

APRENDIZAJE EVOLUTIVO DE UN SISTEMA BASADO EN REGLAS DIFUSAS PARA UN SISTEMA DE CONTROL DE ENTORNO POR MEDIO DE PUNTERO LÁSER

Francisco Chávez¹, Francisco Fernández¹, Rafael Alcalá², Jesús Alcalá², Francisco Herrera²

¹Dept. De Sistemas Informáticos y Telemáticos, Universidad de Extremadura, España, {fchavez, fcofdez}@unex.es

²Dept. de Ciencias de la Computación e Inteligencia Artificial, CITIC-UGR, Universidad de Granada, España, {alcala, jalcala, herrera}@decsai.ugr.es

Resumen

Estudios recientes en hogares inteligentes han propuesto métodos para utilizar un puntero láser que interactúa con los dispositivos eléctricos y electrónicos del hogar, lo que representa un dispositivo fácil de usar y barato para el control de un hogar. Sin embargo, la detección del punto láser originado por el dispositivo es actualmente un problema abierto, ya que se pretende utilizar cámaras estándar sin costosos filtros, lo que nos obliga a utilizar algoritmos especializados de búsqueda en una imagen.

En este artículo proponemos un método híbrido, que combina una técnica clásica utilizada en los procesos de detección de imágenes (*Template Matching*) junto con un aprendizaje evolutivo de los sistemas basados en reglas difusas para la detección de puntos láser en entornos domésticos reales. Este trabajo analiza la eficacia del sistema propuesto, que mejora la tasa de éxito en las imágenes sin punto láser junto con una notable disminución de falsos positivos, al compararlo con sistemas previos utilizados para la detección del punto láser.

Palabras Clave: Sistemas de Interacción, Sistemas de control domóticos, Detección de puntos láser, Sistemas Basados en Reglas Difusas, Aprendizaje Evolutivo.

1 Introducción.

Hoy en día, una vivienda puede ser controlada por diferentes dispositivos, como dispositivos especiales de control en el interior, o por medio de teléfonos móviles, ordenadores, usando *Internet* si los usuarios están al aire libre. Recientes investigaciones en los hogares inteligentes proporcionan

grandes soluciones para el control de dispositivos para el hogar [1].

Por otro lado, el trabajo presentado en [9] hace uso de un robot para ayudar a personas con discapacidad a la hora de coger objetos. En este trabajo, los autores también proponen una interesante forma de señalar los objetos deseados por medio de un puntero láser. El robot debe ser capaz de detectar el punto láser sobre un objeto para poder cogerlo posteriormente. Otro uso de los punteros láser ha sido como elemento indicador para el control de grandes pantallas [10, 15]. Esta idea ha sido adaptada a los sistemas de control de entorno que presentamos en este trabajo. El objetivo principal en este tipo de sistemas es la detección del punto láser de forma eficaz y barata sin utilizar costosos equipos para ello.

Una alternativa es el análisis de imágenes utilizando cámaras estándar [2], donde un conjunto de algoritmos son capaces de detectar la presencia de un punto láser. Sin embargo, estos algoritmos presentan falsos positivos, lo que provocaría el envío de una orden incorrecta al sistema de control domótico, obteniendo así situaciones potencialmente peligrosas e incontroladas. Por esta razón, en [3] se presenta un nuevo enfoque de hibridación de una técnica clásica con el uso de un Sistema de Basado en Reglas Difusas (SBRD) diseñado a partir del conocimiento de expertos [14] para tratar de mejorar la tasa de éxito en las imágenes sin punto láser. Además, este SBRD inicial fue ajustado mediante un Algoritmo Genético (AG) en el trabajo presentado en [4], con el fin de mejorar la tasa de éxito en las imágenes sin punto láser.

En este trabajo se presenta un nuevo enfoque para detectar el punto láser con respecto al presentado en [3] y [4] por medio de un aprendizaje evolutivo del SBRD para el sistema de detección de puntos láser. Consiste en un algoritmo de aprendizaje integrado que ajusta la Base de Datos (BD) basándose en el uso de la representación de 2-tuplas lingüísticas [7] con el objetivo de obtener la mejor Base de Reglas (BR). Los resultados obtenidos mediante el método propuesto utilizan un modelo de validación cruzada para un

conjunto grande de ejemplos, 990 imágenes en total, que simulan una situación real del sistema de control, donde recogen las diferentes situaciones de luz y distancia que se puede dar en un hogar convencional. Estos resultados muestran una mejor tasa de éxito general con respecto a las técnicas anteriores. Pero cabe destacar la ventaja más importante obtenida con el modelo, la práctica eliminación de los falsos positivos.

Este trabajo se divide como sigue: En la sección 2, se describe el sistema de control de entorno junto con los algoritmos utilizados para la detección del punto láser. La sección 3 presenta el aprendizaje evolutivo del SBRD utilizado en este trabajo. Los resultados obtenidos con la técnica clásica, y los enfoques híbridos basados en la derivación del SBRD a partir del conocimiento experto, el ajuste automático y el aprendizaje automático se describen y analizan mediante la comparación de ellos en la sección 4. Finalmente, en la sección 5 se exponen las conclusiones del trabajo.

