estimación 44.8%	71
XXVIII	Actividades secundarias y actividades de más alto nivel de abstracción	72
XXIX	Estimaciones de actividades secundarias con redes neuronales. Rol médico base, error de estimación 50.67%	72
XXX	Estimaciones con redes neuronales utilizando el vector de entrada reducido. Rol enfermera operativa, error de estimación 29.07%	74
XXXI	Estimaciones con el modelo simple. Rol enfermera operativa, error de estimación 8.32%	74
XXXII	Estimaciones con el modelo simple. Rol médico de base, error de estimación 16.25%	75

LISTA DE TABLAS (Continuación)

Tabla		Página
XXXIII	Estimaciones con el modelo en paralelo. Rol enfermera operativa, error de estimación 6.08%	75
XXXIV	Estimaciones con el modelo en paralelo. Rol médico de base, error de estimación 7.92%	76
XXXV	Estimaciones con el modelo en paralelo. Rol médico interno, error de estimación 3.25%	76
XXXVI	Porcentajes de error en la estimación de actividad por rol	77
XXXVII	Estimaciones con observadores expertos. Rol enfermera operativa, error de estimación 48.05%	82
XXXVIII	Estimaciones con observadores expertos. Rol médico de base, error de estimación 30%	82
XXXIX	Estimaciones con observadores expertos. Rol médico interno, error de estimación 65%	83

Capítulo I

Introducción

En este capítulo se presentan los antecedentes, la importancia de estimar la actividad que realizan las personas, y se presentan los objetivos y la metodología seguida en el desarrollo del trabajo. Finalmente se describe brevemente la organización de la tesis.

1.1. Antecedentes

El cómputo consciente del contexto ofrece muchas ventajas para la interacción humano computadora, aumentando los ambientes inteligentes con artefactos computacionales que pueden responder a las necesidades de los usuarios. Uno de los principales retos de la computación consciente del contexto es el reconocimiento del contexto. Mientras algunas variables contextuales como ubicación, pueden ser reconocidas con relativa facilidad, otras como la actividad son más difíciles de estimar, dado que no se puede conocer de manera directa con simples sensores [Schmidt, et al., 1999].

A medida que los sistemas conscientes del contexto van formando parte de nuestro entorno, se incrementa la necesidad de ambientes inteligentes conscientes de la actividad, que sean capaces de responder a las necesidades del usuario y proveer servicios. Es decir, saber qué actividad está realizando el usuario se ha vuelto relevante para algunas aplicaciones donde el tipo de información requerida está ampliamente relacionada con la ubicación del usuario, los artefactos que utiliza y las personas con las que interactúa mientras realiza una actividad.

Hasta el momento, no se ha encontrado un método de estimación de actividad, para actividades complejas en un ambiente altamente dinámico [Bardram, 2003] que brinde resultados lo suficientemente buenos como para desarrollar aplicaciones. El trabajo previo muestra resultados aceptables [Huang, et al, 2004; Oliver, et al., 2004; Zhang, et al., 2006], pero las estimaciones de actividad están fuertemente ligadas a un espacio cerrado (oficina).

Otro trabajo, realizado en un ambiente de casa [AwareHome Project], aunque también presenta buenos resultados, aún no presenta aplicaciones en donde se utilicen los resultados obtenidos. La escalabilidad es el principal inconveniente que se observa en el trabajo previo, ya que difícilmente se podría generalizar la aplicación de los modelos en ambientes altamente dinámicos (por ejemplo hospitales), que presenten actividades más complejas de estimar. El enfoque presentado por Favela, et al., [2006] si bien estima la actividad en un ambiente hospitalario, los resultados presentados no brindan suficiente confiabilidad para desarrollar una aplicación centrada en la actividad.

En este trabajo se propone un enfoque para estimar actividades en un ambiente hospitalario que retoma la estimación de actividad utilizando redes neuronales en un ambiente hospitalario propuesta en [Favela, et al, 2007]. Este enfoque se basa en la información obtenida de un estudio de sombra [McDonald, 2005; Morán, et al., 2006; Tang y Carpendale, 2007], en el que 196 horas de observación detallada de trabajadores hospitalarios fue registrada. La colección de datos se pretende analizar para determinar el conjunto de variables sensibles al contexto que aporten mayor información para la estimación de actividad. El modelo que se propone en este trabajo de tesis, se basa en el uso de modelos ocultos de Markov, que será comparado con los resultados de las estimaciones de actividad en las que se utilizaron redes neuronales.

1.2. Importancia de la Estimación de Actividad

La relevancia de la información consciente del contexto, radica en el tipo de aplicación y el uso que se hace de ella en un ambiente determinado. Por ejemplo, en un ambiente de oficina determinar la presencia o disponibilidad de una persona en base a los datos obtenidos de video, audio o interacción con la computadora, puede aceptar un grado de incertidumbre considerable.

Pero en un ambiente médico es necesario tener una mayor certidumbre, más aún si se trata de un sistema que provee información automática de acuerdo a la localización, rol o actividad. Dado que el personal es altamente móvil y en ocasiones interactúa con tecnología que cada día es más compleja. Por ejemplo, un sistema consciente de la localización puede desplegar en una PDA (Personal Digital Assistant, por sus siglas en inglés) un expediente médico, si el error en la localización es mayor a dos metros. Este error puede causar que se muestre un expediente incorrecto, y con ello puede repercutir en la salud del paciente debido a una incorrecta valoración y/o medicación, incluso se podría ocasionar la muerte por una medicación incorrecta.

El contar con información acerca de la actividad de un trabajador hospitalario puede servir para iniciar una colaboración, por ejemplo: una enfermera que pueda obtener información de la actividad de las personas con las que desea interactuar, podría realizar otra actividad mientras espera a que un especialista termine una actividad (examinar a un paciente) para poder consultarlo. Por otra parte, las enfermeras requieren de mucho tiempo para documentar su trabajo, así, si un sistema es consciente de la actividad de la enfermera, la toma de signos vitales o la administración de medicamento podría ser automáticamente almacenada en el PDA o Tablet PC de la enfermera, o bien almacenado directamente en el expediente médico del paciente. Por otra parte, si el sistema está consciente de que una enfermera está realizando preparación de material y medicamentos, el sistema podría proveer de manera precisa (despliegue en display ambiental o PDA) el listado de medicamentos, las dosis, así como las etiquetas respectivas que facilitarían el proceso de distribución.

La ventaja que ofrece este enfoque es que ya se cuenta con la información necesaria obtenida del estudio de campo, por lo tanto, lo más destacado será el estudio de la relevancia de las variables contextuales, y el modelado para la estimación de actividad.

La presente propuesta de investigación, busca responder a las siguientes preguntas:

- ¿Cuáles son las variables sensibles al contexto que permiten de mejor manera estimar la actividad de un trabajador hospitalario?
- ¿Con que precisión puede estimarse la actividad utilizando modelos ocultos de Markov comparada con la estimación de actividad utilizando redes neuronales?
- ¿Cuál es el efecto que tiene el error en información de contexto primario, en la estimación de actividad?

1.3. Objetivos de la Investigación

En esta sección se presentan los objetivos de este trabajo de tesis.

1.1.1. Objetivo General

Estimar la actividad de trabajadores hospitalarios utilizando modelos ocultos de Markov, en base a la selección de variables contextuales de los registros de varias horas de seguimiento de médicos, enfermeras y médicos internos.

1.1.2. Objetivos Específicos

- ◆ Identificar las variables sensibles al contexto que mayor influencia tengan en la correcta estimación de las actividades de un trabajador hospitalario.
- ◆ Determinar cuál es el efecto que tiene la información errónea en la estimación de actividades.
- ◆ Realizar una comparación de los resultados obtenidos con el modelo de Markov con los resultados obtenidos utilizando redes neuronales.

1.4. Metodología

El desarrollo del trabajo inició con el análisis de la literatura, una revisión de los trabajos realizados y las diferentes técnicas o métodos propuestos para determinar la actividad humana. De manera paralela se revisó la teoría de modelos ocultos de Markov, los algoritmos y los tipos de modelos. Posteriormente se seleccionó el modelo adecuado para la estimación de actividad de acuerdo a la información obtenida.

Se realizó el análisis y la preparación de los datos obtenidos durante el estudio de campo reportado en Morán, et al [2006]. El análisis de sensibilidad de las variables contextuales consistió en calcular los porcentajes de aparición de cada variable en cada una de las actividades. Sólo aquellas variables que tuvieran un porcentaje de aparición mayor al 50% en cada actividad se tomaron en cuenta para formar el vector de entrada. El análisis permitió definir qué variables sensibles al contexto son relevantes para estimar la actividad de un trabajador hospitalario.

Se propusieron dos modelos en capas utilizando modelos ocultos de Markov, un modelo simple y un modelo en paralelo. El modelo simple utiliza un modelo oculto de Markov que procesa la información de una variable contextual en el primer nivel, las salidas del modelo se concatenan con la información de otra variable contextual y el modelo oculto del nivel superior estima la actividad. El modelo en paralelo utiliza en el primer nivel dos modelos ocultos de Markov para procesar la información de dos variables contextuales, las salidas de ambos modelos se concatenan para alimentar otro modelo oculto de Markov en el nivel superior, que finalmente estima la actividad.

El análisis de los resultados de los modelos propuestos permitió concluir cuál es el mejor modelo para la estimación de actividad de trabajadores hospitalarios. Se realizó una comparativa con los resultados de un estudio con observadores expertos, así como una

comparativa con los resultados de la estimación de actividad con redes neuronales publicados en Favela, et al [2006]. Adicionalmente se mostró la robustez del modelo ante entradas con ruido.

1.5. Organización de la Tesis

En esta sección se detalla el contenido y la organización de este trabajo. En este primer capítulo se presenta una introducción general para familiarizar al lector con el problema abordado, los objetivos del mismo, y la metodología seguida.

En el capítulo II se presenta una introducción al cómputo ubicuo, cómputo consciente del contexto e inteligencia ambiental. Ya que este trabajo de tesis se ubica dentro del cómputo consciente de la actividad, se describen los trabajos en el área de reconocimiento de actividad humana y se presenta una discusión del trabajo previo. Con el objetivo de dar una idea de la relevancia y dificultad de la estimación de actividad en ambientes dinámicos.

En el capítulo III se presenta una introducción a los modelos ocultos de Markov, de modo que al finalizar ese capítulo se tenga una noción de la manera en que funcionan las estimaciones del modelo a través de las observaciones.

En el capítulo IV se describe el tratamiento de los datos de entrada, es decir la recolección y la representación de los datos obtenidos del seguimiento de sombra en un hospital. Se presenta el estudio de la relevancia de las variables contextuales en alto y bajo nivel, y se plantean los dos diseños en capas propuestos para la estimación de actividad.

En el capítulo V se presentan los resultados de los experimentos desarrollados con los modelos propuestos en el capítulo IV. Además, se presentan los resultados de estimación de otro experimento con observadores expertos y se presenta una comparativa de ambos resultados con los de redes neuronales.

En el capítulo VI se presentan las conclusiones del trabajo realizado, así como las contribuciones del mismo. Además, se presentan propuestas para trabajo futuro.

Capítulo II

Reconocimiento de Actividad Humana

En este capítulo se presentan los conceptos de cómputo ubicuo, cómputo consciente del contexto e inteligencia ambiental. Se describen los trabajos en el área de reconocimiento de actividad humana y se presenta un análisis del trabajo previo relevante.

II.1. Cómputo Ubicuo

El término cómputo ubicuo (ubicomp) fue introducido por Weiser [1991]. El concepto realza el uso de varias computadoras al servicio de un usuario en un ambiente cotidiano. En estos ambientes la interacción con los dispositivos es transparente al usuario, es decir, el manejo de la información necesaria para brindar un servicio debe ser obtenida de tal forma que el usuario se pueda conducir de manera natural, como lo hacía antes de contar con un ambiente aumentado con tecnología.

El cómputo ubicuo se desarrolla basado en tres modelos teóricos [Abowd, et al., 2002]:

- ◆ Teoría de Actividad. Reconoce conceptos como metas, acciones y operaciones. Se basa en los cambios del mundo físico en lugar de cambios de planes a priori. Aunque las operaciones requieren poca o nada de atención explícita, como por ejemplo manejar un automóvil, las operaciones pueden convertirse en acciones basadas en cambios de las circunstancias tales como tráfico o condiciones del estado del tiempo. Dicha teoría se enfoca en las propiedades de transformación de los artefactos y la ejecución fluida de las acciones y operaciones.

- ◆ Acción situada. Enfatiza los aspectos de improvisación del comportamiento humano y resta énfasis a los planes a priori que una persona realiza. En este modelo el conocimiento del mundo traza continuamente la interpretación actual y la ejecución de una tarea.

- ◆ Conocimiento distribuido. Resta también énfasis al conocimiento humano interno, pero considera a los humanos como parte de un sistema mayor. Esta teoría se enfoca en el proceso colaborativo, en donde varias personas utilizan múltiples objetos para alcanzar una meta a gran escala. Presta mayor atención al conocimiento en el mundo, porque mucha de la información necesaria para alcanzar la meta del sistema está codificada en objetos individuales.

II.1.1. Cómputo Consciente del Contexto

El ser humano por naturaleza cambia su propio contexto y se adapta de acuerdo al lugar en el que se encuentra y a las personas con las que interactúa con el objetivo de socializar como parte integral de las personas.

En general, contexto [RAE] puede ser definido como un entorno físico o de situación, ya sea político, histórico, cultural o de cualquier otra índole, en el cual se considera un hecho. El contexto se define también como cualquier información que puede ser usada para representar la situación de una entidad [Dey, 2000]. Y se denomina información de contexto a los datos, teorías y supuestos que no surgen de la fuente de información, sino que se extraen de otros ámbitos, y que son de utilidad para la interpretación de la realidad

El término consciente del contexto fue introducido en 1994; de ahí se derivaron varias definiciones en torno al software consciente del contexto, que en Schilit y Theimer [1994], es definido como un software que se adapta según la localización, la colección de personas que se encuentran cerca, servidores y dispositivos, así como cambios en el tiempo. Un sistema con estas capacidades puede examinar el ambiente y reaccionar a los cambios. De aquí se propone que los tres aspectos importantes dentro del contexto son: dónde estás, con quién estás y qué recursos están cerca [Schilit, et al., 1994].

El objetivo de usar cómputo consciente del contexto es facilitar la interacción del ser humano con las computadoras, de tal forma que el contexto se derive automáticamente. La mayoría de las definiciones de contexto consideran cuatro principales dimensiones de contexto [Gross y Specht, 2001]:

La localización: como parámetro que puede ser especificado en un espacio físico o electrónico. Un artefacto puede tener una posición física o electrónica descrita por URISs o URLs. Los servicios basados en localización son un tipo de aplicación consciente del contexto, que pueden basarse en el mapeo entre la presencia física de un artefacto y la presentación electrónica correspondiente del artefacto.

La identidad: La identidad de una persona da acceso a información contextual de segundo nivel. En algunas aplicaciones conscientes del contexto se utilizan modelos altamente sofisticados e inferencias de información acerca de los intereses del usuario, preferencias, conocimiento y actividades detalladas como movimientos físicos y manipulación de artefactos.

El tiempo: El tiempo es una importante dimensión para definir contexto. En conjunción con las especificaciones de localización son las dimensiones mayormente utilizadas en las aplicaciones conscientes del contexto. Por ejemplo, la programación de una simple alarma para despertarnos y asistir a un evento o bien encender/apagar de manera automática las luces de una casa.

La actividad o el ambiente: El ambiente describe los artefactos y la ubicación física de la situación actual. En algunos proyectos se utiliza la información ambiental (presencia de una persona en particular) para presentar información al usuario, o bien sensores de temperatura y presencia de usuarios para activar de manera automática el funcionamiento del aire acondicionado en una habitación.

Las dimensiones anteriores responden a las preguntas: ¿Qué es contexto?, ¿Quién se puede beneficiar de la consciencia de su contexto?, ¿quién o qué es lo importante del contexto?, ¿dónde puede ser explotada la consciencia del contexto?, ¿cuándo es útil la consciencia del contexto?, ¿por qué son útiles las aplicaciones conscientes del contexto? Las respuestas a dichas preguntas son la base de la meta-pregunta: ¿Cómo debemos implementar la consciencia del contexto para poder desarrollar aplicaciones conscientes del contexto? (Schilit, 2000). Estas seis preguntas se pueden resumir como el qué, quién, dónde, cuándo, por qué y cómo del contexto.

Se han definido varios modelos que describen diversos aspectos que deben ser tomados en cuenta para la creación de sistemas conscientes del contexto. Un primer modelo toma como referencia los elementos relevantes del contexto: dónde estás, quién eres y qué recursos se encuentran cerca, y clasifican al contexto en tres categorías [Schilit, et al., 1994]:

- Contexto del usuario (el perfil de usuario, localización, personas cercanas, situación social, actividad, condiciones de la salud, el ajuste de la agenda, etc).
- Contexto de ejecución (tráfico de la red, estado del dispositivo, disponibilidad de recursos, costos de la comunicación, recursos próximos, etc.).
- Contexto del ambiente (clima, luz, nivel de ruido, temperatura, tiempo, etc.).

Otro planteamiento para realizar sistemas de cómputo conscientes del ambiente del usuario consiste en distinguir entre dos tipos de contexto, contexto primario y contexto secundario. El *contexto primario* se obtiene de los datos de sensores de bajo nivel; como ubicación, hora e identidad. El tipo de contexto primario describe la situación de una entidad y se utiliza para recuperar información contextual de tipo secundario [Dey, 2000]. Para derivar el *contexto secundario* se procesan los datos de los sensores. Se toman los valores de un sensor simple en cierto tiempo y las salidas se utilizan para deducir el contexto. Por ejemplo, la actividad actual de un usuario puede ser determinada estableciendo su identidad

y la hora actual para posteriormente recuperar perfiles de interés y/o adquirir información del calendario del usuario.

II.1.2. Inteligencia Ambiental (AmI)

La visión de ambientes inteligentes describe un entorno ubicuo equipado con dispositivos computacionales que se encuentran en segundo plano y que tienen capacidades inteligentes para apoyar las metas y actividades centradas en el usuario [Shadbolt, 2003]. Un ambiente es ubicuo en el sentido de que mejora el entorno físico con dispositivos computacionales heterogéneos y dispositivos de comunicación inalámbrica integrados de manera natural y al mismo tiempo invisibles al usuario [Weiser, 1991]. De aquí que las aplicaciones AmI necesitan contar con capacidades “inteligentes” para adaptarse a los usuarios y ser reactivos al contexto con el objetivo de proveer servicios de alta calidad basados en sus preferencias. La consciencia del contexto permite a los ambientes inteligentes tomar la responsabilidad de servir a los usuarios adaptándose a sus necesidades, y mejorando las tareas de acuerdo a la naturaleza del espacio físico.

Esto ha motivado el desarrollo de sistemas conscientes del contexto para aplicaciones de AmI. Por ejemplo, una simple alarma consciente de la hora puede encender una cafetera o abrir las cortinas de una recámara cuando el usuario despierta. Un automóvil equipado con GPS (por sus siglas en inglés Global Positioning System) puede informar al usuario la mejor ruta para llegar a un destino. Finalmente, sistemas aumentados con etiquetas RFID (por sus siglas en inglés Radio Frequency IDentification), lectores de huella digital y reconocimiento de iris se utilizan para identificar personas. Dicho reconocimiento puede proveer servicios en base a ciertos perfiles, así como permitir acceso a información restringida, como lo son las cuentas bancarias. De aquí que el reconocimiento de contexto se está convirtiendo en un componente central para muchas aplicaciones de AmI.

Mientras una cantidad considerable de trabajo se ha hecho en torno al desarrollo de enfoques robustos que estiman tiempo, ubicación, e identidad, como dimensiones de contexto, la dimensión de actividad ha sido dejada a un lado. Dado que las actividades humanas son complejas y dinámicas, no es claro qué información es relevante para modelar las actividades, ni cómo puede ser estimada una actividad. De aquí se sugiere que deben ser desarrollados enfoques robustos para estimar actividades humanas. Estos enfoques deben establecer qué información es relevante para inferir una actividad, qué cantidad de información recuperada de manera automática se requiere y cuáles tecnologías son apropiadas para adquirir dicha información.

II.2. Reconocimiento de Actividad Humana

Se han desarrollado hasta la fecha algunos sistemas que permiten determinar la actividad humana así como la disponibilidad de las personas; para ello se han basado en métodos probabilísticos tales como reglas de inferencia, redes bayesianas, redes neuronales y modelos ocultos de Markov. Los esfuerzos para inferir la actividad de las personas utilizando diferentes técnicas varían desde enfoques que estiman actividades de baja abstracción (por ejemplo hablando o sentado) hasta enfoques para estimar actividades más complejas.

Se ha propuesto el uso de reglas de producción para identificar actividades complejas realizadas por trabajadores hospitalarios [Christensen, 2002]. La presencia de etiquetas RFID adheridas a artefactos y personas se utilizaron para disparar reglas de inferencia codificadas utilizando ingeniería del conocimiento.

Para el reconocimiento de actividad basada en sensores se han reportado métodos de reconocimiento y clasificación de usuarios sentados, de pie y comportamiento de caminata. Para obtener la velocidad angular se utilizan sensores en la ropa [Lee y Mase, 2002], como lo muestra la figura 1. La información de los sensores permite clasificar los

comportamientos de caminata en tres subcategorías, caminando, subiendo y bajando escaleras. Basado en el reconocimiento de esas actividades, proponen un método para detectar la transición en ambientes predefinidos, que utilizan el movimiento incremental en el tiempo con un algoritmo simple de vecinos cercanos. Presentaron un 68% de exactitud o certeza.