2 Descripción del sistema y trabajos previos.

Como se ha mencionado, el sistema de control de entorno por medio de un apuntador láser permite a sus usuarios indicar qué dispositivo desean controlar. El sistema está dividido en tres secciones (ver figura 1).




Figura 1: Sistema de Control de Entorno.

- ♦ Sección 1. La herramienta de configuración permite a los usuarios seleccionar los dispositivos del hogar que serán controlados por el sistema. Con esta herramienta, se marcarán las diferentes zonas activas para cada dispositivo, utilizando las imágenes enviadas por una cámara de vídeo estándar.
- ♦ Sección 2. En esta sección, el sistema utiliza diferentes técnicas para analizar la imagen enviada por la cámara de vídeo y localizar la posición del punto láser.
- ♦ Sección 3. La arquitectura KNX/EIB [11] permite controlar los dispositivos del hogar una vez que el punto láser se encuentra y éste está sobre una zona activa. El sistema envía al sistema doméstico las órdenes necesarias para activar/desactivar el dispositivo seleccionado.

La principal contribución de este trabajo se centra en la sección 2, con el fin de mejorar la capacidad de detección de punto de láser. En la figura 2, puede verse un ejemplo de las imágenes con y sin punto láser.



Figura 2: Imagen con punto láser (izq). Imagen sin punto láser (der).

Los algoritmos utilizados en trabajos anteriores para la detección del punto láser han sido los siguientes:

1. Umbralización Dinámica (*UD*)
2. Template Matching (*TM*)
3. Template Matching + Umbralización Dinámica (*TM + UD*)
4. Template Matching + SBRD diseñado por un experto (*TM + SBRD_{experto}*)
5. Template Matching + SBRD ajustado automáticamente por un AG (*TM + SBRD_{ajustado-AG}*).

El sistema de control de entorno basado en el puntero láser que se presenta en [2] utilizó tres algoritmos clásicos diferentes, UD, TM y TM + UD. En [3] se propone un modelo híbrido inicial mediante la combinación de TM con un SBRD obtenidos a partir de la experiencia de expertos, donde posteriormente se ajustan las funciones de pertenencia del mismo a través de un AG [4].

3 Template Matching más sistema de aprendizaje evolutivo para detección del punto láser.

En esta sección, se presenta un nuevo enfoque del problema presentado. Éste se basa en el uso de una técnica más avanzada para un aprendizaje completo del SBRD utilizado para detectar el punto láser de la imagen obtenida por TM. Por lo tanto, en este trabajo se propone la técnica de TM en combinación con el aprendizaje de la Base de Conocimiento (BC) (BD+BR) completa.

Con el fin de aplicar eficazmente este nuevo enfoque a nuestro problema concreto, consideramos ocho variables de entrada: las variables utilizadas en el SBRD inicial. Para mayor detalle el lector puede consultar el trabajo presentado en [3], donde se describe por completo la extracción

de las variables. Como complemento al conjunto inicial de variables, se extraen tres nuevas variables que representan el color especial de láser (rojo, verde y azul). El sistema utiliza una variable de salida para denotar si la información analizada corresponde o no a un punto láser. A este nuevo enfoque del SBRD inicial, utilizando el aprendizaje de reglas y al AG lo llamaremos $SBRD_{apr-AG}$, que en combinación con la técnica de TM da paso a un nuevo sistema híbrido, $TM + SBRD_{apr-AG}$.

De esta manera, se presenta un algoritmo de aprendizaje de la BC que puede administrar eficientemente el espacio de búsqueda. El esquema de aprendizaje se presenta en la siguiente subsección, donde se introduce un modelo de representación de la BD, lo que disminuye el espacio de búsqueda con respecto a las representaciones clásicas de las funciones de pertenencia triangulares. Finalmente, se presenta el AG para el aprendizaje del SBRD.

3.1 Esquema del SBRD basado en aprendizaje.

El aprendizaje de la BC a través del aprendizaje de la BD, es un enfoque reciente que implica un espacio de búsqueda más sencillo que el aprendizaje clásico de la BC. Consiste en la obtención de la BD y por separado una BR, basado en un aprendizaje [5, 12] (véase la figura 3). Esta forma de trabajar nos permite conocer el contexto más adecuado para cada partición difusa, que es necesaria en diferentes contextos de aplicación y modelos difusos de extracción de reglas.




Figura 3: Esquema de aprendizaje de la Base de Conocimiento.

El esquema de aprendizaje utilizado en este trabajo está compuesto por:

- ♦ Proceso para aprender la BD, que permite definir:
 - El número de etiquetas por cada variable lingüística.
 - El desplazamiento lateral de cada variable.

Se utilizan funciones de pertenencia triangulares debido a su simplicidad.

- ♦ Se utiliza un método *Ad-hoc* basado en datos para obtener la BR [13]. Este método se ejecuta para cada definición de la BD generada por el AG utilizado,

y por lo tanto, permite que el proceso de aprendizaje híbrido propuesto obtenga finalmente la definición de la BC (BD y BR) por medio de la acción cooperativa de ambos métodos.