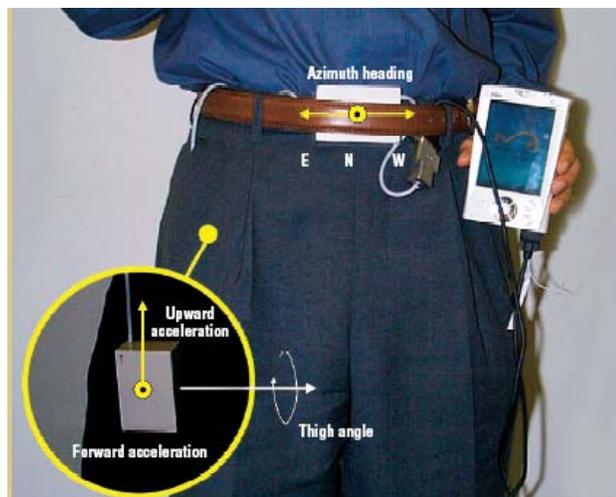


Figura 1. Estimación de actividad por medio de sensores en la ropa.

Por otro lado, se han presentado estudios cuantitativos [Hudson, et al., 2005] que demuestran que la información de sensores (por ejemplo la grabación de video, micrófonos, uso del teléfono, e información de actividad del mouse y/o del teclado y varias combinaciones de los anteriores) pueden apoyar la construcción de modelos que predicen la actividad humana tan bien como lo hacen las personas. La predicción de la actividad permite además inferir la disponibilidad de las personas. Los resultados de estimaciones correctas en cuanto a la disponibilidad de las personas, utilizando los sensores más sencillos (detección de voz), fueron del 76.5%.

La actividad también ha sido inferida por la detección de interacción entre usuarios con objetos particulares mediante la lectura con un guante detector de RFID [Philipose, et al.,

2004], obteniendo un 73% de certeza. Esto se realiza etiquetando cada artefacto de interés con una etiqueta RFID y leyendo a través de un guante detector de RFID (ver figura 2).

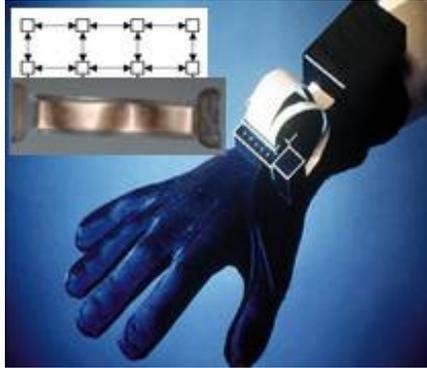


Figura 2. Guante detector de RFID, para estimación de actividad mediante interacción con objetos con etiquetas RFID.

Similar a los dos proyectos anteriores, y como parte del proyecto de Georgia Tech AwareHome, se utilizan grabaciones de audio y video, e información de diferentes sensores para monitorear las actividades en un ambiente de casa [AwareHome Project]. El objetivo que se persigue es que la casa “inteligente” sea capaz de proveer los servicios necesarios a los habitantes. Aunque aún no se han reportado resultados en cuanto a las estimaciones de actividad y los servicios como respuesta a dichas estimaciones, ya se cuenta con la información recopilada para modelar aplicaciones.

La implementación de un sistema llamado SEER [Oliver, et al., 2004] que estima actividades con un alto nivel de abstracción (por ejemplo, una persona se encuentra en una conferencia) utilizando modelos ocultos de Markov, en capas y en paralelo. La información contextual de audio, video e interacción con la computadora obtenida de sensores distribuidos en un ambiente de oficina se usan para inferir la actividad que se está llevando a cabo. La figura 3 muestra la arquitectura del sistema SEER, con la que se obtuvo una precisión de 99.7%.

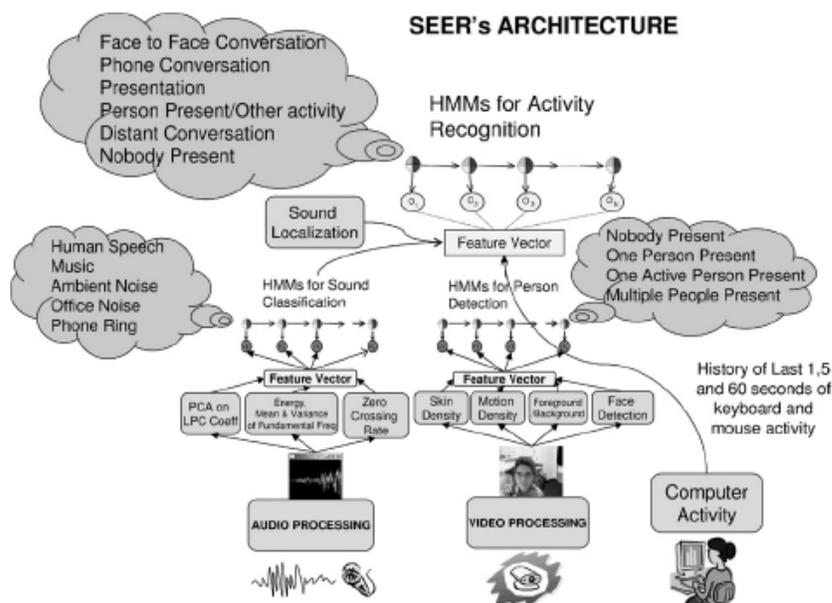


Figura 3. Arquitectura del sistema SEER, para estimación de actividad en un ambiente de oficina.

Para inferir las actividades de un usuario en una oficina [Huang, et al, 2004], se integra la información contextual de múltiples entradas de sensores. Utilizan una arquitectura en capas para modelar las actividades humanas con diferentes granularidades. Un árbol IHDR (por sus siglas en inglés, incremental hierarchical discriminant regression) se utiliza para generar automáticamente modelos de señales acústicas de cadenas no segmentadas, con alta capacidad de adaptación a nuevos entornos. Los modelos ocultos de Markov se implementaron para detectar patrones de movimiento. Las salidas de los dos componentes (IHDR y modelos ocultos de Markov) alimentan un modelo oculto de Markov que analiza la actividad humana. La precisión de las estimaciones fue de 95%.

El trabajo propuesto por Zhang, et al., [2006] propone el modelado de acciones individuales y grupales utilizando modelos ocultos de Markov en capas. Para definir de manera apropiada el conjunto de acciones individuales, las acciones de grupo se modelan

como un proceso en dos capas; uno que modela las actividades individuales a través de características de audio y video, y otro que modela las interacciones. La figura 4 muestra en la parte superior un ejemplo de la actividad grupal que se estima, “una presentación”, y la parte inferior presenta el modelo general utilizado para estimar la actividad. La precisión de dicho modelo para las acciones individuales es 89.7%, y para las acciones grupales es 70.3%.

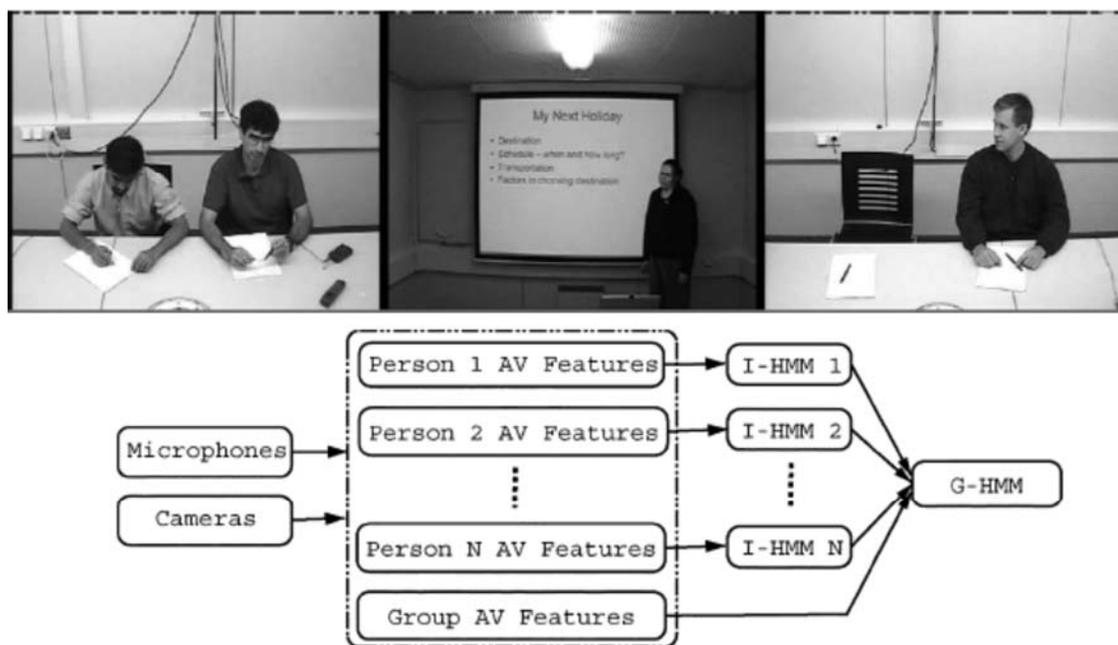


Figura 4. Estimación de actividad individual y grupal, modelo general.

Otro enfoque utilizó redes neuronales (RN) de retropropagación y fue entrenada para mapear información contextual (es decir la ubicación de un empleado en un hospital, artefactos que se utilizan, las personas con las que colabora y la hora) mientras los trabajadores hospitalarios realizan sus actividades [Favela, et al., 2007]. De aquí, algunas neuronas –ubicación, artefactos, agentes y hora-se utilizaron como entradas, en donde la salida representa la actividad. La figura 5 a la izquierda muestra el momento de la captura de la información que posteriormente se codificó, para alimentar las entradas de la red

neuronal, y a la derecha el modelo de la red neuronal utilizado. Los resultados indicaron que se puede determinar correctamente la actividad de los trabajadores hospitalarios el 75% de las veces.

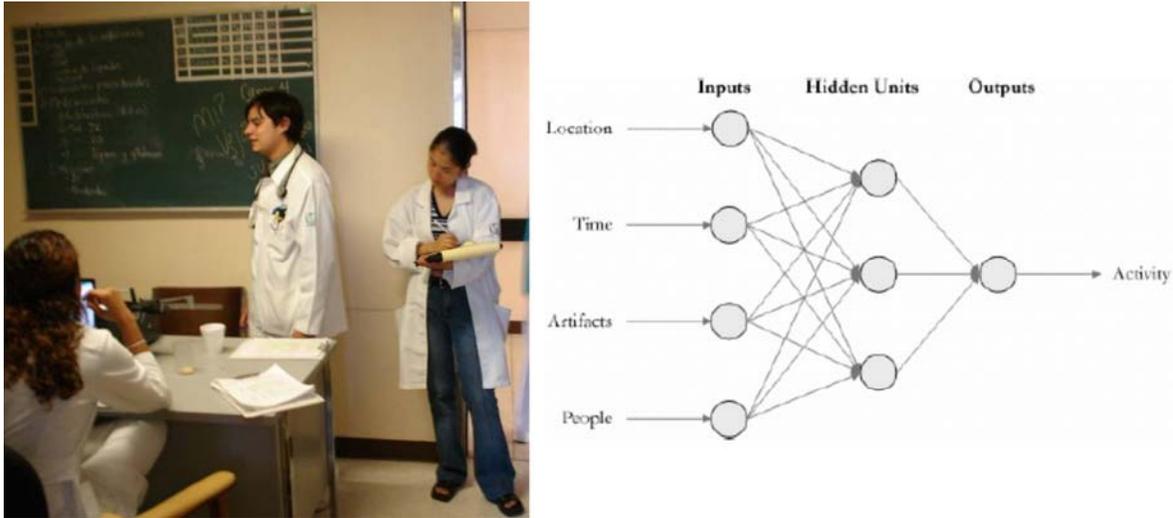


Figura 5. Estimación de actividad, captura de la información y modelo.

La descripción de los sistemas que permiten estimar la actividad han sido sólo propuestas de diferentes enfoques, pero cabe resaltar que los resultados obtenidos aún no se han implementado en aplicaciones, es decir, ya se estimó la actividad pero ninguno presenta una aplicación que utilice la información de la actividad.

II.3. Estimación de Actividad en Aplicaciones Conscientes del Contexto

Un ejemplo de una aplicación que se centra en la actividad humana, así como en las preferencias musicales, es el sistema XPod, que se adapta para reproducir la música correcta de acuerdo al contexto [Sandor, et al., 2007]. El sistema utiliza un dispositivo sujetado al cuerpo (como muestra la figura 6) que mide con precisión el estado sociológico

del usuario, obtenido a través de un número de variables que determinan los niveles de actividad del usuario (pasivo, activo, descansando), movimiento y estado físico; y de esa manera decide cuál es la música apropiada para reproducirse en ese momento.



Figura 6. XPod - Reproducción de audio, en base a la estimación de Actividad.

Un ambiente de trabajo que se puede beneficiar del uso de aplicaciones conscientes del contexto son los hospitales [Bardram, 2004; Bardram, et al., 2006; Morán, et al., 2006]. Son ambientes ricos en tecnología, en los que los trabajadores experimentan un alto nivel de movilidad resultando en infraestructuras de información con artefactos distribuidos en

todo el hospital. Algunos elementos de cómputo consciente del contexto están siendo gradualmente introducidos en hospitales. Estos varían desde redes inalámbricas, PDAs [Chin, 2005], etiquetas RFID para el seguimiento (monitoreo) de pacientes [O'Connor, 2006], dispositivos de comunicación activados por voz [Stanford, 2003] y sensores para monitoreo de pacientes [Pentland, 2004]. No obstante, experiencias en el desarrollo de aplicaciones conscientes del contexto en hospitales han enfatizado que deben proveer “confianza en la acción” para la adopción exitosa de tales aplicaciones [Bardram, 2004]. Esto ha motivado el desarrollo de aplicaciones conscientes del contexto que son capaces de descubrir la meta actual del usuario utilizando tales tecnologías, estipulando cómo adaptar aplicaciones conscientes del contexto para presentar servicios e información apropiados al usuario.

II.3.1. Detección de Disponibilidad en Hospitales

Como una muestra de las aplicaciones conscientes de la actividad en un ambiente hospitalario, el sistema de comunicación Vocera [Stanford, 2003] utiliza una etiqueta controlada por voz que permite a los usuarios comunicarse a través de una red inalámbrica en un hospital. La figura 7 muestra la arquitectura de dicho sistema.



Figura 7. Sistema de comunicación Vocera.

Ya que la actividad puede ser estimada con un sistema como éste, se cuenta con información suficiente para decidir a qué enfermera llamar de acuerdo a su disponibilidad. El sistema incluso determina cuándo una enfermera atendiendo a un paciente tiene baja disponibilidad, comparada con una enfermera que se encuentre elaborando reportes.

II.4. Discusión de Trabajo Previo

La tabla I muestra un condensado del trabajo previo en el área de estimación de actividad humana.

Tabla I. Estimación de Actividad Humana.

Estimación de Actividad Humana				
<i>Estimación</i>	<i>Modelo</i>	<i>Oficina</i>		<i>Precisión</i>
		<i>Medio/fuente</i>	<i>Clases</i>	
Actividad individual y grupal [Zhang, et al., 2006]	MOM-C	Audio, video	Ind. 3 Gpo 8	89.7% 70.3%
Presencia en oficina [Huang, et al., 2004]	MOM, discriminante incremental jerárquico	Audio y video	4	95%
Actividad [Oliver, et al., 2004]	MOM-C	Audio, video, act. mouse y teclado	6	99.7%
Disponibilidad [Hudson, et al., 2005]	Bayes Naïve, máquinas de vector soporte y AdaBoost	Video, sensores y audio	2	75%
<i>Hogar</i>				
Actividad [Philipose, et al., 2004]	Inferencial	RFID, ADLs	14	88%
<i>Hospital</i>				
Actividad [Favela, et al., 2006]	RN	Estudio de sombra	5	75%

El proyecto de Georgia Tech AwareHome, que utiliza grabaciones de audio para monitorear e inferir actividades en un ambiente de casa con un 75% de certeza [AwareHome Project], tiene el problema de que las actividades detectadas (sentado, masticando) son muy específicas, haciendo difícil el desarrollo de aplicaciones conscientes del contexto en base a estas actividades.

En cuanto al uso de reglas de producción para identificar actividades realizadas por trabajadores hospitalarios [Christensen, 2002], la creación de estas reglas es una tarea muy laboriosa que requiere considerable experiencia y conocimiento del entorno para poder plantearlas.

La inferencia de la presencia de un usuario en una oficina [Huang, et al, 2004], con múltiples entradas de sensores (aun cuando presenta 95% de precisión) estima actividades un tanto simples (conversación, ruido, teléfono y silencio).

La actividad inferida a través de un guante detector de RFID [Philipose, et al., 2004], por su parte infiere actividades en base a artefactos en donde la relación es casi unívoca, es decir, si se detecta un cepillo de dientes, la actividad obvia es “higiene bucal” y no hay ninguna otra actividad con la que se pueda confundir.

Cabe resaltar que el presente trabajo no busca realizar una comparativa con el trabajo previo; lo que se pretende es plantear es tipo de actividades que se han estimado así como el nivel de abstracción de dichas actividades.

Con respecto a ambientes hospitalarios, el enfoque que usa redes neuronales (RN) de retropropagación [Favela, et al., 2006] presentó resultados en los que se puede predecir la actividad de los trabajadores hospitalarios el 75% de las veces. Aunque la certeza obtenida con este enfoque es suficiente para el desarrollo de algunas aplicaciones conscientes del contexto, no es suficiente para apoyar la naturaleza del trabajo hospitalario.

II.5. Resumen

En este capítulo se presentaron los conceptos de sistemas conscientes del contexto, así como de ambientes inteligentes. Se describieron brevemente los trabajos realizados en el campo de estimación de actividad utilizando variables contextuales, y finalmente se presentó una discusión del trabajo previo presentado. El siguiente capítulo describe el funcionamiento de los modelos ocultos de Markov, así como sus principales algoritmos.

Capítulo III

Modelos Ocultos de Markov

En este capítulo se presentan el concepto y la clasificación de los modelos de Markov. Se describen los algoritmos que se utilizan para procesar la información con los modelos ocultos de Markov. La parte final del capítulo presenta una descripción de las redes neuronales de retropropagación, dado que el objetivo es hacer una comparación con los resultados de la estimación de actividad, descritos en el capítulo anterior.

III.1. Procesos de Markov

Para definir un proceso de Markov es necesario considerar la definición de un proceso estocástico. Un proceso estocástico se define como una secuencia de variables aleatorias cuya distribución varía de acuerdo a un parámetro, generalmente el tiempo.

Un modelo estocástico es el que predice un conjunto de posibles salidas en base a similitud o probabilidad [Taylor y Karlin, 1994]. Por ejemplo la predicción del estado del tiempo (ver figura 8) no se puede realizar de manera sencilla con el solo conocimiento del estado del tiempo del día anterior. Se puede realizar una estimación, pero no se puede asegurar que sea una predicción correcta.



Figura 8. Estados de un modelo estocástico.

Los modelos de Markov se pueden clasificar de acuerdo a los estados y a las acciones que se realizan después de las estimaciones. El ejemplo más simple son las cadenas de Markov. En una cadena de Markov, el estado es completamente observable (conocido en todo momento), y no existen acciones (no hay toma de decisiones). Las cadenas de Markov sólo utilizan la información del estado anterior para deducir como se llegó al estado actual. Las probabilidades de transición se registran en una matriz de transición (una matriz estocástica), en donde cada vector fila representa la distribución de las probabilidades de transición del estado anterior al estado actual.

Un proceso de Markov de primer orden es aquel que realiza las estimaciones tomando como referencia el estado anterior, sin importar los estados previos. Dado un parámetro discreto $\{X(t), t = 0, 1, 2, \dots\}$ o un parámetro continuo $\{X(t), t \geq 0\}$ de un proceso estocástico, se dice que es un proceso de Markov sí, para cualquier conjunto de n puntos en el tiempo $t_1 < t_2 < \dots < t_n$, la distribución condicional de $X(t_n)$, para valores dados de $X(t_1), \dots, X(t_{n-1})$ depende únicamente del valor más reciente conocido $X(t_{n-1})$; de manera más precisa, para cualquier número real x_1, \dots, x_n

$$\begin{aligned} P[X(t_n) \leq x_n \mid X(t_1) = x_1, \dots, X(t_{n-1}) = x_{n-1}] \\ = P[X(t_n) \leq x_n \mid X(t_{n-1}) = x_{n-1}] \end{aligned}$$

Es decir, dado el presente del proceso, el futuro es independiente de su pasado [Parzen, 1999].

III.2. Modelos Ocultos de Markov

Los modelos ocultos de Markov (MOM o HMM por sus siglas en inglés, Hidden Markov Model) han sido usados por cerca de tres décadas en el procesamiento de señales, principalmente en el contexto de reconocimiento automático del habla [Rabiner y Juang, 1996]. Estas técnicas también han sido aplicadas en una amplia variedad de disciplinas

tales como acústica, biociencias, seguros, finanzas, climatología, procesos de control, comunicaciones, econometría, escritura y reconocimiento de texto, procesamiento de imágenes, visión por computadora y muchos otros campos.

Un MOM de acuerdo a Russell y Norving, [1993] es un modelo probabilístico temporal en donde cada estado del proceso está definido por una única variable aleatoria discreta. Los posibles valores de la variable son los estados posibles del modelo que corresponden a un evento observable (físico). Esta breve definición se basa en la descrita por Rabiner [1989]:

“Un Modelo Oculto de Markov es una máquina de estados finitos en la cual interactúan entre sí dos procesos estocásticos bien definidos: Un proceso estocástico que es no observable (“oculto”) que puede ser evidenciado solamente a través del proceso estocástico que produce la secuencia de observación (observable). El proceso oculto se compone de estados que están conectados entre sí por probabilidades de transición. Este proceso oculto está conectado a través de probabilidades de emisión con el proceso observable, que contiene los valores de las observaciones de salida”.

Los modelos ocultos de Markov se componen de los siguientes elementos básicos:

- El número de estados en el modelo (N), que comprende los estados ocultos del modelo. Estos estados, generalmente, están interconectados de tal forma que cada estado puede ser alcanzado desde cualquiera de los otros estados. Los estados individuales se denotan como $S = \{S_1, S_2, \dots, S_N\}$ y a los estados en un tiempo t se les denota como $Q = \{q_1 \dots q_n\}$
- Los estados observables (M), que son el número de los distintos símbolos de observación por estado, i.e. el tamaño del alfabeto discreto. Los símbolos de observación corresponden a la salida física del sistema que está siendo modelado. A la secuencia de posibles observaciones se le denomina $O = \{o_1 \dots o_m\}$

- La prioridad o distribución inicial de estados es la distribución inicial de estados del MOM, $\pi = \pi_i$ donde $\Pi = \{\pi_1 \dots \pi_N\}$, $\pi_i = P(S_0 = q_i)$. Y debe cumplir $\sum_{i=1}^N \pi_i = 1$
- La matriz de transición de estados es la distribución de probabilidad de transición entre los estados. Es una matriz cuadrada en donde cada elemento a_{ij} corresponde a la probabilidad de transición del estado q_i al estado q_j . $A = \{a_{ij}\}$, donde $a_{ij} = P(S_t = q_j | S_{t-1} = q_i)$. Dado que es una matriz estocástica debe cumplir $\sum_{j=1}^N a_{ij} = 1$.
- La matriz de observación se define como la distribución de probabilidad de observación del símbolo en el estado j , con $B = \{b_j(O_i)\}$, donde $b_j(O_i) = P(O_i | S_t = q_j)$.

Por conveniencia, se usa la notación compacta para indicar el conjunto de parámetros completo del modelo

$$\lambda = \{A, B, \pi\}.$$

Dependiendo de la naturaleza de las observaciones, se distinguen varias clases de MOM. Si las mismas son de naturaleza discreta (símbolos de un alfabeto), se dice que los MOM son discretos. Si por el contrario estas observaciones son de naturaleza continua (por ejemplo reconocimiento de voz), entonces estamos tratando con MOM continuos, con una función de densidad de probabilidad de emisión generalmente aproximada por una mezcla de Gaussianas. Una tercera familia de MOM son los llamados MOM semi-continuos, los cuales mutuamente optimizan los vectores de cuantificación y sus parámetros asociados (de los MOM), por medio de un esquema probabilístico unificado.

III.2.1. Algoritmos de los Modelos Ocultos de Markov

De acuerdo a [Rabiner, 1989], los problemas a resolver con los modelos ocultos de Markov son:

- Estructura del modelo, Aprendizaje, dado un modelo λ y un conjunto de observaciones, ¿cómo ajustar los parámetros del modelo para maximizar la probabilidad de observación de una secuencia? (algoritmo Baum-Welch)
- Evaluación, dado un modelo λ y una secuencia de T observaciones O, calcular $P(O | \lambda)$ de forma eficiente (algoritmo hacia delante-atrás).
- Decodificación, dado un modelo λ y una secuencia de T observaciones O, ¿cuál es la secuencia más probable de estados Q? (algoritmo Viterbi)

Los MOM se pueden utilizar para evaluar la probabilidad de que una secuencia haya sido producida por un modelo basándose en el proceso de producción de secuencias. Formalmente, conocida como una secuencia de observaciones $O_t = O_1 O_2 \dots O_t$ y el correspondiente modelo de Markov $\lambda = \{A, B, \pi\}$, para evaluar la probabilidad de que dicha secuencia haya sido producida por el modelo, $P(O_t | \lambda)$, han de considerarse todas las posibles secuencias de t estados. Si $Q = \{q_1 \dots q_n\}$ es una de dichas posibles secuencias de N estados, la probabilidad de la secuencia observada está dada por

$$P(O_n | \lambda) = \sum_{i=1}^{N-1} \pi_{q_i} b_{q_i}(O_i) a_{q_i q_{i+1}}.$$

III.2.1.1. Algoritmo Hacia Delante

La función $\alpha_j(t)$ para $0 < j < N$, denota la densidad de probabilidad de que un proceso de Markov se encuentre en el estado q_j en el tiempo t, y haya emitido la secuencia de vectores $O_1 O_2 \dots O_t$. Es decir, $\alpha_j(t) = P(O_1 O_2 \dots O_t, q_t)$, y puede expresarse en forma recursiva como

$$\alpha_t(i) = \sum_{j=1}^N (\alpha_{t-1}(j) a_{ji}) b_i(O_t).$$

El algoritmo hacia delante calcula $\alpha_j(t)$ de la siguiente forma:

- ◆ Inicialización

$$\alpha_1(i) = \pi_i b_i(O_1) \quad t = 1 \quad 1 \leq i \leq N$$

- ◆ Recursividad

$$\alpha_t(i) = \left[\sum_{j=1}^N \alpha_{t-1}(j) a_{ji} \right] b_i(O_t) \quad 1 \leq i \leq N \quad 2 \leq t \leq T$$

◆ Terminación

$$P(O | \lambda) = \sum_{i=1}^N \alpha_T(i).$$

La figura 9 representa el paso de inducción del algoritmo hacia delante, en donde el estado S_j puede ser alcanzado en el tiempo $t+1$ desde N posibles estados S_i en tiempo t . Dado que $\alpha_t(i)$ es la probabilidad de que se observen los eventos $O_1 O_2 \dots O_t$ y el estado en tiempo t es S_i , el producto $\alpha_t(i) a_{ij}$ es entonces la probabilidad de que el evento $O_1 O_2 \dots O_t$ sea observado, y el estado S_j sea alcanzado en tiempo $t+1$ a través del estado S_i en tiempo t . Sumando este producto sobre los N posibles estados S_i en tiempo t , resulta la probabilidad de S_j en tiempo $t+1$ con todas las observaciones parciales. Dado que ya se tiene el valor en el estado S_j es fácil ver que $\alpha_{t+1}(j)$ se obtiene contabilizando la observación O_{t+1} en estado j , es decir, multiplicando la cantidad sumada por la probabilidad $b_j(O_{t+1})$.

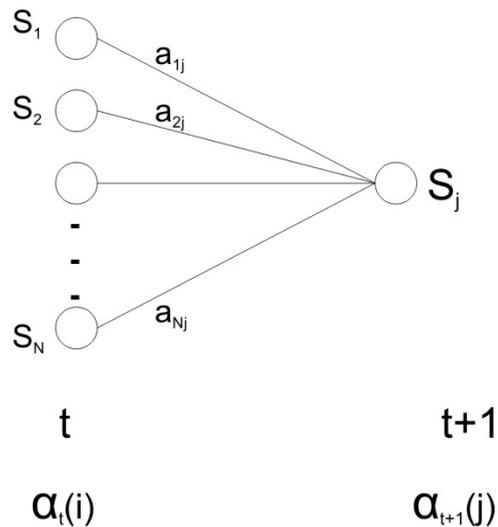


Figura 9. Algoritmo hacia delante (Forward).

Finalmente, la conclusión del algoritmo provee el valor deseado de $P(O|\lambda)$ como la suma de las variables terminales hacia delante $\alpha_T(i)$.

III.2.1.2. Algoritmo hacia Delante-Atrás (Forward-Backward)

Se realiza un cálculo de dos variables intermedias:

Hacia delante: $\alpha_t(i) = P(O_1 O_2 \dots O_t, q_t = S_i | \lambda)$ probabilidad de la secuencia de observaciones parciales $O_1 O_2 \dots O_t$ y el estado S_i en el instante t , para el modelo λ .

Atrás: $\beta_t(i) = P(O_{t+1} O_{t+2} \dots O_T | q_t = S_i, \lambda)$

Probabilidad de la observación parcial de la secuencia desde $t+1$ hasta el final, dado un estado S_i , y un modelo λ .

El algoritmo hacia delante para el cálculo de la variable $\alpha_1(i)$ se muestra a continuación. El detalle del cálculo del algoritmo está descrito en la subsección anterior (algoritmo hacia delante III.2.1.1).

- ◆ Inicialización

$$\alpha_1(i) = \pi_i b_i(O_1) \quad t = 1 \quad 1 \leq i \leq N$$

- ◆ Recursividad

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(O_{t+1}) \quad 1 \leq j \leq N \quad 1 \leq t \leq T-1$$

- ◆ Terminación

$$P(O | \lambda) = \sum_{i=1}^N \alpha_T(i).$$

Algoritmo Atrás para el cálculo de la variable $\beta_t(i)$.

- ◆ Inicialización

$$\beta_T(i) = 1 \quad t = 1 \quad 1 \leq i \leq N$$

◆ Recursividad

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(O_{t+1}) \beta_{t+1}(j) \quad 1 \leq j \leq N \quad t = T-1, T-2, \dots, 1$$

◆ Terminación

$$P(O | \lambda) = \sum_{i=1}^N \beta_T(i).$$

La figura 10 muestra el paso de inducción del cálculo de probabilidad atrás, en donde para estar (haber estado) en el estado S_j en el tiempo t , y contabilizar la secuencia de observación al tiempo $t+1$, es necesario considerar todos los posibles estados S_j en tiempo $t+1$, contabilizando la transición de S_i a S_j (el término a_{ij}), así como la observación O_{t+1} en el estado j (el término $b_j(O_{t+1})$) y entonces sumar el resto de la secuencia del estado j (el término $\beta_{t+1}(j)$) observación parcial.

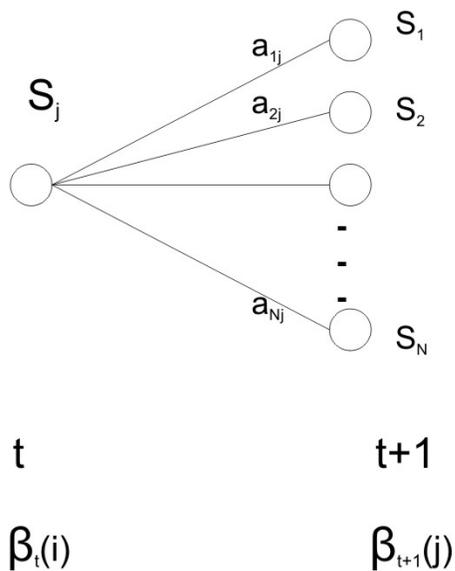


Figura 10. Algoritmo atrás.

Existen restricciones al utilizar el algoritmo de suavizado hacia delante-atrás; que la matriz de transición se pueda invertir y que el modelo sensor no contenga ceros, es decir, cada observación es posible en cada estado [Russell y Norving, 1993].

III.2.1.3. Algoritmo Baum-Welch (EM)

El algoritmo de Baum-Welch es un caso particular de algoritmo EM (“Expectation-Maximization”). El algoritmo Baum-Welch garantiza la convergencia uniforme hacia un máximo local de la función probabilidad de generación. El algoritmo realiza en cada iteración una estimación del conjunto de parámetros y luego maximiza la probabilidad de generar los datos de entrenamiento utilizando el modelo, de tal modo que la nueva probabilidad es mayor o igual a la previa. Estimación de máxima verosimilitud $\lambda_{MLE} = \arg \max P(O|\lambda)$. La figura 11 ilustra el proceso del algoritmo EM.

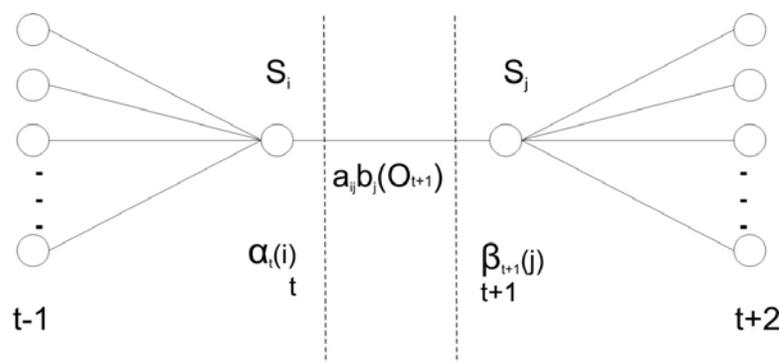


Figura 11. Algoritmo hacia delante-atrás.

Para describir el procedimiento de reestimación (actualización iterativa y perfeccionamiento) de los parámetros del MOM, se define la variable $\xi_t(i,j)$, la probabilidad de estar en el estado S_i en tiempo t , y en el estado S_j en tiempo $t+1$, dado el modelo y la secuencia de observación. Esto es,

$$\xi_t(i, j) = P(q_t = S_i, q_{t+1} = S_j | O, \lambda) .$$

De acuerdo a las variables hacia delante y atrás, se puede reescribir $\xi_t(i, j)$ de la forma

$$\xi_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{P(O | \lambda)} = \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)} \quad \sum_{i=1}^N \sum_{j=1}^N \xi_t(i, j) = 1.$$

Utilizando las fórmulas anteriores existe un método para reestimar las variables de un MOM. Los valores del modelo se reasignan de acuerdo a las siguientes ecuaciones [Rabiner, 1989]:

$$\begin{aligned} \bar{\pi} &= (\text{número esperado de veces de estar en } S_i \text{ en } t=1), \\ \bar{a} &= \frac{(\text{número esperado de transiciones realizadas desde } S_i \text{ hasta } S_j)}{(\text{número esperado de transiciones realizadas desde } S_i)}, \\ \bar{b}(k) &= \frac{(\text{núm esperado de veces de estar en } S_i \text{ y observar el símbolo } V_k)}{(\text{número esperado de veces de estar en } S_i)}. \end{aligned}$$

El procedimiento es iterativo siempre que $P(O | \bar{\lambda}) > P(O | \lambda)$.

La iteración finaliza cuando $\bar{\lambda} = \lambda$ (máx verosimilitud del MOM).

III.2.1.4. Algoritmo Viterbi

Se puede encontrar la secuencia más probable de estados ocultos listando todas las posibles secuencias de estados ocultos y encontrando la probabilidad de una secuencia observada para cada una de las combinaciones.

Para encontrar la mejor secuencia de estados $Q = \{q_1 q_2 \dots q_T\}$ para una secuencia de observación dada $O = \{O_1 O_2 \dots O_T\}$, necesitamos definir la cantidad

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P[q_1 q_2 \dots q_t = i, O_1 O_2 \dots O_t | \lambda],$$

es decir, $\delta_t(i)$ es la probabilidad más alta para el camino simple en tiempo t .

Para cada t y j es necesario guardar el camino seguido para conservar la secuencia de estados, por ello se utiliza el arreglo $\psi_t(j)$. Para obtener la secuencia más probable de estados ocultos el proceso a seguir es:

- ◆ Inicialización

$$\delta_1(i) = \pi_i b_i(O_1) \quad \psi_1(i) = 0 \quad t = 1, \quad 1 \leq i \leq N$$

- ◆ Recursividad

$$\delta_t(j) = \left[\max_{1 \leq i \leq N} \delta_{t-1}(i) a_{ij} \right] b_j(O_t) \quad \psi_t(j) = \arg \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] \quad 1 \leq j \leq N, 2 \leq t \leq T$$

- ◆ Terminación

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)] \quad q_T^* = \arg \max_{1 \leq i \leq N} [\delta_T(i)]$$

- ◆ Secuencia de estados óptima (backtraking)

$$q_t^* = \psi_{t+1}(q_{t+1}^*) \quad t = T-1, T-2, \dots, 1$$

El algoritmo Viterbi implementado en matlab realiza cálculos de probabilidades parciales para cada celda, es decir, basado en programación dinámica. Dado que se cuenta con la observación en tiempo t , se determina la secuencia más probable de haber llegado hasta el estado actual. Para la observación en tiempo $t+1$ se retoman los valores ya calculados en el tiempo t , y sólo se reestiman las probabilidades de esa observación con respecto a los caminos posibles anteriores. La figura 12 ilustra el proceso del algoritmo Viterbi, una vez finalizado el proceso descrito anteriormente.

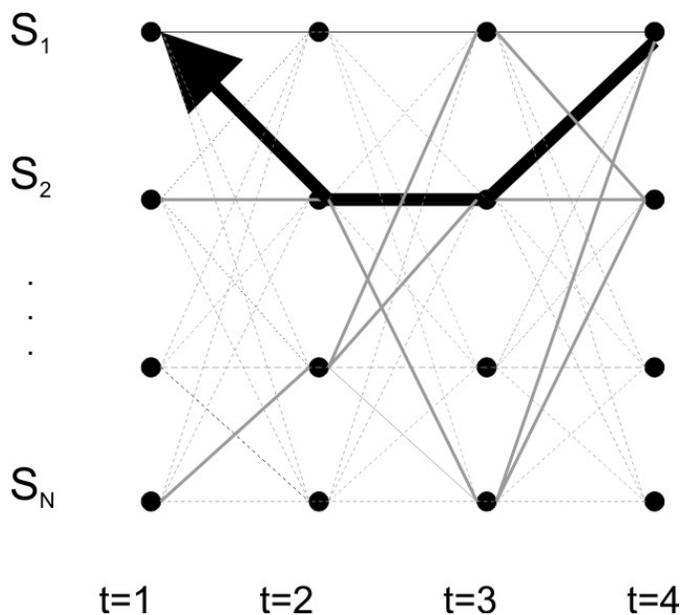


Figura 12. Algoritmo Viterbi.

III.3. Aplicando Modelos Ocultos de Markov Discretos

Un ejemplo que facilitará la comprensión del funcionamiento de los modelos ocultos de Markov discretos es la predicción del estado del tiempo, en donde sólo hay tres posibles estados: soleado, lluvioso y nublado [Resch, 2006], [Boyle, 2006]. Para realizar una predicción del clima del próximo día en base a como estuvo el clima ayer, anteayer, y así sucesivamente, se habla de una predicción en base a probabilidades; si se toma como referencia sólo la observación del día anterior, se le conoce como proceso de Markov de primer orden, es decir una observación en tiempo n , únicamente depende de la observación en tiempo $n-1$.

Como muestra la tabla II, sólo se requiere de $3^2=9$ números para representar las probabilidades de todas las secuencias.

Tabla II. Matriz de transición de estados, para estimación del estado del tiempo.

		Estado del tiempo mañana		
		Soleado	Lluvioso	Nublado
Estado del tiempo Hoy	Soleado	0.8	0.05	0.15
	Lluvioso	0.2	0.6	0.2
	Nublado	0.2	0.3	0.5

La figura 13 muestra la máquina de estados finitos para la predicción del estado del tiempo correspondiente a la tabla II.

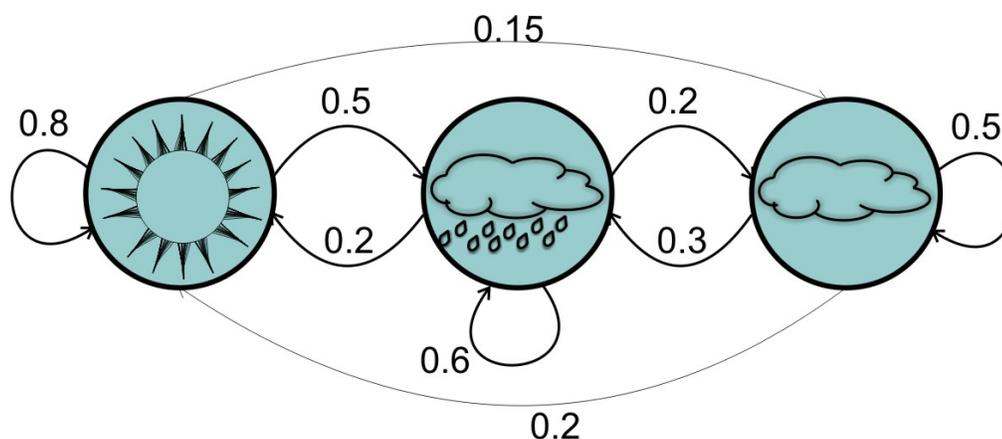


Figura 13. Máquina de estados finitos para la predicción del estado del tiempo.

Ahora supongamos que se está encerrado en un cuarto por varios días y se desea saber como está el clima afuera. La única pieza de evidencia con que se cuenta es cuando una persona que diariamente lleva la comida entra al cuarto con una sombrilla o sin ésta. La tabla III muestra la matriz de observación correspondiente a varios días.

Tabla III Matriz de emisión o matriz de observación para la estimación del estado del tiempo

	Prob. de Sombrilla	Prob. de no Sombrilla
Soleado	0.1	0.9
Lluvioso	0.8	0.2
Nublado	0.3	0.7

La figura 14 muestra el modelo oculto de Markov correspondiente a la estimación del estado del tiempo con tres estados ocultos correspondientes al estado del clima y dos estados observables (evidencia).

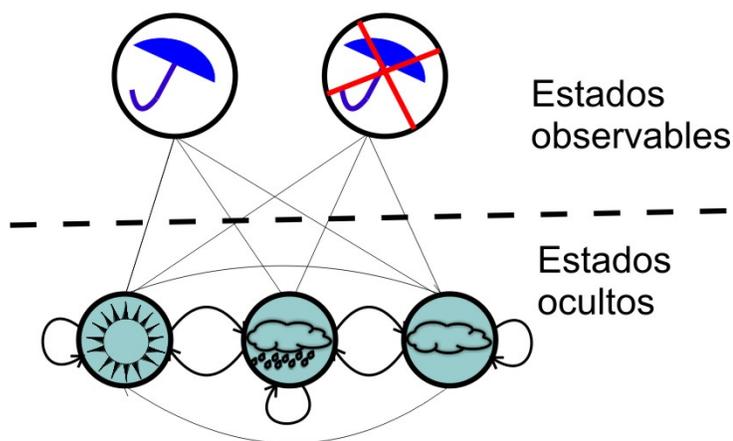


Figura 14. Modelo oculto de Markov para la estimación del estado del tiempo.

Teniendo ya el MOM del estado del tiempo, estando en el cuarto cerrado, y dadas las observaciones sombrilla, no sombrilla, sombrilla, se desea conocer la secuencia del estado del tiempo más probable usando el algoritmo de Viterbi. (Se supone que los tres estados del tiempo son equiprobables el día 1).

◆ Inicialización

$$t = 1, \quad \delta_1(sol) = \pi_{sol} b_{sol}(O_1) = \frac{1}{3} \cdot 0.9 = 0.3 \quad \psi_1(sol) = 0$$

$$\delta_1(lluv) = \pi_{lluv} b_{lluv}(O_1) = \frac{1}{3} \cdot 0.2 = 0.0667 \quad \psi_1(lluv) = 0$$

$$\delta_1(nub) = \pi_{nub} b_{nub}(O_1) = \frac{1}{3} \cdot 0.7 = 0.233 \quad \psi_1(nub) = 0$$

◆ Recursividad

$t = 2$

$$\delta_2(sol) = \max[\delta_1(sol) \cdot a_{12}, \delta_1(lluv) \cdot a_{21}, \delta_1(nub) \cdot a_{31}] b_{sol}(O_2) = \psi_2(sol) = \text{soleado}$$

$$\max[0.3 \cdot 0.8, 0.0667 \cdot 0.2, 0.233 \cdot 0.2] \cdot 0.1 = 0.024$$

Se aplica el mismo procedimiento para los estados lluvioso y nublado y se tiene $\delta_2(lluv)=0.056$, $\psi_2(lluv)=\text{nublado}$ y $\delta_2(nub)=0.035$, $\psi_2(nub)=\text{nublado}$.

$t = 3$

$$\delta_2(sol) = \max[\delta_2(sol) \cdot a_{11}, \delta_2(lluv) \cdot a_{21}, \delta_2(nub) \cdot a_{31}] b_{sol}(O_3) = \psi_3(sol) = \text{soleado}$$

$$\max[0.024 \cdot 0.8, 0.056 \cdot 0.2, 0.035 \cdot 0.2] \cdot 0.1 = 0.0019$$

Se aplica el mismo procedimiento para los estados lluvioso y nublado y se tiene $\delta_3(lluv)=0.0269$, $\psi_3(lluv)=\text{lluvioso}$ y $\delta_3(nub)=0.0052$, $\psi_3(nub)=\text{nublado}$.

◆ Terminación

$$P^* = \max[\delta_3(i)] = \delta_3(lluv) = 0.0269 \quad q_3^* = \arg \max[\delta_3(i)] = \text{lluvioso}$$

◆ Secuencia de estados óptima (backtraking)

$$q_t^* = \psi_3(q_3^*) = \psi_3(lluv) = \text{lluvioso} \quad t = T - 1 = 2$$

$$q_t^* = \psi_2(q_2^*) = \psi_2(lluv) = \text{nublado} \quad t = T - 1 = 1$$

Así, la secuencia más probable es: nublado, lluvioso, lluvioso.

No es trivial la tarea de encontrar la secuencia de estados del modelo HMM que emite una secuencia de observaciones de salida dada [Toselli, 2004]. Debido a la naturaleza probabilística de la salida generada por un estado, casi cualquier secuencia de estados podría en principio generar la secuencia observada. En otras palabras, la imposibilidad de hacer corresponder unívocamente una secuencia de observaciones de salida con una secuencia de estados oculta al observador la secuencia de estados que realmente generó

dicha secuencia de observaciones. Ésta es la razón de la denominación de Modelos Ocultos de Markov.

III.4. Redes Neuronales de Retropropagación

Una definición de red neuronal [Haykin, 1999] desde el punto de vista de máquinas adaptativas es:

“Una red neuronal es un procesador distribuido paralelo formado por el procesamiento de unidades simples, cuya tendencia natural es almacenar conocimiento experimental y hacerlo disponible para su uso. Se parece al cerebro humano en dos aspectos:

1. *El conocimiento es adquirido a través de un procesamiento de aprendizaje.*
2. *Conexiones fuertes entre neuronas, conocido como peso sináptico, son usadas para almacenar el conocimiento adquirido ”*

La neurona es la unidad de procesamiento básica de una red neuronal, en ésta se pueden identificar algunos elementos básicos, los cuales se mencionan a continuación:

1. Un conjunto de ligas sinápticas. Cada una de éstas tiene un peso asociado. Una señal de entrada conectada en la sinapsis de la neurona es multiplicada por el peso sináptico.
2. Sumador o combinador lineal. Para sumar o agregar las señales de entrada, que previamente fueron multiplicadas por los respectivos pesos sinápticos.

3. Una función de activación. Limita la amplitud de la señal de salida de la neurona.

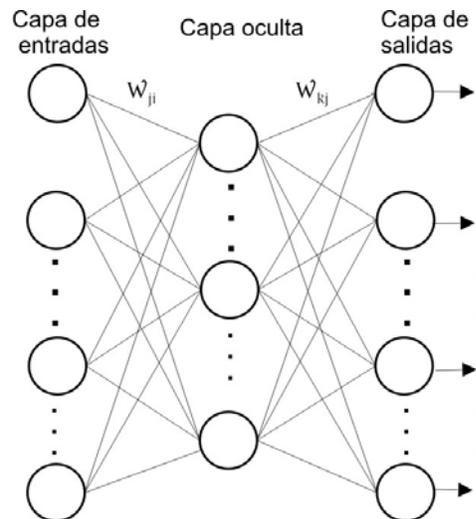


Figura 15. Red neuronal de retropropagación.

Uno de los modelos más populares de entrenamiento para redes de múltiples capas (ver figura 15) se basa en un gradiente de error descendente -el algoritmo retropropagación (backpropagation) [Duda et al., 2001] o regla delta generalizada, que es una extensión natural del algoritmo de error cuadrático medio (LMS por sus siglas en inglés Least Mean Square).

El enfoque básico para entrenamiento de una red con el algoritmo retropropagación, es iniciar con una red no entrenada, presentar un patrón de entrenamiento para la capa de entrada, pasar la señal a través de la red y determinar la salida de la capa de salida. Las salidas se comparan con los valores meta; cualquier diferencia corresponde a un error. Este error o función criterio es una función escalar de pesos y es minimizada cuando las salidas de la red coinciden con las salidas deseadas. Así, los pesos son ajustados para reducir el error.

La base de la retropropagación es como sigue [Kennedy, et al., 1998]:

1. La retropropagación busca minimizar el costo de la función del error cuadrático en un conjunto de entrenamiento

$$E = \sum_{i=1}^{N_{\text{train}}} \left\{ \frac{1}{2} \sum_{j=1}^J (d_{ij} - y_{ij})^2 \right\},$$

donde la i numera cada patrón en el conjunto de entrenamiento, y j numera cada variable de salida (N_{train} patrones en el conjunto de entrenamiento; cada patrón tiene J salidas); d_{ij} es el valor deseado de salida, y y_{ij} es el valor de salida actual del modelo.

2. El algoritmo ajusta pesos a través del método del descenso del gradiente. Las dos versiones estándar del algoritmo de retropropagación utilizan el método del descenso del gradiente empleando el procedimiento denominado de paso fijo o una variante incremental. Cada paso de la primera versión, con frecuencia llamado la versión por lotes (batch), es en dirección contraria al gradiente de error cuadrático medio (MSE por sus siglas en inglés Mean Squared Error). La versión incremental realiza pasos que minimizan el error cuadrático en un ejemplo simple de un patrón, y los ciclos de todos los ejemplos de patrones. Cada ciclo del conjunto de entrenamiento es llamado época.

III.5. Resumen

En este capítulo se presentó un bosquejo general de lo que son los modelos ocultos de Markov. Al inicio se presentó la definición y se describieron los algoritmos que utilizan los modelos. Posteriormente se mostró un ejemplo de aplicación de los modelos ocultos de Markov, finalmente se dió una descripción de las redes neuronales de retropropagación.

El siguiente capítulo describe como se aborda el problema de la estimación de actividad de trabajadores hospitalarios utilizando modelos ocultos de Markov. Se también describe el procesamiento de los datos de entrada y las propuestas del modelo.

Capítulo IV

Estimación de Actividad con Modelos Ocultos de Markov

En el presente capítulo se describe la obtención de los datos, el procesamiento y la reducción del vector de entrada mediante un estudio de sensibilidad a bajo nivel, que permite determinar la relevancia de las variables contextuales como tiempo, ubicación, artefactos y agentes en la estimación de la actividad. Por último, se presenta el diseño del modelo en capas utilizando modelos ocultos de Markov (MOMs).

IV.1. Introducción

Los modelos ocultos de Markov toman en cuenta información del pasado para determinar la probabilidad de cambiar de un estado a otro. En el diseño del modelo oculto de Markov que se propone, los estados ocultos corresponden a las actividades que se desea estimar y las variables contextuales representan los estados observables. Las estimaciones de actividad de los MOMs se realizaron con el toolbox de Matlab HMM; los algoritmos utilizados son Baum-Welch para la fase de entrenamiento y Viterbi para la fase de pruebas. La metodología utilizada, misma que se detalla en el presente capítulo, se ilustra en la figura 16.

Es importante resaltar que la información para la estimación de actividad de trabajadores hospitalarios utilizando modelos ocultos de Markov fue recabada de un estudio de sombra en un hospital. 196 horas y 46 minutos de datos recopilados [Morán, et al., 2006] fueron codificados en entradas y salidas, tomando en cuenta las variables contextuales hora del día, ubicación, personas con las que interactúa y artefactos que se utilizan mientras se realizan las actividades.

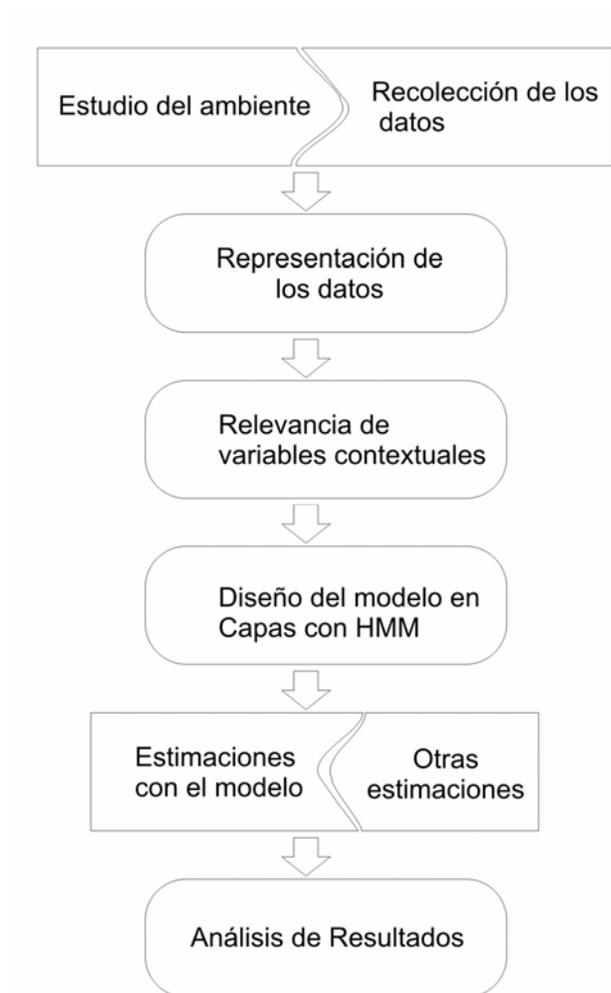


Figura 16. Metodología para el desarrollo del MOM en capas.

IV.2. Organización y Recolección de Datos

Los datos necesarios para estimar la actividad fueron recabados de un estudio de sombra realizado en el Hospital General del IMSS de Ensenada, BC [Moran, et al., 2006]. La información fue recopilada por un grupo de observadores mediante un reporte escrito capturado mientras los trabajadores hospitalarios realizaban sus actividades. El estudio fue conducido durante nueve meses en dos turnos de trabajo. En el estudio participaron cinco enfermeras, cinco médicos internos y cinco médicos de base, que fueron observados durante dos jornadas completas de trabajo.

Se utilizó un formato para capturar la información para mantener uniformidad en los datos. Dicha información se refiere a la naturaleza de las acciones, artefactos utilizados, contenido de las conversaciones, interacción con las personas relacionadas con la acción realizada y ubicación de los individuos. Los registros fueron capturados con la mayor precisión posible, un nuevo registro se capturaba si ocurrían nuevos eventos que alteraran o cambiaran una o más de las variables contextuales. Por ejemplo, si una persona llegaba a la escena mientras un médico base discutía un caso clínico con un colega. Dado que todos los registros fueron capturados manualmente “in-situ”, fueron posteriormente transcritos e integrados en reportes de observación. La figura 17 muestra un segmento de un reporte de observación.

Hora	Ubicación	Que estaban haciendo	Artefactos	Participantes	Actividad Primaria
08:57:30	Pasillo	Reporta el diagnóstico del paciente en la hoja de enfermería	Hoja de Enfermería (HE) + Accesorios de oficina (AO)		MD
07:36:01	Camas	Se dirige al cuarto 240. Toma la temperatura y el ritmo cardiaco del paciente	Material Médico (MM)	Paciente(P)	CP
12:21:00	Camas	Discute el diagnóstico del paciente con los médicos intenos	Expediente Médico (EM)	Médico base(MB) + Interno(MI)	VYD

Figura 17. Reporte de observación del rol enfermera operativa.

Una vez vaciada la información en reportes utilizando Excel, la información fue analizada por los investigadores y algunos trabajadores hospitalarios. Como resultado del análisis un

grupo de investigadores se dieron a la tarea de desarrollar un esquema de código que describiera las actividades realizadas por los trabajadores hospitalarios y sus principales características. Una vez finalizado el esquema de codificación, algunos investigadores codificaron los reportes de observación asignando a cada captura el código que representara la actividad que se estaba realizando en ese momento. Por ejemplo, en la figura 17 se puede observar que la primera columna contiene la hora; otra contiene la descripción de una actividad en la que una enfermera reporta el diagnóstico de un paciente en la hoja de enfermería. Posteriormente aparece una columna que contiene los artefactos que se utilizan, en este ejemplo hoja de enfermería y accesorios de oficina. Una siguiente columna indica a personas que intervienen en la actividad, en este caso no hay intervenciones; una columna más da la ubicación y finalmente, una columna que indica la actividad primaria realizada. Esta actividad corresponde a la actividad Cuidados al Paciente etiquetada, con el código CP.

La codificación para el resto de las actividades es: valoración y diagnóstico (VYD), manejo de documentos (MD), coordinación o sincronización (SN), y clases y capacitación (CC). Aunque la naturaleza de las actividades es diferente, cabe resaltar que la información contextual para representarla es similar en la mayoría de los casos. Por ejemplo, si un médico se encuentra frente a la cama de un paciente con médicos internos y una enfermera, el médico base puede estar discutiendo un caso clínico, coordinando actividades, preparando medicinas o realizando cuidados al paciente.

La distribución de las muestra para realizar las pruebas de estimación de actividad se realizó de la siguiente manera (ver figura 18). Las muestras se agruparon por actividad divididas en dos conjuntos, uno para entrenamiento y otro para pruebas. Debido a que algunas actividades contaban con una mayor cantidad de muestras se decidió balancear los conjuntos de datos, tanto de entrenamiento como de prueba. Por ejemplo, para un médico base, de 1258 muestras de la actividad valoración y diagnóstico se tomaron sólo 230 datos. De ahí se dividió nuevamente la cantidad de muestras en 150 datos para entrenamiento y 80 para la fase de pruebas. De manera similar se balanceó la cantidad de muestras para el resto de las actividades.



Figura 18. Distribución de las muestras de los reportes de observación.

IV.3. Representación de los Datos

La codificación descrita en la sección anterior fue aplicada posteriormente a los vectores de entrada, los cuales alimentaron la red neuronal para las pruebas de estimación de actividad [Favela, et al., 2006]. La representación del vector de entrada se muestra en la figura 19. El vector de entrada, en sus dos primeros elementos contiene la hora que describe el tiempo en que se realizaba la actividad. Posteriormente contiene la ubicación con valores de 0-8, que indican la localización en donde se lleva a cabo la actividad; posteriormente contiene los agentes. Dicho segmento contiene la información con valores que representan la interacción (1) o la no interacción (0) entre los agentes al desempeñar la actividad. El siguiente segmento representa la interacción con una serie de artefactos, en donde 1 representa que se está utilizando y 0 que no se está utilizando. Finalmente, contiene la actividad que se estaba llevando a cabo, para poder hacer la comparación de los resultados obtenidos en la estimación con los valores reales.

vector de entrada un valor discreto. Como se puede observar en la figura 20, el valor obtenido no es un número discreto, además de que hay una serie de combinaciones que no se utilizan, por ejemplo, el que en una actividad se encuentren todos los agentes y/o un agente utilice todos los artefactos mientras realiza una actividad.

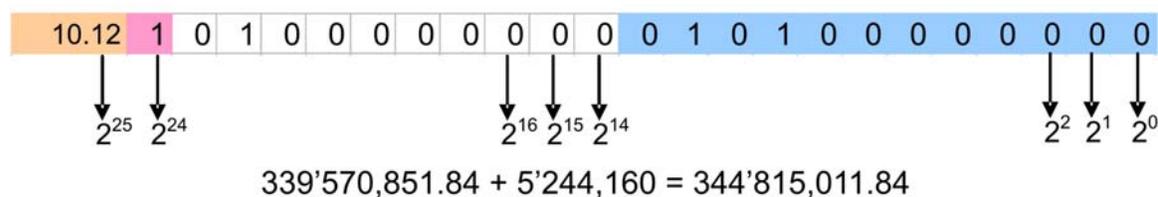


Figura 20. Transformación simple del vector de entrada.

Suponiendo que la codificación se aceptara, el valor mínimo del vector sería 4097, que representaría la interacción del rol con sólo una persona y el uso de un solo artefacto; difícilmente el siguiente valor sería 4098, dado que el valor más significativo del vector es la hora. Además, cabe resaltar que el valor máximo posible sería 927'868,024.88, el cual representa utilizar todos los artefactos y el tener a todos los agentes interactuando en un mismo lugar, con un registro de la hora de 23:59, y este hecho es muy complicado por no decir imposible de observar. Así, con la transformación propuesta se podría tener un aproximado de 2'097,149 entradas; eso sin tomar en cuenta la variable hora que es un valor que puede variar desde 00:01 hasta 23:59 y corresponde al valor más significativo del vector. Teniendo presente que se manejará un modelo oculto de Markov discreto, aquí el primer paso es solucionar la aparición de valores no discretos.

La figura 21 muestra un posible procesamiento de las entradas para transformarlas en valores discretos, solucionando al menos la aparición de valores no discretos al transformar la variable de hora del vector.

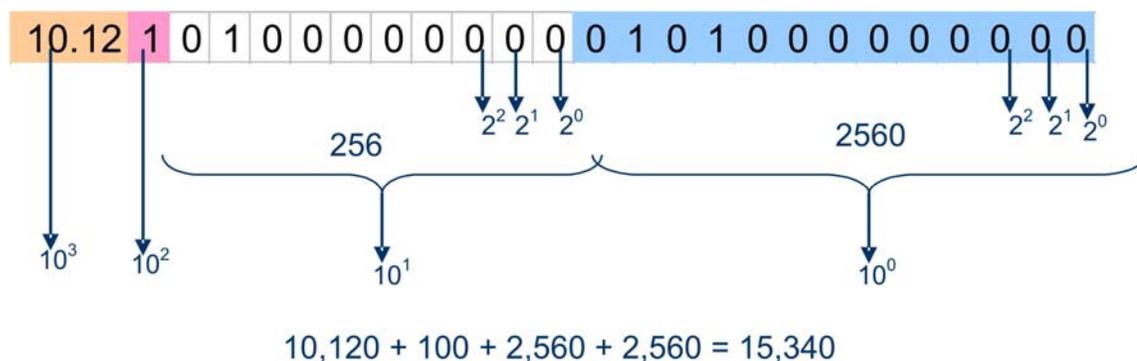


Figura 21. Transformación del vector de entrada a valores discretos.

Los valores discretos obtenidos aunque han reducido la distancia de los valores, aún no son viables para el procesamiento, puesto que las distancias de los valores obtenidos para una misma actividad son muy lejanas. Los modelos ocultos de Markov utilizan como referencia una matriz de observación, y dado que las distancias entre los valores de observación transformados como lo muestra la figura 21 son lejanas, habrá muchos valores con distribución de probabilidad 0, mismos que no son permitidos para el procesamiento de la matriz. Además, existe la posibilidad de que dos o más representaciones para diferentes actividades puedan corresponder a un mismo valor.

Otra propuesta de codificación consistió en reagrupar las variables y asignarles nuevos valores. Por ejemplo, si el segmento correspondiente a agentes mostrara sólo una interacción, en lugar de tener un segmento muy largo sólo se tendría el valor 0, que representaría una interacción simple. En cuanto a los artefactos, éstos se agruparon de tal forma que las variables pudieran generalizarse; en lugar de describir artefactos como plumas y medios de comunicación, un valor generalizado sería 1, que comprende artículos de oficina y comunicación. La tabla V muestra que las interacciones se redujeron a tres valores y el segmento que contiene la información de los artefactos a cuatro valores.

Tabla V. Codificación agrupada propuesta para los segmentos agentes y artefactos.

Interacciones	
0	Simple
1	Múltiple
2	Ninguna
Artefactos	
0	Médicos y diagnóstico
1	Oficina y comunicación
2	Ambos
3	Ninguno

La figura 22 muestra la transformación del vector de entrada aplicando la codificación de agrupación de variables. En este caso la variable correspondiente a la hora se transformó del registro de la hora usual a sistema de hora militar.

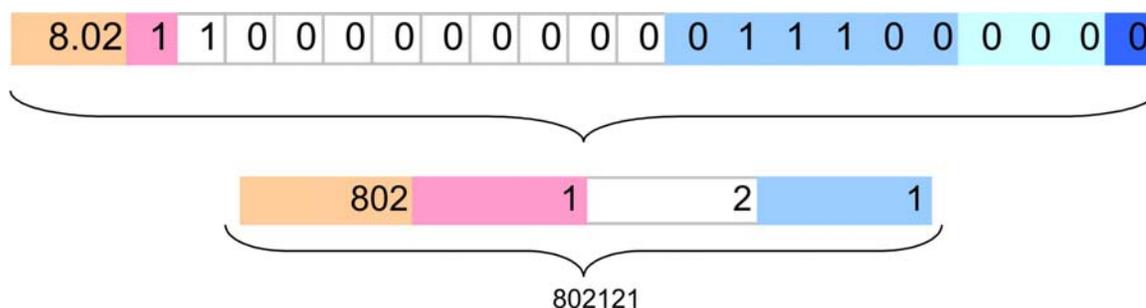


Figura 22. Transformación del vector de entrada con codificación agrupada.

El mapeo de los datos de entrada reduce significativamente la dimensión del vector, aunque tiene como principal desventaja que es una agrupación a muy alto nivel y se pierde la especificación de la información, por lo cual se descartó la codificación agrupada y se procedió a explorar otras codificaciones factibles para el vector de entrada.

Otra propuesta para la representación del vector de entrada consistió en numerar las posibles combinaciones de las interacciones entre agentes, tomando como referencia las interacciones más comunes. De manera similar, se realizó la numeración de las

combinaciones más comunes en el uso de artefactos. La tabla VI muestra en la primera columna el listado de las interacciones entre agentes más observadas; la segunda columna muestra el valor asignado para ser utilizado como entrada del MOM, y la última columna representa el segmento del vector de entrada utilizado en redes neuronales.

Tabla VI. Codificación para las interacciones más comunes entre agentes.

Interacciones entre Agentes	MOM	RN									
MEDINT	1	0	1	0	0	0	0	0	0	0	0
MEDBASE+MEDESP	2	0	0	0	1	0	0	1	0	0	0
PAC+FAM	3	0	0	1	0	0	1	0	0	0	0
ENFOP+JEFAPISO	4	0	0	0	0	1	0	0	1	0	0
NOBODY	5	1	0	0	0	0	0	0	0	0	0
ADMIVO+TECNICO	6	0	0	0	0	0	0	0	0	1	1
MEDINT+MEDBASE+MEDESP+PAC+FAM	7	0	1	1	1	0	1	1	0	0	0
MEDINT+MEDBASE+MEDESP+ENFOP+JEFAPISO	8	0	1	0	1	1	0	1	1	0	0
MEDINT+MEDBASE+MEDESP+ADMIVO+TECNICO	9	0	1	0	1	0	0	1	0	1	1
MEDINT+MEDBASE+MEDESP	10	0	1	0	1	0	0	1	0	0	0
MEDINT+PAC+FAM	11	0	1	1	0	0	1	0	0	0	0
MEDINT+ENFOP+JEFAPISO+AMIVO+TECNICO	12	0	1	0	0	1	0	0	1	1	1
MEDINT+ENFOP+JEFAPISO	13	0	1	0	0	1	0	0	1	0	0
MEDINT+ADMIVO+TECNICO	14	0	1	0	0	0	0	0	0	1	1
MEDBASE+MEDESP+PAC+FAM+ENFOP+JEFAPISO	15	0	0	1	1	1	1	1	1	0	0
MEDBASE+MEDESP+PAC+FAM	16	0	0	1	1	0	1	1	0	0	0
MEDBASE+MEDESP+ENFOP+JEFAPISO	17	0	0	0	1	1	0	1	1	0	0
PAC+FAM+ENFOP+JEFAPISO	18	0	0	1	0	1	1	0	1	0	0
PAC+FAM+ADMIVO+TECNICO	19	0	0	1	0	0	1	0	0	1	1

De manera similar, la tabla VII muestra la asignación de valores de acuerdo a las agrupaciones que se observaron más frecuentemente en el uso de artefactos para realizar las actividades. La primera columna representa las observaciones más comunes; la segunda columna el valor discreto correspondiente para MOM, y la última columna la misma representación para redes neuronales.

Tabla VII. Codificación para las interacciones más comunes con artefactos.

Artefactos	MOM	RN									
NON	1	0	0	0	0	0	0	0	0	1	
MM+EQ	2	0	0	0	0	0	0	1	0	1	0
EM+HE	3	1	0	1	0	0	0	0	0	0	0
AO	4	0	1	0	0	0	0	0	0	0	0
CA	5	0	0	0	0	0	0	0	1	0	0
FA	6	0	0	0	1	0	0	0	0	0	0
MR	7	0	0	0	0	0	1	0	0	0	0
MM+EQ+EM+HE+AO+CA	8	1	1	0	0	0	0	1	1	1	0
MM+EQ+EM+HE+AO	9	1	1	0	0	0	0	1	0	1	0
MM+EQ+EM+HE+CA	10	1	0	0	0	0	0	0	1	1	0
MM+EQ+EM+HE	11	1	0	1	0	0	0	1	0	1	0
MM+EQ+AO+FA+MR	12	0	1	0	1	0	1	1	0	1	0
MM+EQ+AO	13	0	1	0	0	0	0	1	0	1	0
MM+EQ+CA	14	0	0	0	0	0	0	1	1	1	0
MM+EQ+FA	15	0	0	0	1	0	0	1	0	1	0
EM+HE+AO+CA	16	1	1	1	0	0	0	0	1	0	0
EM+HE+AO+FA	17	1	1	1	1	0	0	0	0	0	0
EM+HE+AO	18	1	1	1	0	0	0	0	0	0	0
EM+HE+AO+CA+FA	19	1	1	1	1	0	0	0	1	0	0
EM+HE+CA	20	1	0	1	0	0	0	0	1	0	0
EM+HE+FA	21	1	0	1	1	0	0	0	0	0	0
AO+CA+FA	22	0	1	0	1	0	0	0	1	0	0
AO+CA	23	0	1	0	0	0	0	0	1	0	0
AO+FA	24	0	1	0	1	0	0	0	0	0	0
AO+MR	25	0	1	0	0	0	1	0	0	0	0

La representación del vector de entrada, a pesar de proveer una representación numéricamente más reducida, deja fuera muchas combinaciones. La agrupación de variables permitió observar que es necesario hacer una valoración de las variables del vector de entrada para tomar en cuenta sólo las variables que realmente aporten información sobre la actividad que se está realizando.

Por ejemplo, para predecir si un médico base está realizando formalización de notas o bien manejo de información, un artefacto relevante es la máquina de escribir. Por su parte, las enfermeras no tienen acceso a tales artefactos, por lo que incluir dicha variable para estimar la actividad de las enfermeras no mejorará los resultados. Tomando como base el anterior planteamiento, se procedió a realizar un estudio de sensibilidad a más bajo nivel para

determinar qué artefactos y qué personas son relevantes para la representación del vector de entrada para estimar la actividad.

El proceso consistió en obtener los promedios de aparición de cada uno de los artefactos por actividad, y por rol; sólo aquellos artefactos con aparición mayor al 50% fueron considerados para la representación final del vector. La tabla VIII muestra los artefactos que resultaron con mayor promedio de aparición; las últimas tres columnas representan a cada uno de los roles.

Tabla VIII. Sensibilidad de variables en el segmento artefactos.

Artefactos		EO	MB	MI
EM	Expediente médico		✓	✓
AO	Accesorios de oficina	✓		
MM	Material de curación			✓
HE	Hoja de enfermería	✓		
EC	Equipo de cómputo			
CE	Censo		✓	
BP	Bloc personal			
FA	Formatos administrativos	✓		✓
EQ	Equipo de medición	✓	✓	✓
CA	Carrito de medicinas o expedientes	✓	✓	
RE	Resultados de laboratorio		✓	✓
MC	Medios de comunicación	✓	✓	
MR	Material referencia		✓	✓
ED	Equipo de despliegue			
Ninguno	Ninguno			✓

De manera similar se procedió con el segmento interacción entre personas. Las variables relevantes resultantes por rol se muestran en la tabla IX, en donde cada renglón representa cada uno de los roles.

Tabla IX. Sensibilidad de variables en el segmento agentes.

	Nadie	MedInt	Pac	MedBase	EnfOp	Fam	MedEsp	JefaPiso	Admvo	Técnico	Otro
EO			✓					✓			✓
MB		✓	✓		✓				✓	✓	✓
MI	✓		✓	✓	✓				✓		

La reducción del vector es notoria, como lo muestra la figura 23, y cabe señalar que sigue aportando la información necesaria, ya que se realizaron estimaciones con redes neuronales probando el vector de entrada reducido. Los resultados de las estimaciones se muestran en la sección 5.2.

Hora	Ubicación	Agentes	Artefactos					Actividad								
7.386	1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0

Figura 23. Vector de entrada reducido, basado en la relevancia de las variables.

Los porcentajes de reducción de los vectores de entrada para los diferentes roles se muestran en la tabla X. La primera columna corresponde a cada uno de los roles; la segunda columna muestra el tamaño original del vector de entrada utilizado con redes neuronales; la tercera columna muestra el tamaño del vector una vez seleccionados los componentes relevantes, y la última columna indica el porcentaje de reducción del vector de entrada por rol. Finalmente, el promedio de reducción del vector de entrada es del 38%.

Tabla X. Porcentajes de reducción del vector de entrada.

Rol	Tamaño original	Tamaño reducido	Reducción
EO	29	17	41.62 %
MB	30	21	42.42 %
MI	33	19	30 %

IV.3.1. Distribución Inicial de Estados

El vector de prioridad o distribución inicial de estados representa la prioridad de realizar una actividad sobre el resto de las actividades. Este vector puede ser visto como el porcentaje de tiempo que el personal del hospital utiliza para realizar las diferentes actividades. Para calcular este vector se tomó en cuenta el tiempo total (por día) que los trabajadores hospitalarios requerían para realizar las actividades a estimar. La tabla XI muestra los vectores de prioridad para los diferentes roles, en la cual se observa que la actividad principal que desempeñan las enfermeras es la actividad preparación de material. Para los médicos de base la actividad primaria es valoración y diagnóstico, y para los médicos internos la actividad principal es manejo de información.

Tabla XI. Porcentajes de tiempos promedio en la realización de actividades por día.

Actividades (Tiempo por día)	EnfOp (% tiempo promedio)	MedInt (% tiempo promedio)	MedBase (% tiempo promedio)	TOTAL (% tiempo promedio)
Valoración y Diagnóstico (VYD)	19.97	29.16	29.08	26.07
Cuidado del Paciente(CP)	22.56	11.26	20.23	18.02
Coordinación(SN)	23.23	25.01	23.14	23.79
Preparación de Material(P)	24.26	0.00	0.00	8.09
Manejo de Información (MD)	8.38	29.45	27.55	21.80
Clases y Capacitación (CC)	1.60	5.12	0.00	2.24

IV.3.2. Matrices de Transición de Estados

Posterior al vector de prioridad se obtuvieron las matrices de transición de estados para cada uno de los roles. La matriz de transición refleja las probabilidades de transición de estados, que indican la probabilidad de estar haciendo una actividad o estar en el estado q_i

y cambiarse al estado q_j . La figura 24 muestra el diagrama de transición de estados para el rol médico base.

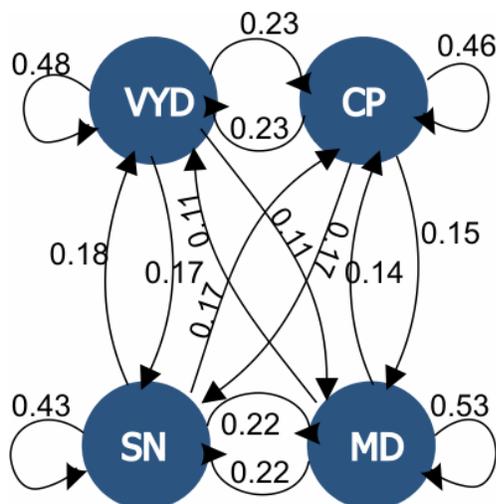


Figura 24. Diagrama de transición de estados para el rol médico base.

Las transiciones se almacenan en una matriz de transiciones de estados para posteriormente alimentar el modelo oculto de Markov, en donde los estados son las etiquetas de las filas, y las direcciones de las flechas indican los valores correspondientes a las columnas. La correspondiente matriz de transición de estados para el rol médico base se muestra en la tabla XII, en donde las filas representan la actividad actual y las columnas indican la actividad siguiente. Se lee como “dado que se encuentra realizando la actividad valoración y diagnóstico, la probabilidad de que cambie a la actividad sincronización es 0.1739”.

Tabla XII. Matriz de transición de actividad para el rol médico base.

MEDBASE	VYD	CP+CE	SN	MD
VYD	0.4826	0.2304	0.1739	0.1130
CP+CE	0.2304	0.4609	0.1609	0.1478
SN	0.1839	0.1659	0.4305	0.2197
MD	0.1101	0.1366	0.2247	0.5286

La tabla XIII muestra la matriz de transición de estados correspondiente al rol médico interno, en donde se puede observar que la actividad más recurrente, o en la que no se dan tantos cambios mientras se ejecuta, es la actividad clases y capacitación.

Tabla XIII. Matriz de transición de actividad para el rol médico interno.

MEDINT	VYD	CP+CE	SN	MD	CC
VYD	0.5263	0.1009	0.2149	0.1535	0.044
CP+CE	0.1806	0.6516	0.0968	0.0710	0.00
SN	0.1770	0.0929	0.5619	0.1638	0.044
MD	0.1762	0.044	0.1454	0.6300	0.044
CC	0.0345	0.00	0.00	0.0345	0.9310

Finalmente, para el rol de enfermera operativa, la matriz de transición de estados se muestra en la tabla XIV. De manera similar a la de médicos internos, la actividad en la que no hay tantos cambios entre actividades es la actividad clases y capacitación.

Tabla XIV. Matriz de transición de actividad para el rol enfermera operativa.

ENFOP	VYD	CP+CE	SN	P	MD	CC
VYD	0.3684	0.1535	0.1798	0.193	0.1009	0.0044
CP+CE	0.1974	0.3947	0.1623	0.1579	0.0877	0.00
SN	0.2143	0.1339	0.4018	0.1786	0.0714	0.00
P	0.113	0.2565	0.1652	0.387	0.0783	0.00
MD	0.2167	0.125	0.15	0.1583	0.35	0.00
CC	0.0400	0.00	0.00	0.00	0.00	0.9600

IV.4. Relevancia de Variables Contextuales para el Reconocimiento de la Actividad

La información contextual representada por ubicación del personal, artefactos que están siendo utilizados, personas con quienes colaboran y la hora del día, fue utilizada para entrenar la red neuronal. Utilizando el modelo de redes neuronales propuesto en Favela, et al., [2007] se realizaron algunas pruebas omitiendo la variable hora del día; dicha prueba

permitió identificar la relevancia de las variables en la estimación de la actividad. El detalle y los resultados de las pruebas se describirán en la sección 5.1.

Teniendo en cuenta la consideración anterior, se procedió a examinar la información por segmentos del vector de entrada, para estimar la actividad utilizando modelos ocultos de Markov.

Dado que se seleccionaron los modelos ocultos de Markov discretos para la estimación de actividad, la variable hora del día no se consideró en las estimaciones; dicha decisión fue respaldada con los resultados de las estimaciones de actividad con redes neuronales (aumento en la precisión de la estimación del 4%). Una razón para este comportamiento es que el trabajo hospitalario es altamente dinámico y muchas de las actividades no se realizan en un horario estricto.

Las estimaciones para inferir la actividad se realizaron diseñando un modelo oculto de Markov simple para cada una de las variables a estimar (ubicación, artefactos y personas). El modelo utilizado se muestra en la figura 25.

En el ejemplo del modelo oculto de Markov para el rol médico base mostrado en la figura 25, los estados ocultos corresponden a las actividades que se desean estimar: valoración y diagnóstico (vyd), cuidados al paciente (cp), coordinación (c) y manejo de documentos. Las flechas entre los estados indican las transiciones entre estados, cuyos valores se presentaron en la tabla XII.

Para los estados observables, en el caso de ubicación, las posibles salidas son: sala de atención (1), consultorio (2), central de enfermeras (3), almacén (4), pasillo (5), sala personal (6), sala de servicios (7), sala especializada (8) y fuera del hospital (9).

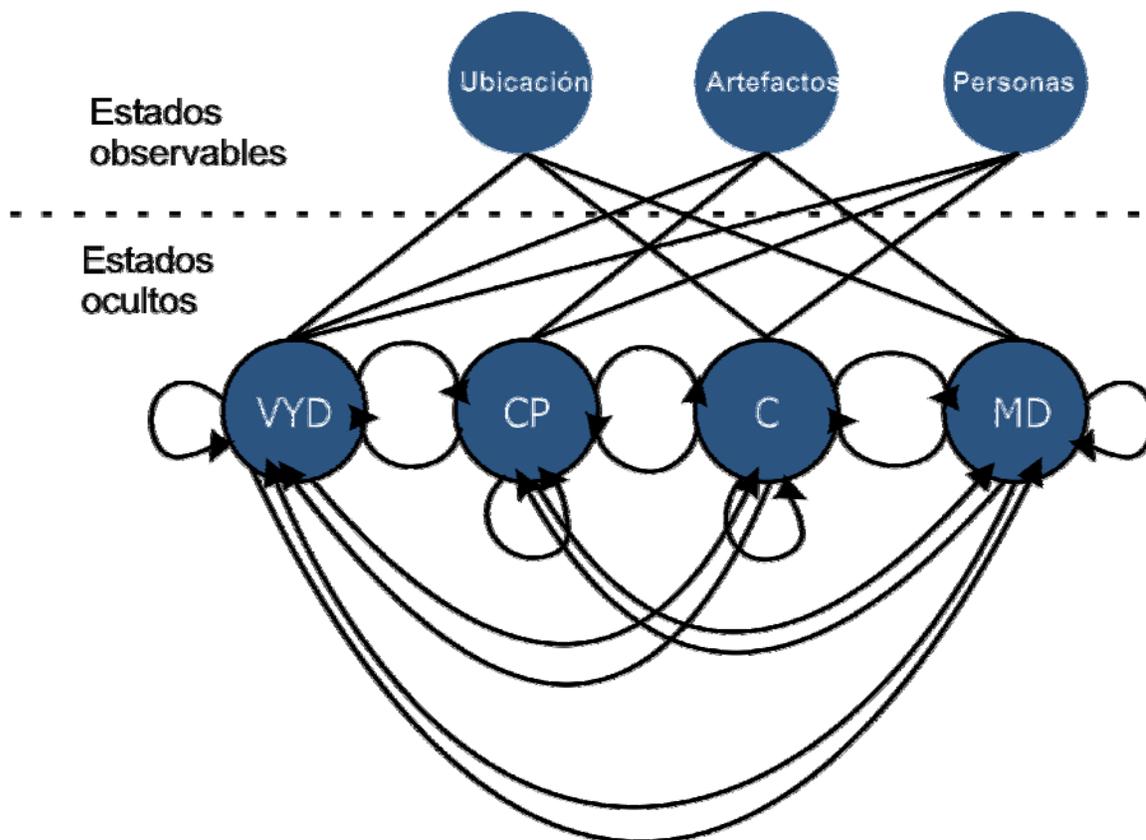


Figura 25. Modelo oculto de Markov para estimación de actividad.

IV.4.1. Estimaciones usando sólo Información de Ubicación

Los resultados de las estimaciones del modelo simple se presentan en forma de matrices de confusión, en donde cada fila representa la actividad que se estaba realizando, y las columnas sobre la misma fila representan las estimaciones del modelo, de tal forma que la diagonal principal representa los aciertos del modelo en la estimación de la actividad.

La matriz de confusión correspondiente al rol enfermera operativa se muestra en la tabla XV. Los resultados obtenidos permiten visualizar que las estimaciones llegan a un 100% de acierto para la actividad clases y capacitación. La razón por la que se puede estimar de

manera tan exacta dicha actividad se debe a que siempre se realiza en el almacén y el resto de las actividades no se presentaron jamás en esa ubicación. El error promedio en la estimación de actividad del modelo es de 38.7%.

Tabla XV. Matriz de confusión de la estimación de actividad para el rol enfermera operativa, utilizando sólo información de ubicación.

EO	VYD	CP+CE	SN	PM	MD	CC
VYD	90	10	0	0	0	0
CP+CE	1.25	98.75	0	0	0	0
SN	80	6.67	10	1.66	1.67	0
PM	28.75	0	1.25	66.25	3.75	0
MD	97.14	0	0	0	2.86	0
CC	0	0	0	0	0	100

Para el rol de médico interno se muestra la matriz de confusión en la tabla XVI, con un error promedio del 27.67% en las estimaciones. Aunque en algunos casos son buenas, no puede considerarse una buena referencia para estimar la actividad un MOM con sólo información de la ubicación.

Tabla XVI. Matriz de confusión de la estimación de actividad para el rol médico interno, utilizando sólo información de ubicación.

MI	VYD	CP+CE	SN	MD	CC
VYD	92.5	2.5	2.5	2.5	0
CP+CE	38.33	61.67	0	0	0
SN	3.75	0	20	76.25	0
MD	0	0	2.5	97.5	0
CC	0	0	0	10	90

Las estimaciones para el rol de médico base se muestran en la tabla XVII. La estimación en los resultados para la actividad cuidados al paciente (CP+CE) se puede justificar con el argumento de que en la misma ubicación (SA-sala de atención) se lleva a cabo también, con frecuencia, la actividad valoración y diagnóstico.

Tabla XVII. Matriz de confusión de la estimación de actividad para el rol médico base, utilizando sólo información de ubicación.

MB	VYD	CP+CE	SN	MD
VYD	91.67	8.33	0	0
CP+CE	95	3.33	0	1.67
SN	0	0	30	70
MD	0	0	23.33	76.67

Para estimar la actividad de una persona, la variable contextual ubicación no provee suficiente información para estimar la actividad de un trabajador hospitalario. En términos generales, para las personas en un ambiente médico el hecho de sólo conocer la ubicación de una enfermera operativa no provee suficiente información para inferir que actividad está realizando.

IV.4.2. Estimaciones usando sólo Información de Personas (agentes)

Las estimaciones de actividad considerando sólo la interacción con agentes, para el rol de enfermera operativa, se muestran en la tabla XVIII, con un 100% de precisión en la estimación de la actividad clases y capacitación, debido a que existe un agente decisivo para dicha actividad, que es la variable otro (agente externo al hospital). En cambio, para la actividad preparación de medicamentos, la estimación es muy baja, y es comprensible, pues no hay interacción con otros agentes y el modelo fácilmente puede confundirse con la actividad manejo de documentos.

Tabla XVIII. Matriz de confusión de la estimación de actividad para el rol enfermera operativa, utilizando sólo información de agentes.

EO	VYD	CP+CE	SN	PM	MD	CC
VYD	88.75	0	1.25	1.25	8.75	0
CP+CE	16.25	83.75	0	0	0	0
SN	0	1.67	98.33	0	0	0
PM	0	0	1.25	7.5	91.25	0
MD	2.86	0	0	2.86	94.28	0
CC	0	0	0	0	0	100

Para el rol de médico interno, la matriz de confusión con las estimaciones de actividad se muestra en la tabla XIX; el error de 3.25% en las estimaciones es bastante aceptable. Entonces puede recomendarse como un modelo final para estimación de actividad para el rol de médico interno, y proponerse para la identificación de agentes diferentes tecnologías como RFIDs o identificación por video.

Tabla XIX. Matriz de confusión de la estimación de actividad para el rol médico interno, utilizando sólo información de agentes.

MI	VYD	CP+CE	SN	MD	CC
VYD	93.75	6.25	0	0	0
CP+CE	0	100	0	0	0
SN	0	0	100	0	0
MD	0	0	0	100	0
CC	0	0	0	10	90

La matriz de confusión para el rol de médico base se muestra en la tabla XX. En este caso el error en la estimación de actividad es de 15.4%. Se puede observar que la actividad mejor estimada es cuidados al paciente con 96.67%, seguida de valoración y diagnóstico con 95%.

Tabla XX. Matriz de confusión de la estimación de actividad para el rol médico base, utilizando sólo información de agentes.

MB	VYD	CP+CE	SN	MD
VYD	95	5	0	0
CP+CE	0	96.67	0	3.33
SN	0	0	58.33	41.67
MD	0	3.33	8.33	88.34

IV.4.3. Estimaciones usando sólo Información de Artefactos

La parte del vector de entrada correspondiente a artefactos provee en algunos casos suficiente información para estimar la actividad de los trabajadores hospitalarios. Las estimaciones correspondientes al rol de enfermera operativa se muestran en la tabla XXI.

Tabla XXI. Matriz de confusión de la estimación de actividad para el rol enfermera operativa, utilizando sólo información de artefactos.

EO	VYD	CP+CE	SN	PM	MD	CC
VYD	81.25	0	10	0	8.75	0
CP+CE	0	98.75	1.25	0	0	0
SN	0	8.33	83.33	0	8.34	0
PM	0	0	2.5	97.5	0	0
MD	11.43	2.86	5.71	0	80	0
CC	0	100	0	0	0	0

La tabla XXII muestra las estimaciones de actividades para el rol médico base, utilizando sólo información de los artefactos que utiliza mientras realiza la actividad. Las actividades mejor estimadas son valoración y diagnóstico, y cuidados al paciente con 96.67%.

Tabla XXII. Matriz de confusión de la estimación de actividad para el rol médico base, utilizando sólo información de agentes.

MB	VYD	CP+CE	SN	MD
VYD	96.67	0	3.33	0
CP+CE	0	96.67	3.33	0
SN	3.33	46.67	41.67	8.33
MD	30	6.67	5	58.33

Para el rol médico interno, las estimaciones de actividades utilizando sólo información de artefactos se muestran en la tabla XXVIII, donde se puede observar que la actividad mejor estimada es cuidados al paciente con 96.67%. El error de estimación del modelo es de 29.67%.

Tabla XXIII. Matriz de confusión de la estimación de actividad para el rol médico interno, utilizando sólo información de agentes.

MI	VYD	CP+CE	SN	MD	CC
VYD	8.75	1.25	82.5	5	2.5
CP+CE	3.33	96.67	0	0	0
SN	5	2.5	92.5	0	0
MD	3.75	0	22.5	73.75	0
CC	10	0	10	0	80

Posterior al análisis de las estimaciones de las actividades por segmentos, una propuesta para concluir con un modelo para el rol de enfermera operativa es mantener el modelo oculto de Markov que estima la actividad con sólo artefactos. Dado que las estimaciones son aceptables, excepto en la actividad clases y capacitación, se propone que en el modelo se omita dicha actividad, apoyando la propuesta con el argumento de que no es una actividad muy relevante. Los resultados serían los mostrados en la tabla XXIV.

Tabla XXIV. Matriz de confusión de la estimación de actividad para el rol enfermera operativa, utilizando sólo información de agentes, sin la actividad clases y capacitación (CC).

EO	VYD	CP+CE	SN	PM	MD
VYD	80	0	20	0	0
CP+CE	0	98.75	1.25	0	0
SN	0	16.67	80	0	3.33
PM	0	0	2.5	97.5	0
MD	0	2.86	20	0	77.14

IV.4.4. Estimaciones con el Vector de Entrada Completo

Las estimaciones correspondientes al vector de entrada completo para cada uno de los roles también se realizaron, pero surgió un inconveniente en la fase de entrenamiento, y es que la matriz de observación resultante del entrenamiento tenía varias columnas cero. Dicha matriz es necesaria para la fase de pruebas, y como se especifica en Russell y Norvig [1993], no debe haber columnas con valor cero en la matriz de observación. En la sección

III.2.1 se describen los algoritmos utilizados para estimar la actividad, con el modelo oculto de Markov propuesto, dicha información nos provee del detalle del funcionamiento de los algoritmos.

Como detallan las subsecciones IV.4.1, IV.4.2 y IV.4.3, al utilizar sólo información de ubicación con un MOM, el error promedio de la estimación es mayor a 39%, comparado con las estimaciones utilizando sólo información de los artefactos (23%), y con sólo la información de las interacciones (23%). Dichos resultados se pueden explicar ya que la mayoría de las actividades del personal del hospital son indiferentes a la ubicación de las personas que las realizan. Por ejemplo, las actividades relacionadas con el paciente (es decir, sincronización, cuidados del paciente, valoración y diagnóstico y preparación de material) se realizan normalmente frente a la cama del paciente, a pesar de la naturaleza de la actividad. Tomando como base los porcentajes de error anteriores, se confirmó que se puede prescindir de la variable ubicación para entrenar a los MOM. Además, es claro que utilizar la información contextual por separado incrementa la precisión de las estimaciones.

IV.5. Diseño del Modelo en Capas

Con base en los resultados obtenidos con modelos simples, y tomando como referencia el modelo en capas utilizando MOMs propuesto en Oliver, et al. [2004], se decidió diseñar un modelo en capas utilizando MOMs para estimar la actividad de los trabajadores hospitalarios.

Para estimar la actividad se entrenó un modelo por rol (es decir, médico base, médico interno y enfermeras), en las dos variantes descritas en las secciones IV.5.1 y IV.5.2.

IV.5.1. Modelo Simple en dos Capas con Modelos Ocultos de Markov

La figura 26 muestra el modelo en capas con MOM. El primer nivel (capa inferior) es un MOM cuyas entradas son el vector de prioridad, matriz de transición, y los artefactos que están siendo utilizados por los trabajadores hospitalarios. Las salidas del primer nivel se concatenan con la información de los agentes (que representan las interacciones con otras personas) para convertirse en las entradas que alimentan el MOM del segundo nivel, que finalmente estimará la actividad.

Es decir, el nivel inferior estima la actividad con la información de sólo artefactos (como describe la sección IV.4.3), con el vector de prioridad y la matriz de transición descritos en la sección IV.3.1 y IV.3.2. La salida del modelo se concatena con el vector correspondiente a las interacciones entre agentes, la nueva entrada se procesa en el modelo de la capa superior para finalmente estimar la actividad.

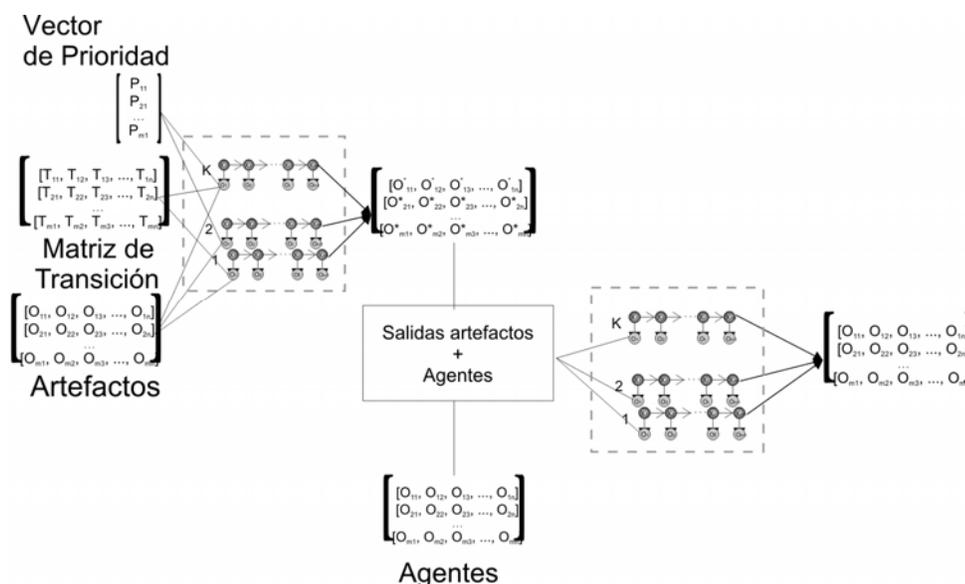


Figura 26. Modelo simple de dos capas con modelos ocultos de Markov.

IV.5.2. Modelo paralelo en dos capas con Modelos Ocultos de Markov

La figura 27 muestra un modelo paralelo en dos capas con MOM. El primer nivel esta compuesto por dos MOM que son entrenados en paralelo, cada uno con la información contextual referente a artefactos y agentes. Posteriormente, las salidas de ambos modelos se mezclan para alimentar el nivel superior que es otro MOM que finalmente determina la actividad del trabajador hospitalario.

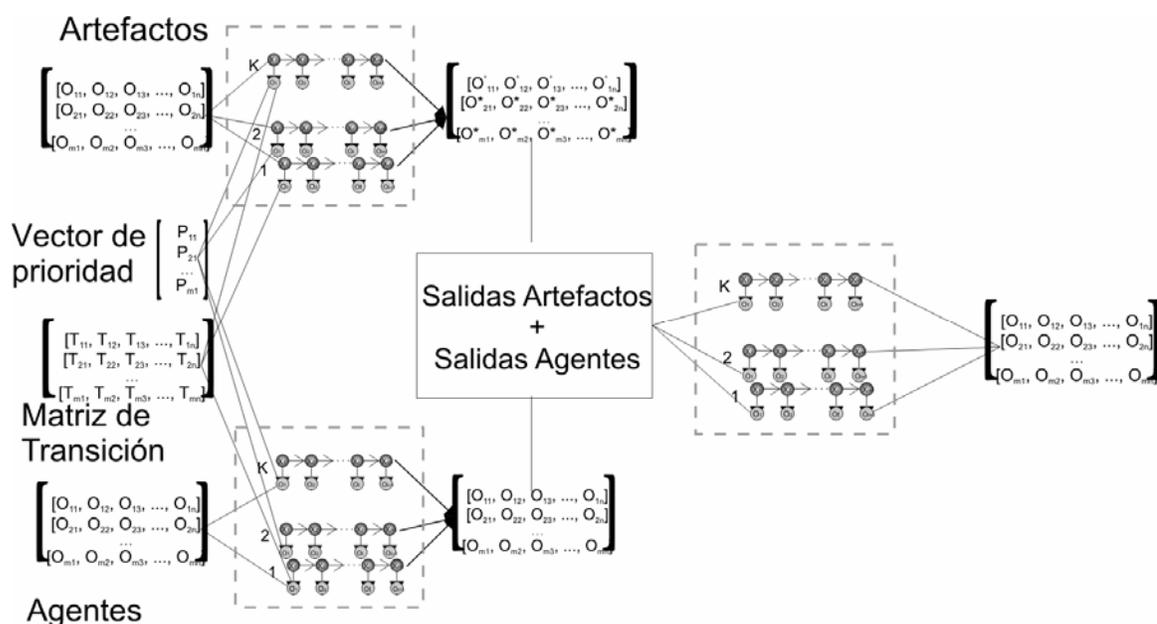


Figura 27. Modelo paralelo en dos capas con modelos ocultos de Markov.

Para este modelo, el nivel inferior estima la actividad con la información de sólo artefactos (descrito la sección IV.4.3) y sólo agentes (descrito en la sección IV.4.2), cada uno con el vector de prioridad y la matriz de transición descritos en la sección IV.3.1 y IV.3.2. Las salidas ambos modelos se concatena para formar la nueva entrada que se procesa en el modelo de la capa superior, para finalmente estimar la actividad. Los resultados obtenidos de las estimaciones de actividad de los modelos propuestos se detallan en el capítulo V.

IV.6. Resumen

Los datos recabados del estudio de sombra en el hospital fueron codificados como variables contextuales (estados observables) y actividades a estimar (estados ocultos) para un diseño basado en MOMs discretos. Se obtuvo el vector de prioridad que representa los porcentajes de tiempo que invierten los trabajadores hospitalarios en el desempeño de sus actividades, y se obtuvo la matriz de transición que contiene la información de las probabilidades de cambiar a la actividad B dado que se encuentra desempeñando la actividad A.

Mediante un estudio de sensibilidad se redujo la dimensión del vector de entrada en un 38.01%. Se determinó la relevancia de las variables contextuales (tiempo, ubicación, artefactos y agentes) en la estimación de actividad en un ambiente hospitalario.

Finalmente, se diseñaron dos modelos en capas. La diferencia entre los dos modelos es el manejo de la información contextual como entrada. Para el modelo descrito en la subsección IV.5.1, el primer nivel utiliza sólo información de los artefactos, que es procesada por un MOM, y las salidas se mezclan con la información de agentes. El modelo descrito en la subsección IV.5.2 procesa en paralelo la información de artefactos y agentes, para posteriormente alimentar el MOM superior con las salidas y estimar de mejor manera la actividad realizada.

En el siguiente capítulo se describen los resultados de las estimaciones utilizando los modelos descritos en el presente capítulo. Además, se incluyen estimaciones de actividad con redes neuronales y estimaciones realizadas por observadores expertos.

Capítulo V

Resultados y Conclusiones

En este capítulo se presentan los resultados de las estimaciones de actividad de los modelos descritos en el capítulo anterior. En las diferentes secciones se presentan estimaciones de actividad utilizando redes neuronales con las transformaciones del vector de entrada descritas en la sección IV.3. Se describen y presentan también estimaciones de actividad realizadas por un grupo de observadores expertos. Se argumenta la robustez del modelo en paralelo con el manejo de ruido en las entradas. Se comparan los resultados de la estimación de actividad con observadores expertos, con redes neuronales y con los modelos ocultos de Markov en capas propuestos en este trabajo.

V.1. Estimaciones con Redes Neuronales

En esta sección se presentan las estimaciones hechas con redes neuronales, con el objetivo de realizar una comparativa entre los resultados obtenidos con las redes neuronales y las posteriores estimaciones obtenidas con los modelos ocultos de Markov, mostrados en la siguiente sección.

Para confirmar la hipótesis de la relevancia de las variables contextuales, las primeras estimaciones se hicieron con el modelo de redes neuronales propuesto en Favela, et al [2007]. La información contextual consta de ubicación del personal, artefactos que están siendo utilizados, personas con quienes colaboran y la hora del día. En primera instancia se omitió la variable hora del día, y los resultados obtenidos para los diferentes roles se presentan a continuación.

Los resultados de la estimación para el rol enfermera operativa sin la variable hora del día se muestran en la matriz de confusión de la tabla XXV. La actividad mejor estimada es clases y capacitación (CC) con 100% de precisión, seguida de las actividades cuidados al

paciente (CP), sincronización (SN) y preparación de material y medicinas (PM) con un 73.75%. El error de estimación para este rol es de 24.93 %.

Tabla XXV. Estimaciones con redes neuronales sin la variable hora. Rol enfermera operativa, error de estimación 24.93%.

EO	VYD	CP+CE	SN	PM	MD	CC
VYD	62.5	8.75	13.75	7.50	7.50	0
CP+CE	1.25	73.75	5	20	0	0
SN	6.25	10	73.75	10	0	0
PM	3.75	3.75	18.75	73.75	0	0
MD	11.9	2.38	2.38	16.67	66.67	0
CC	0	0	0	0	0	100

La matriz de confusión de la tabla XXVI muestra las estimaciones de actividades sin la variable hora del día para el rol médico base. Para este rol las actividades mejor estimadas por el modelo son cuidados al paciente (CP) con 81.25%, seguida de sincronización o coordinación (SN) con un 67.5%, y manejo de documentos (MD) con 66.25%. El error de estimación promedio para este rol es de 35.31%.

Tabla XXVI. Estimaciones con redes neuronales sin la variable hora. Rol médico de base, error de estimación 35.31%.

MB	VYD	CP	SN	MD
VYD	43.75	22.5	17.5	16.25
CP	2.5	81.25	11.25	5
SN	11.25	6.25	67.5	15
MD	16.25	2.5	15	66.25

La tabla XXVII muestra la matriz de confusión de actividades para el rol médico interno con estimaciones sin la variable hora del día, con un porcentaje de error de 44.8%. La actividad mejor estimada es coordinación o sincronización (SN) con 62.5%, seguida de las actividades valoración y diagnóstico (98.75%), y cuidados al paciente (96.67).

Tabla XXVII. Estimaciones con redes neuronales sin la variable hora. Rol médico interno, error de estimación 44.8%.

MI	VYD	CP	SN	MD	CC
VYD	47.5	20	20	12.5	0
CP	10.91	61.82	25.45	0	1.82
SN	13.75	2.5	62.5	21.25	0
MD	8.75	2.5	30	58.75	0
CC	27.27	0	27.27	0	45.45

V.1.1. Estimaciones con Actividades Secundarias con RN

Se planteó una propuesta de estimación de actividad para los trabajadores hospitalarios, estimando primero las actividades secundarias y posteriormente realizar la estimación de la actividad general. La figura 28 muestra la propuesta de la organización de las variables contextuales para estimar primero una actividad secundaria, para posteriormente fusionar esa información con otra variable contextual que permitiera estimar la actividad de mejor manera.

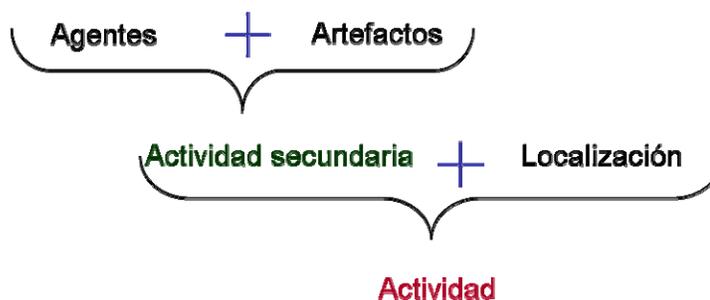


Figura 28. Asociación de variables contextuales para estimar actividad.

La codificación de las actividades secundarias fue realizada por el grupo que realizó el estudio de sombra. Dicha codificación forma parte del trabajo de investigación de doctorado “Cómputo Consciente de la Actividad para el Diseño de Aplicaciones Médicas

Ubicuas”, realizado por Mónica Tentori en el CICESE. Las actividades secundarias para el rol médico base se muestran en la tabla XXVIII.

Tabla XXVIII. Actividades secundarias y actividades de más alto nivel de abstracción.

Actividades	Actividades secundarias
VYD	PV -Procedimientos de valoración PR -Procedimientos de referencia PD -Procedimientos de diagnóstico
CP+CE	PT -Procedimientos técnicos de atención PB -Procedimientos básicos de atención PI -Procedimientos de información de atención
SN	PE -Procedimientos de enlace PS -Procedimientos de sincronización
MD	PSU -Procedimientos de <i>setting up</i> PP -Procedimientos de producción

En este caso se rediseñó el modelo de la red neuronal planteado en Favela, et al [2007]. La nueva red tuvo más valores de salida para el modelo. Los resultados obtenidos con la red neuronal utilizando actividades secundarias fueron más bajos que los resultados obtenidos con el vector de entrada reducido y las actividades originalmente propuestas. La matriz de confusión resultante se muestra en la tabla XXIX.

Tabla XXIX. Estimaciones de actividades secundarias con redes neuronales. Rol médico base, error de estimación 50.67%.

MB		VYD			CP			SN		MD	
		PV	PR	PD	PT	PB	PI	PE	PS	PSU	PP
VYD	PV	57.33	4	8	0	0	18.67	0	6.67	0	5.33
	PR	1.33	60	13.33	0	0	6.67	0	8	0	10.67
	PD	9.33	28	40	0	0	5.33	0	8	1.33	8
CP	PT	57.14	0	14.29	0	0	0	0	28.57	0	0
	PB	100	0	0	0	0	0	0	0	0	0
	PI	26.67	1.33	6.67	0	0	52	0	8	0	5.33
SN	PE	11.76	5.88	47.06	0	0	0	11.76	23.53	0	0
	PS	2.67	9.33	16	0	0	8	0	56	0	8
MD	PSU	0	23.81	9.52	0	0	0	0	28.57	28.57	9.52
	PP	2.67	12	4	0	0	8	0	12	4	57.33

El porcentaje de error de estimación del modelo es de 50.67%. La actividad secundaria mejor estimada es procedimientos de referencia (PR) con 60% de precisión, seguida de las actividades procedimientos de valoración (PV) y procedimientos de producción (PP) con un 27.33%.

Como muestra la tabla XXIX, la precisión en la estimación de actividades secundarias es muy baja, debido en gran parte a la baja cantidad de datos que se tienen como muestra para cada una de las actividades secundarias. La cantidad de muestras para cada una de las actividades secundarias correspondientes a la actividad cuidados al paciente (CP) era menor al 10% de la cantidad de muestras de otras actividades secundarias, como por ejemplo la actividad secundaria procedimientos de referencia. Dados estos resultados y argumentos, se decidió no realizar un modelo oculto de Markov correspondiente a las actividades secundarias.

V.1.2. Estimaciones de Actividad con el Vector Reducido con RN

El estudio de sensibilidad descrito en la sección IV.3 (representación de los datos), se aplicó también a las entradas del modelo de la red neuronal, es decir, se estimaron nuevamente las actividades con los vectores de entrada reducidos para los tres roles. Las tablas de confusión de los correspondientes roles se describen a continuación.

Para el rol de enfermera operativa, la tabla XXX muestra la matriz de confusión de la actividad estimada por el modelo de la red neuronal propuesto en Favela et al [2006] con los vectores de entrada reducidos por el estudio de sensibilidad descrito en la sección IV.3. La actividad mejor estimada es clases y capacitación (CC) con 100% de precisión, seguida de la actividad cuidados al paciente (CP) con 87.5%, y la actividad valoración y diagnóstico (VYD) con 65%. El error en la estimación para el rol es de 29.07%.

Tabla XXX. Estimaciones con redes neuronales utilizando el vector de entrada reducido. Rol enfermera operativa, error de estimación 29.07%.

EO	VYD	CP	SN	PM	MD	CC
VYD	65	17.5	11.25	3.75	2.5	0
CP	3.75	87.5	5	3.75	0	0
SN	5	13.33	61.67	10	10	0
PM	12.5	3.75	11.25	60	12.5	0
MD	14.29	0	14.29	20	51.43	0
CC	0	0	0	0	0	100

V.2. *Estimaciones con Modelos Ocultos de Markov*

Los resultados de las estimaciones de las siguientes subsecciones corresponden a las estimaciones de los dos modelos ocultos de Markov en capas descritos en el capítulo anterior. Las estimaciones de actividad de los modelos propuestos se presentan en forma de matrices de confusión.

V.2.1. Estimaciones con el Modelo Simple en dos Capas

La tabla de confusión correspondiente al rol enfermera operativa (ver tabla XXXI), muestra las estimaciones de actividad con el modelo simple en capas descrito en la sección 4.5.1. Las actividades mejor estimadas son clases y capacitación (CC) y cuidados al paciente con 100% de precisión, seguidas por la actividad preparación de material y medicinas (PM) con un 97.5%, y valoración y diagnóstico (VYD) con 88.75%. El error de estimación para este rol, con el modelo simple en dos capas, es de 8.32 %.

Tabla XXXI. Estimaciones con el modelo simple. Rol enfermera operativa, error de estimación 8.32%.

EO	VYD	PC	SN	PM	MD	CC
VYD	88.75	0	8.75	0	2.25	0
CP+CE	0	100	0	0	0	0
SN	0	3.33	86.67	0	10	0
PM	0	0	2.5	97.5	0	0
MD	17.14	0	5.71	0	77.15	0
CC	0	0	0	0	0	100

La tabla XXXIV presenta la matriz de confusión de las actividades de médicos de base con un porcentaje de error promedio de 7.92%. Las actividades mejor estimadas son valoración y diagnóstico y cuidados al paciente con 96.67%, seguidas de la actividad sincronización o coordinación con 88.33%, y manejo de documentos con 86.67%.

Tabla XXXIV. Estimaciones con el modelo en paralelo. Rol médico de base, error de estimación 7.92%.

MB	VYD	CP	SN	MD
VYD	96.67	1.67	1.67	0.00
CP	0.00	96.67	3.33	0.00
SN	0.00	0.00	88.33	11.67
MD	0.00	3.33	10.00	86.67

La tabla XXXV muestra la matriz de confusión de actividades para el rol médico interno con un porcentaje de error de 3.25%. La actividad mejor estimada es sincronización o coordinación con 100%, seguida de las actividades valoración y diagnóstico (98.75%) y cuidados al paciente (96.67%).

Tabla XXXV. Estimaciones con el modelo en paralelo. Rol médico interno, error de estimación 3.25%.

MI	VYD	CP	SN	MD	CC
VYD	98.75	1.25	0.00	0.00	0.00
CP	3.33	96.67	0.00	0.00	0.00
SN	0.00	0.00	100	0.00	0.00
MD	0.00	0.00	26.50	73.75	0.00
CC	0.00	0.00	0.00	10.00	90.00

V.2.3. Comparativa de las Estimaciones de los Modelos Propuestos

La tabla XXXVI muestra los errores en la estimación de actividad para cada uno de los roles. Los resultados del modelo en paralelo estiman la actividad de los trabajadores

hospitalarios con un error promedio de 7.4%. Para cada rol, los porcentajes de error en las estimaciones de la actividad son menores utilizando el modelo en paralelo, comparado con los porcentajes de error en la estimación de actividad con el modelo simple. Esto puede ser principalmente porque el modelo en paralelo captura diferentes niveles de abstracción y toma las ventajas del enfoque “dividir y vencer”, ya que en la primera capa un MOM es utilizado para entrenar cada variable contextual (artefactos y personas). En la fase de entrenamiento, el valor de máxima similitud se selecciona para cada MOM, y dado que la información contextual es entrenada de manera independiente en cada MOM, la precisión en la estimación final se incrementa. Finalmente, el modelo en paralelo es más robusto que el modelo simple, es decir, el modelo simple es más sensible a cambios en las interacciones con las personas, como muestra la tabla de los porcentajes de error para los roles de médico base y médico interno (tabla XXXVI).

Tabla XXXVI. Porcentajes de error en la estimación de actividad por rol.

Modelo dos Capas	EO	MB	MI	Promedio
Modelo Simple	8.32%	16.25%	29.42%	18.0%
Modelo en Paralelo	6.08%	7.92%	8.17%	7.4%

V.2.4. Análisis de las Estimaciones con el Modelo Paralelo en dos Capas

Al realizar el análisis de las estimaciones del modelo paralelo en dos capas, se pueden observar diferencias en el nivel de precisión entre algunas actividades. Por ejemplo, para el rol enfermera operativa la actividad mejor estimada fue clases y capacitación con un 100% de precisión; para el rol médico interno las mejores estimaciones de actividad corresponden a valoración y diagnóstico, y cuidados al paciente con 96.67%, y para el rol médico base la actividad mejor estimada es valoración y diagnóstico con 98.75%. En este caso se observa que el intercambio entre las actividades de cada uno de los roles afecta la forma en la que se estima la actividad. Por ejemplo, como se muestra en la tabla XXXIII (EO) la actividad cuidados al paciente se puede confundir con la actividad valoración y diagnóstico. En el

ambiente real del hospital es común el intercambio entre estas dos actividades. En este caso el modelo oculto de Markov no tiene suficiente evidencia para diferenciar entre las dos actividades, dado que la información contextual no cambia.

La figura 29 muestra los porcentajes de estimación de actividad correspondientes al rol médico base. En donde, el porcentaje mayor indica las veces en las que coincidieron de manera correcta las estimaciones de actividad de los modelos del primer nivel (agentes, artefactos). El porcentaje de 15.4% corresponde a las veces en las que se estimó de manera correcta la actividad, debido a que el MOM con información de sólo agentes estimó de manera precisa la actividad. El porcentaje de 10.4% representa las veces en las que el modelo con sólo información de artefactos aportó mayor información para la estimación final de la actividad. Finalmente, el 7.9% corresponde a las estimaciones incorrectas, ya sea porque ambos modelos aun cuando coinciden en la estimación de actividad en el primer nivel, el modelo final estima que se realiza otra actividad.

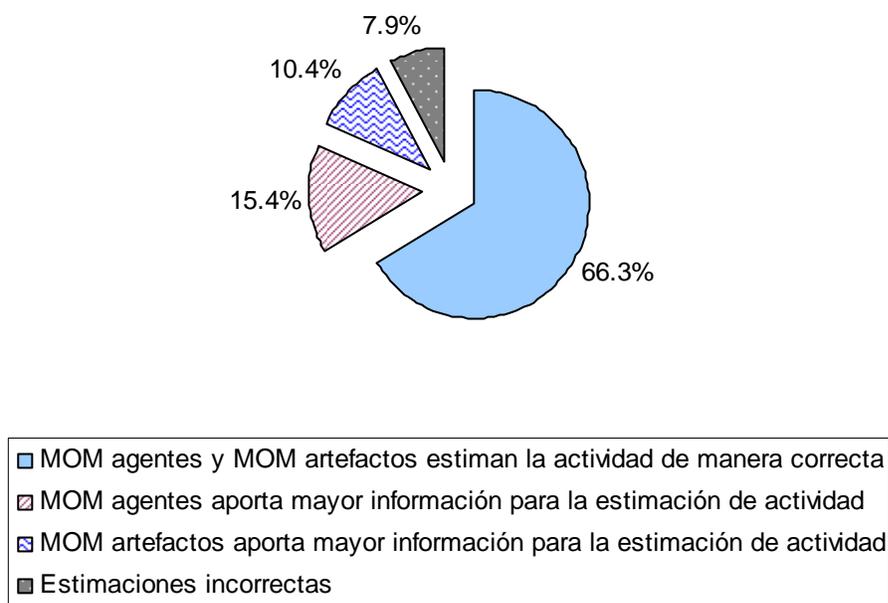


Figura 29. Gráfica de la influencia de los modelos (agentes, artefactos) en la salida final del modelo en paralelo.

V.2.5. Robustez del Modelo Paralelo en dos Capas

Para mostrar la robustez del modelo en paralelo en dos capas, se realizaron algunas pruebas manipulando las entradas, es decir, introduciendo error. El tipo de error aplicado es el de sustitución, ya que se consideró que en una implementación con tarjetas RFID, es el tipo de error más probable. Los errores podrían ocurrir al leer la información de alguna de las tarjetas, es decir, en el caso de que alguno de los agentes olvidara su tarjeta, o bien podría no leerse por estar deteriorada. En caso de los artefactos alguno podría ya no contar con dicha tarjeta o de manera similar a los agentes la tarjeta podría estar deteriorada.

Para el modelo de error, la transformación de sustitución consiste en cambiar los valores que representan interacción (1), por valores que representan no interacción (0). Por ejemplo

$$1010100 \xrightarrow{s} 1010000,$$

en este caso, el segmento correspondiente a interacciones con artefactos para el rol médico base indica que hay interacciones con el expediente médico del paciente, con equipo de medición y con resultados de laboratorio. Al aplicar la transformación de sustitución el segmento cambia una interacción con los resultados de laboratorio, por la no interacción con ese artefacto.

Para la fase de pruebas, las transformaciones de sustituciones se realizaron de la siguiente manera: un 10% de ruido en las entradas significa que a un 10% de los vectores de entrada por actividad se le sustituyó una interacción (1) por la no interacción (0), ya sea con agentes o con artefactos. Las entradas a las que se les sustituyeron interacciones, se seleccionaron de manera aleatoria, al igual que las posiciones en donde había interacciones.

La figura 30 muestra la gráfica de precisión para el rol médico base con los dos modelos propuestos, la línea con rombos corresponde al modelo en paralelo y a línea con cuadros corresponde a los valores del modelo simple en dos capas. Para el modelo en paralelo, el decremento gradual de la precisión permite observar que para algunas aplicaciones se podrá

contar con una precisión en la estimación de actividad superior al 80%, aun cuando el ruido en las entradas sea de hasta un 40%.

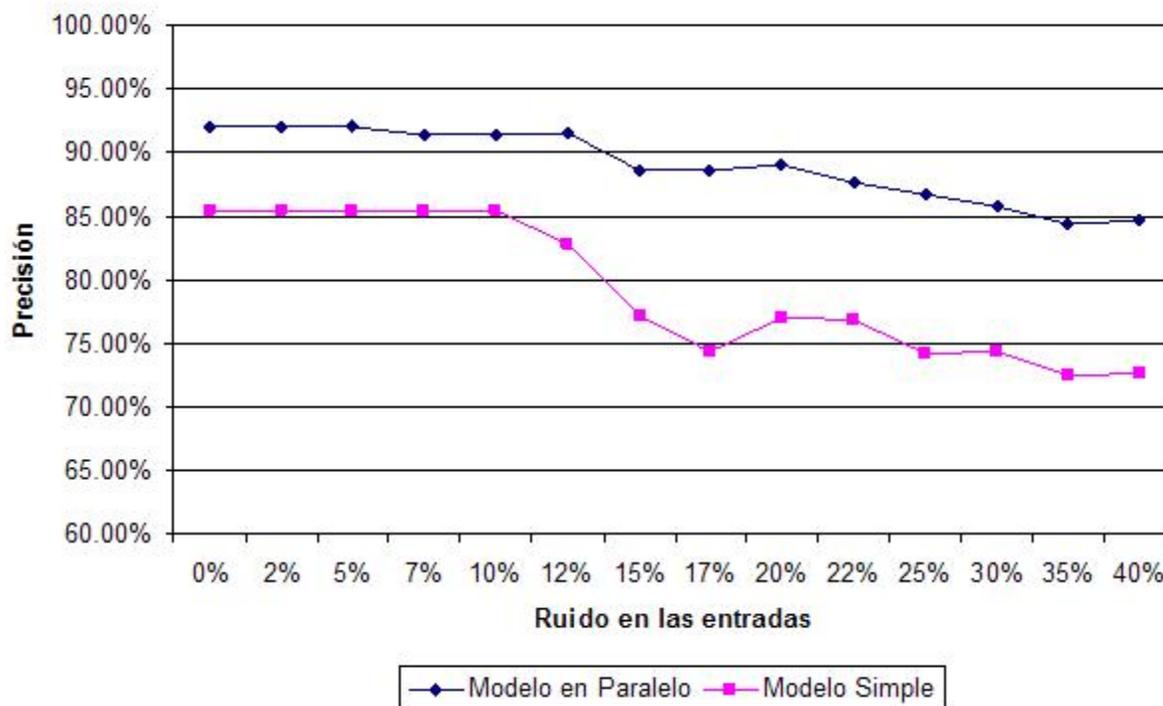


Figura 30. Gráfica de precisión en la estimación de actividad con ruido en las entradas, rol médico base.

V.3. *Estimaciones con Observadores Expertos*

Para determinar cómo las personas familiarizadas con un ambiente de trabajo hospitalario estimaban la actividad utilizando información contextual, en Favela et al [2007] se realizó un experimento con observadores expertos. Los observadores expertos son personas familiarizadas con el trabajo hospitalario, que realizaron el seguimiento de sombra reportado en Morán et al [2006], por lo que están familiarizados con el esquema de codificación utilizado. A seis usuarios se les presentó la información de las variables

contextuales (rol, ubicación, hora del día, artefactos utilizados y las interacciones con sus colegas, como muestra la figura 31) usadas por la red neuronal para estimar la actividad. A los participantes se les presentaron 120 muestras (40 por rol) y se les pidió situarse en la descripción del reporte de observación, y basándose en la evidencia, inferir la actividad que se estaba realizando. Los observadores expertos pudieron estimar correctamente las actividades sólo un 48.82% de las veces.

Rol	Time	Localizacion	Personas	Artefactos	Actividad
Soy	Estoy en ...	Estoy con ...	Uso ...	¿Que estoy haciendo?
ENFOP	13.53	SALA ATENCION	PAC	NINGUNO	Valoracion y diagnostico
ENFOP	12.36	SALA ATENCION	PAC	NINGUNO	Selecciona una actividad
ENFOP	12.24	SALA ATENCION	NOBODY	MATERIAL MEDICO Y MEDICINAS	Valoracion y diagnostico
ENFOP	11.52	CENTRAL ENFERMERAS	MEDINT	NINGUNO	Cuidados al paciente
ENFOP	12.11	CENTRAL ENFERMERAS	NOBODY	NINGUNO	Coordinacion
ENFOP	10.36	SALA ATENCION	PAC+MEDESP	HOJA DE ENFERMERIA	Preparacion de medicinas
ENFOP	10.36	PASILLO	MEDINT	NINGUNO	Manejo de documentos
#	#	#	#	#	Clases y Capacitacion
#	#	#	#	#	Coordinacion
MEDINT	11.26	PASILLO	NADIE	EXPEDIENTE+CARRITOS	Cuidados al paciente
MEDINT	9.51	SALA ATENCION	MEDINT+MEDBASE	EXPEDIENTE+ACCESORIOS DE OFICINA	Valoracion y diagnostico
MEDINT	10.54	SALA ATENCION	MEDINT+MEDBASE	EXPEDIENTE	Valoracion y diagnostico
MEDINT	9.27	CONSULTORIO	MEDINT+MEDBASE	EQUIPO DE COMPUTO	Valoracion y diagnostico
MEDINT	7.30	CONSULTORIO	MEDINT+MEDBASE	CENSO	Coordinacion
MEDINT	10.52	SALA ATENCION	FAM	EXPEDIENTE+ACCESORIOS DE OFICINA	Cuidados al paciente
#	#	#	#	#	Manejo de documentos
#	#	#	#	#	#
MEDBASI	12.26	PASILLO	MEDINT	FORMAS	Valoracion y diagnostico
MEDBASI	9.38	SALA ATENCION	MEDINT	RESULTADOS DE ESTUDIOS	Valoracion y diagnostico
MEDBASI	8.18	CONSULTORIO	NOBODY	NINGUNO	Manejo de documentos
MEDBASI	10.41	SALA ATENCION	MEDINT+FAM	EXPEDIENTE	Valoracion y diagnostico
MEDBASI	12.38	PASILLO	MEDINT	ACCESORIOS DE OFICINA+FORMAS+MEDIO DE COMUNICACION	Coordinacion
MEDBASI	10.32	SALA ATENCION	MEDINT	HOJA DE ENFERMERIA	Cuidados al paciente
MEDBASI	8.05	PASILLO	ENFOP+JEFAPISO+TE	EXPEDIENTE+CARRITOS	Cuidados al paciente
MEDBASI	10.06	SALA ATENCION	MEDINT+PAC	NINGUNO	Valoracion y diagnostico

Figura 31. Esquema de codificación utilizado en la prueba con observadores expertos.

La tabla XXXVII muestra la matriz de confusión para el rol enfermera operativa; las estimaciones corresponden a los observadores expertos. Para este rol, la actividad mejor estimada es manejo de documentos (MD) con 84%, seguida de la actividad cuidados al paciente (CP) con 67.5%, y la actividad preparación de material y medicinas (PM) con un 62.5%. El error de estimación para este rol, es de 48.05%.

Tabla XXXVII. Estimaciones con observadores expertos. Rol enfermera operativa, error de estimación 48.05%.

EO	VYD	CP	SN	PM	MD	CC
VYD	15	27.50	20	5	32.50	0
CP	2.50	67.50	10	17.50	2.50	0
SN	20	25	50	0	2.50	2.50
PM	2.50	12.50	17.5	62.50	5	0
MD	16	0	0	0	84	0
CC	6.67	13.33	40	13.33	0	26.67

En la tabla XXXVIII se muestra la matriz de confusión de las actividades de médicos de base con un porcentaje de error de 63%. Las actividades mejor estimadas son valoración y diagnóstico y cuidados al paciente con 60 y 40%, respectivamente, seguidas de la actividad manejo de documentos con 30%.

Tabla XXXVIII. Estimaciones con observadores expertos. Rol médico de base, error de estimación 30%.

MB	VYD	CP	SN	MD
VYD	60	30	0	10
CP	50	40	10	0
SN	60	10	20	10
MD	20	30	20	30

Finalmente, la tabla XXXIX presenta las estimaciones para el rol médico interno en donde el porcentaje de error es de 65%. La actividad mejor estimada es valoración y diagnóstico con 60%, seguida de la actividad cuidados al paciente con 57.14%, y sincronización o coordinación y manejo de documentos con 30%.

Tabla XXXIX. Estimaciones con observadores expertos. Rol médico interno, error de estimación 65%.

MI	VYD	CP	SN	MD	CC
VYD	60	20	10	10	0
CP	14.29	57.14	0	14.29	14.29
SN	30	10	30	20	10
MI	10	30	20	30	10
CC	33.33	0	33.33	33.33	0

V.4. Comparativa de Resultados

Los resultados obtenidos, descritos en las anteriores secciones, se compararon de manera directa. La figura 32 muestra la gráfica de los resultados finales, donde podemos observar que la reducción del error promedio de estimación de actividad es de 75.15%. Cabe resaltar que los resultados correspondientes a la estimación con redes neuronales tienen un proceso adicional de manejo de incertidumbre. Es decir, aplicaron una estrategia de manejo de incertidumbre para incrementar la precisión de las estimaciones. Basados en los reportes de seguimiento, observaron que la realización de algunas actividades se lleva a cabo en largos periodos de tiempo, y presenta fenómenos de recurrencia. Considerando ese principio, se tomó en cuenta que hay una gran probabilidad de que los trabajadores hospitalarios continúen realizando una actividad en lugar de cambiar a otra actividad. Utilizando el principio de recurrencia el error de estimación se redujo un 5%.

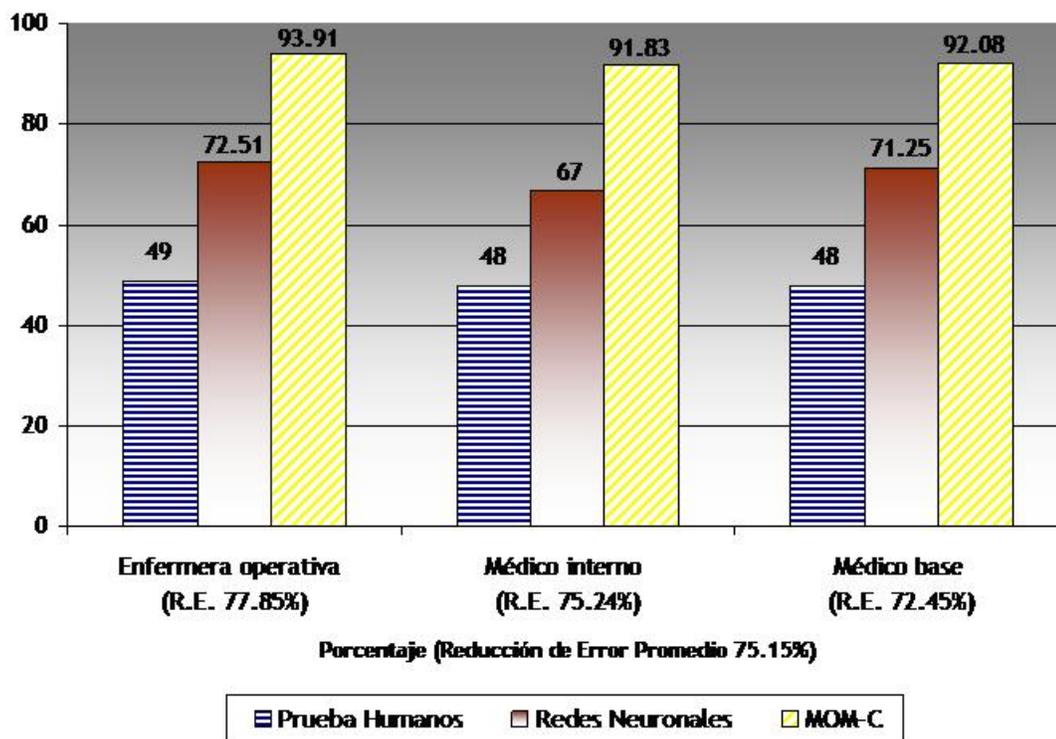


Figura 32. Comparativa de resultados de estimaciones entre observadores expertos, redes neuronales y modelos ocultos de Markov.

Los resultados obtenidos con el modelo en paralelo en dos capas proveen las mejores estimaciones de actividad, aun cuando sólo usa parte de la información (agentes y artefactos), a diferencia de las redes neuronales, que utilizan cuatro variables contextuales (hora del día, ubicación, agentes y artefactos). Incluso, el modelo en paralelo es un modelo robusto, que permitirá soportar la implementación de algunas aplicaciones que brinden servicios a los usuarios mientras realizan sus tareas.

Conociendo la actividad de un usuario, una aplicación podría tener suficiente evidencia para filtrar mensajes entrantes o identificar los servicios de cómputo relevantes para la tarea que se realiza. A pesar de que, los errores en este tipo de servicios no causan un gran impacto en el aspecto del trabajo médico (es decir, no afectan la salud del paciente), son un factor clave para la adopción de la aplicación.

Cabe resaltar que en un ambiente hospitalario el personal organiza sus tareas en base a las actividades que realizan otras personas. Por esto deben estar conscientes de la actividad de los otros. En ocasiones se utiliza información contextual como hora del día, presencia y ubicación de colegas para inferir la actividad que realizan otros. Por ejemplo, se puede inferir que un médico de base se encuentra realizando una ronda, sabiendo que se encuentra en el cuarto de un paciente, con médicos internos, y son las 11AM. En este caso, las estrategias que utilizan para inferir la actividad son un tanto imprecisas, pero es la única forma que emplean para darse una idea del ritmo de trabajo en el hospital.

El uso de la estimación de actividad en aplicaciones conscientes del contexto, proveerá de varios beneficios a los trabajadores hospitalarios. Asimismo permitiría una mejor realización de las tareas apoyándose en los servicios que se les puedan brindar de acuerdo a la actividad que realizaran.

Capítulo VI

Conclusiones y Trabajo Futuro

En este capítulo se presentan las conclusiones del trabajo de tesis desarrollado. Se mencionan brevemente las aportaciones del trabajo de tesis y se describen algunas propuestas para trabajo futuro.

VI.1. Conclusiones

En este trabajo de tesis se presentó un estudio cuyo objetivo principal fue el de estimar la actividad de trabajadores hospitalarios utilizando modelos ocultos de Markov, tomando como base la información recopilada de varios días de seguimiento de médicos de base, enfermeras y médicos internos.

Se identificó la información contextual relevante para modelar e inferir las actividades de los trabajadores hospitalarios. Por mencionar un ejemplo, los resultados de las estimaciones de actividad sin la variable hora del día utilizando redes neuronales incrementaron la precisión un 4%. Los resultados mostraron la baja relevancia de dicha variable para la estimación de actividades, dado que es un ambiente altamente dinámico y las actividades se realizan sin seguir un horario estricto. El estudio de sensibilidad sobre las variables contextuales permitió la reducción del vector de entrada en un 38.01%.

Los resultados de las estimaciones de actividades secundarias utilizando redes neuronales no fueron exitosos debido a la escasa cantidad de datos para entrenar a la red neuronal con las muestras de actividades secundarias. Tomando en cuenta dicha limitante no se continuó con la estimación de actividad realizada a más alto nivel, ni se procedió al diseño del modelo para estimar actividades secundarias con modelos ocultos de Markov.

Se propusieron dos modelos en capas para estimar la actividad. Un modelo simple y un modelo en paralelo. En base a los resultados de error promedio obtenidos (18% y 7.4%) en la estimación de actividad de los trabajadores hospitalarios con los modelos propuestos, se concluye que el mejor modelo para estimar la actividad es el modelo en paralelo en dos capas. Se mostró además que el modelo en paralelo propuesto es un modelo robusto, es decir, la precisión en la estimación de la actividad se mantiene superior al 80% con ruido en las entradas desde 2% hasta 40%.

Finalmente, los resultados de las estimaciones de actividad con el modelo en paralelo en dos capas mejoraron notablemente (92.6%), comparado con los resultados de las estimaciones de actividad utilizando redes neuronales (75%), lo que nos muestra que es un modelo robusto ante ambientes dinámicos. Sin embargo, el modelo tiene algunas limitaciones en cuanto a la información observable usada para estimar la actividad. Si una configuración de información contextual usada no ha sido observada, el MOM no puede predecir la actividad que se está ejecutando. Para resolver este problema se definieron rangos de proximidad para cada entrada de las variables contextuales usadas. Es decir, si una entrada no ha sido observada, se asigna el valor de la entrada observable más parecida. Este tipo de limitante ya ha sido tratado en Casar y Fonollosa [2006], donde proponen la ponderación de la probabilidad de observación de los modelos de Markov, equilibrando la diferencia entre rangos dinámicos de las probabilidades de transición y de observación.

VI.2. Aportaciones

El objetivo principal de este trabajo fue el de proponer un modelo que permita estimar la actividad de trabajadores hospitalarios utilizando modelos ocultos de Markov, un modelo lo suficientemente robusto para ofrecer una precisión en la estimación de actividad superior al 80%, que permita el diseño de aplicaciones que provean servicios al usuario. En este sentido, la principal aportación es el estudio previo para proponer un modelo robusto para la estimación de actividad de trabajadores hospitalarios.

A continuación se listan otras aportaciones que se hicieron en el transcurso de la realización de este trabajo de tesis:

- Un análisis de sensibilidad a alto y bajo nivel de las variables contextuales hora del día, ubicación, artefactos y personas, con el fin de decidir cuáles son las variables contextuales que aportan mayor información para estimar la actividad de un trabajador hospitalario.
- La propuesta de un modelo en paralelo utilizando modelos ocultos de Markov, que aplican el enfoque “dividir y vencer”, lo cual permite un alto porcentaje de precisión en la estimación de actividad.
- El manejo de rangos de proximidad para vectores de entrada no entrenados. Con este enfoque se obtienen mejores resultados en la estimación de la actividad. Consiste en asignar a valores no entrenados el valor próximo más parecido a la entrada dada.
- Un modelo en paralelo robusto que permite estimar de manera correcta la actividad un 92% de las veces con las entradas sin ruido, u una precisión superior al 80% aun con ruido en las entradas de hasta 40%.

Parte de los resultados obtenidos en este trabajo de tesis se presentaron en el artículo de investigación: Sánchez, D., Tentori, M. y Favela, J. ‘Hidden Markov Models for Activity Recognition in Ambient Intelligence Environments’. Aceptado para publicarse en las memorias del Encuentro Internacional de Ciencias de la Computación, IEEE Computer Press, ENC’07, Morelia, Michoacán, Septiembre, 2007.

VI.3. Trabajo Futuro

Los resultados obtenidos a partir del estudio de sensibilidad y del modelo basado en modelos ocultos de Markov presentados en este trabajo de tesis fueron muy buenos, sin embargo, aún queda trabajo por hacer. A continuación se enumeran una serie de adecuaciones que deberían hacerse y que permitirían obtener resultados mejores a los reportados en este trabajo.

- Realizar una comparativa de los resultados obtenidos utilizando otros métodos de reconocimiento de patrones como máquinas de vector soporte [Cortes y Vapnik, 1995], [Burges, 1998] árboles de decisión o métodos AdaBoost [Duda, et al., 2001].
- Refinar las estimaciones en base al rol y a la actividad que se realiza, para utilizar un método deductivo que permita incrementar la precisión agregando la información de ubicación a las salidas del modelo oculto de Markov.
- Integrar al modelo en paralelo en capas otras fuentes de información como audio y video, para estimar con mayor precisión la actividad desarrollada. Esto es, el tener mayor información que permita deducir si es sólo una persona o son varias las personas que dialogan, aunado a los artefactos con los que interactúan y a los movimientos que realizan, permitiría estimar la actividad de mejor manera.
- Diseñar un componente de software que pueda obtener de manera sencilla los resultados de la estimación de actividad, y que permita el desarrollo de aplicaciones centradas en la actividad del usuario para proveer servicios en un ambiente médico.
- Implementar una aplicación que, consciente de la actividad del trabajador hospitalario, le brinde servicios que le faciliten la realización de sus tareas. Por ejemplo, si una enfermera se encuentra realizando preparación de medicamentos y medicinas, el sistema sea capaz de mostrar en una pantalla o bien en una PDA, el listado de los pacientes,

sus respectivos medicamentos, así como las dosis, y adicionalmente imprimir las etiquetas de los medicamentos que así lo requieran (por ejemplo sueros).

- Explorar el uso de redes bayesianas dinámicas para modelar la estimación de la actividad, de manera que se pueda hacer la estimación utilizando entradas que no hayan sido observadas.

Referencias

Abowd, G., Mynatt, E. y Rodden, T., 2002. The Human Experience. Pervasive computing. IEEE, 1(1): 48-57.

AwareHome Project, 2007. Georgia Institute of Technology. The Aware Home, <http://www.cc.gatech.edu/fce/ahri>. Consulta: mayo de 2007.

Bardram, J., 2003. Hospitals of the Future: Ubiquitous Computing support for Medical Work in Hospitals. Proceedings of UbiHealth, Workshop on Ubiquitous Computing for Pervasive Healthcare Applications. Seattle, Washington, 12 de octubre de 2003.

Bardram, J.E., 2004 Applications of context-aware computing in hospital work: examples and design principles. En ACM symposium on Applied computing. Nicosia, Cyprus, 14 al 17 de marzo de 2004, ACM Press, p.1574-1579.

Bardram, J.E., Baldus, H. y Favela, J., 2006. Pervasive Computing in Hospitals. Pervasive Computing in Healthcare. CRC Press, p. 49-78.

Boyle, Roger. Hidden Markov models: An introduction tutorial. http://www.comp.leeds.ac.uk/roger/HiddenMarkovModels/html_dev/main.html , Consulta: 7 de septiembre de 2006.

Burges, C., 1998. A Tutorial on Support Vector Machines for Pattern Recognition. Springer Netherlands, 2(2): 121-167.

Casar, M., y Fonollosa, J.A., 2006 Ponderación de las probabilidades de observación de los HMM para verificación de locuciones en sistemas de RAH. IV Jornadas en Tecnología del Habla. Zaragoza, España, 8 al 10 de noviembre de 2006, p. 243-247.

Chin, T., 2005. Untapped power: a physician's handheld. *American Medical News*, 48(2): 25-26.

Christensen, H.B., 2002. Using Logic Programming to Detect Activities in Pervasive Healthcare. 18th International Conference on Logic Programming. Copenhagen, Denmark, 29 de julio al 1 de agosto de 2002, p. 21-36.

Cortes, C. y Vapnik, V., 1995. Support-vector network. *Machine Learning*. Springer Netherlands, 20(3): 273-297.

Dey, A. y Abowd, G., 2000. Towards a better understanding of context and context awareness. En workshop on the What, Who, Where, When, and How of Context-Awareness. CHI'00, The Hague, Netherlands, 1 al 6 de abril de 2000.

Duda, R., Hart, P. y Stork, D., 2001. *Pattern Classification*. Ed. Wiley-Interscience. Second Edition, 2001.

Favela, J., Tentori, M., Castro, L.A., González, V.M., Moran, E.B. y Martínez-García, A.I., 2007. Activity Recognition for Context-Aware Hospital Applications: Issues and Opportunities for the Deployment of Pervasive Networks. *Mobile Networks and Applications*. Springer Netherlands, 12(2-3): 155-171.

Fogarty, J., Hudson, S.E., Atkeson, C.G., Avrahami, D., Forlizzi, J., Kiesler, S., Lee, J.C. y Yang, J., 2005 Predicting human interruptibility with sensors. *ACM Transactions on Computer-Human Interaction*. 12(1): 119-146.

Gross, T. y Specht, M., 2001. Awareness in Context-Aware Information Systems. *Mensch and Computer 2001*. En Oberquelle, Oppermann y Krause (Eds.) *Fachübergreifende Konferenz*. Stuttgart: Bad Honnef, Germany, 5 al 8 de marzo de 2001, p. 173-182.

Haykin, S., 1999. *Neural networks: A Comprehensive Foundation*. Prentice Hall, Second Edition, 1999.

Huang, X., Weng, J. y Zhang, Z., 2004. Office presence detection using multimodal context information. *IEEE International Conference on Acoustics, Speech, and Signal Processing*, Montreal, Canada, 17 al 21 de mayo de 2004, 3(3): 773-779.

Hudson, S. E., Fogarty, J., Atkeson, C. G., Avrahami, D., Forlizzi, J., Kiesler, S., Lee, J. C., y Yang, J., 2003. Predicting human interruptibility with sensors: A Wizard of Oz Feasibility Study. *SIGCHI conference on Human factors in computing*. Ft. Lauderdale, Florida, USA, 5 al 10 de abril de 2003. ACM Press, 12(1): 119-146.

Kennedy, R., Lee, Y., Van Roy, B., Reed, C. y Lippman, R., 1998. *Solving Data Mining Problems through pattern recognition*. Data warehousing Institute series from Prentice Hall, 1998.

Lee, S. W. y Mase, K., 2002. Activity and location recognition using wearable sensors, *IEEE Pervasive Computing*, 1(2): 24-32.

McDonald, S., 2005. Studying actions in context: a qualitative shadowing method for organizational research. *Qualitative Research*, SAGE Publications, 5(4): 455-473.

Morán, E.B., Tentori, M., González, V.M., Martínez-García, A.I. y Favela, J., 2006. Mobility in Hospital Work: Towards a Pervasive Computing Hospital Environment. *International Journal of Electronic Healthcare*, 3(1): 72-89.

Morse, D. y Dey, A., 2000. The What, Who, Where, When, and How of Context-Awareness. *CHI'00 workshop on Context-Awareness*. The Hague, Netherlands, 1 al 6 de abril de 2000.

O'Connor, M.C., 2006. Testing Ultrasound to Track, Monitor Patients. RFID Journal, 2006. 1(31): 2-3.

Oliver, N., Garg, A. y Horvitz, E., 2004. Layered representations for learning and inferring office activity from multiple sensory channels. Computer Vision and Image Understanding, Elsevier Science Inc, 96(2): 163-180.

Parzen, E., 1999. Stochastic Processes. Mathematics, SIAM 1999, p. 188.

Pentland, A., 2004. Healthwear: Medical Technology Becomes Wearable. IEEE Computer, 37(5): 42-49.

Philipose, M., Fishkin, K. P., y Perkowi, M., 2004. Inferring Activities from Interactions with objects. IEEE Pervasive Computing, 3(1): 50-57.

Rabiner, L.R., 1989. A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition. Proceedings of the IEEE 1989, 77(2): 257-286.

Rabiner, L.R. y Juang, B.H., 1986. An introduction to hidden Markov models. ASSP Magazine, IEEE, 3(1): 4-16.

RAE, <http://www.rae.es/> Diccionario de la Real Academia Española 22ª Edición, 2001. Consulta: julio 2006.

Resch, Barbara. Hidden Markov Models: A Tutorial for the Course Computational Laboratory. Signal Processing and Speech Communication Laboratory. <http://www.igi.turgaz.at/lehre/CI>. Consulta: 9 de octubre de 2006.

Russell, S. y Norvig, P., 1993. Artificial Intelligence: A Modern Approach. Prentice Hall, 1993.

Sandor, D. English, J., Oates, T., Segall, Z. y Joshi, A., 2007. XPod: A Human Activity Aware Learning Mobile Music Player. Workshop on AI Techniques for Ambient Intelligence. 6 al 7 de enero de 2007.

Schilit, B. y Theimer, M., 1994. Disseminating Active Map Information to Mobile Hosts. IEEE Network, p. 22-32.

Schilit, B., Adams, N. y Want, R., 1994. Context-Aware Computing Applications. 1st International Workshop on Mobile Computing Systems and Applications, p. 85–90.

Schmidt, A., Beigl, M. y Gellersen, H-W., 1999. There is more to Context than Location. Computers and Graphics, Elsevier, 23(6): 893-901.

Shadbolt, N., 2003. Ambient Intelligence. IEEE Intelligent Systems. IEEE Educational Activities Department, 18(4): 2-3.

Stanford, V., 2003. Beam Me Up, Doctor McCoy, IEEE Pervasive Computing, 2(3): 13-18.

Tang, C. y Carpendale, S., 2007. An Observational Study on Information Flow during Nurses' Shift Change. Proceedings of the SIGCHI conference on Human factors in computing systems. San Jose, CA, USA, 28 de abril al 3 de mayo de 2007, ACM Press, p. 219-228.

Toselli, A., 2004. Tesis doctoral: Reconocimiento de Texto Manuscrito Continuo. Universidad Politécnica de Valencia.

Weiser, M., 1991. The computer for the 21st century. Scientific American, 265(3): 94-104.

Zhang, D. Gatica-Perez, D., Bengio, S. y McCowan, I., 2006. Modeling Individual and Group Actions in Meetings with Layered HMMs. *IEEE Transactions on Multimedia*, 8(3): 509-520.