3.2 Representación del modelo lingüístico de 2-Tuplas.

El modelo de representación lingüístico de 2-Tuplas introducido en [7] permite un desplazamiento lateral del soporte de una etiqueta y mantiene la interpretabilidad asociada al SBRD lingüístico obtenido. Este modelo incluye un nuevo enfoque basado en el concepto de translación simbólica, que permite desplazar lateralmente el soporte de las etiquetas considerando un único parámetro (pequeños desplazamientos a la izquierda/derecha de las funciones de pertenencia originales), con el objetivo de obtener etiquetas que contengan un conjunto de ejemplos con mejor cubrimiento (búsqueda de precisión) conservando su forma original, y reducir el espacio de búsqueda del proceso de ajuste respecto al ajuste clásico, que normalmente considera 3 parámetros en caso de funciones de pertenencia triangulares.

La translación simbólica de una etiqueta es un número (α) dentro del intervalo $[-0.5, 0.5]$, representando este intervalo el dominio de la etiqueta cuando ésta se mueve entre sus dos etiquetas laterales adyacentes (Ver figura 4). Consideremos un conjunto de etiquetas $S(S = \{s_1, s_2, \dots, s_n\})$ representando una partición difusa. Formalmente, para representar la translación simbólica de una etiqueta en S tenemos el par,

$$(s_i, \alpha_i), \quad s_i \in S, \quad \alpha_i \in [-0.5, 0.5].$$




Figura 4: Desplazamiento lateral de las etiquetas lingüísticas.

La figura 4 muestra el desplazamiento lateral de las diferentes etiquetas, siendo y_2 una nueva etiqueta que representa a la antigua M desplazada lateralmente, localizándose entre B y M .

3.3 Algoritmo Genético utilizado.

En este trabajo se utilizará CHC [6] para diseñar el algoritmo de aprendizaje. CHC es un AG que presenta un equilibrio entre exploración y explotación, usado para problemas de espacio de búsqueda complejos. Considerando este enfoque, el proceso de aprendizaje de la BD debe ser definido

como: la granularidad de la particiones lingüísticas y los desplazamientos laterales de las funciones de pertenencia.

3.3.1 Codificación de la Base de Datos.

La *granularidad* y los *parámetros de traslación* se representan por $C = C_1 + C_2$, donde:

- C_1 (Número de etiquetas): Vector de tamaño N (siendo N el número de variables del sistema). El conjunto de etiquetas se encuentra entre $\{3, \dots, 9\}$:

$$C_1 = (L^1, \dots, L^N) .$$

- C_2 (Desplazamiento lateral): Vector de números reales de tamaño $N * 9$ (N variables con un máximo de 9 etiquetas por variable). Si un cromosoma no tiene el número máximo de etiquetas en una variable, el espacio reservado sobrante es ignorado en el proceso de evaluación. Por ello, la parte C_2 tiene la siguiente estructura:

$$C_2 = (\alpha_1^1, \dots, \alpha_{L^1}^1, \dots, \alpha_1^N, \dots, \alpha_{L^N}^N)$$

3.3.2 Evaluación del cromosoma.

Para evaluar un determinado cromosoma se aplicará el método de Wang y Mendel [13] para obtener la BR. Una vez obtenida la BC (BD + BR) completa se trata de minimizar la función:

$$F_C = w_1 \cdot FE + w_2 \cdot NR,$$

donde:

- NR es el número de reglas obtenidas, penalizando un exceso de reglas.
- $w_1 = 1$.
- w_2 es un factor del Error Cuadrático Medio (ECM) y NR obtenido por el modelo, que se obtendría fijando el número máximo de etiquetas a 9 sin considerar los parámetros de desplazamiento.

$$w_2 = \alpha \cdot \frac{ECM_{max-etq}}{NR_{max-etq}} ,$$

siendo α un porcentaje fijado por un experto que determina el equilibrio entre precisión y complejidad. Se utilizan valores mayores a 1.0 para modelos con pocas reglas y valores menores que 1.0 para modelos con gran precisión. En este problema utilizamos $\alpha = 1.15$.

- FE es la Función de Evaluación utilizada para analizar el número de falsos negativos (FN) y falsos positivos (FP) obtenidos con la BC generada,

$$FE = \frac{|FN|}{|D|} + 10 \cdot \frac{|FP|}{|D|}$$

donde $|FN|$ es el número de falsos negativos, $|FP|$ número de falsos positivos y $|D|$ tamaño del conjunto de datos.

Para cada ejemplo, el SBRD debe generar un valor en el intervalo $[0, 1]$. Si ese valor es mayor a 0.5, el ejemplo se considera como punto láser, en caso contrario como imagen sin punto láser, nos podemos encontrar las siguientes situaciones:

- FN: Si el ejemplo es clasificado como imagen sin láser pero realmente es una imagen con láser.
- FP: Si el ejemplo es clasificado como imagen con láser pero realmente es una imagen sin láser.
- Acierto: El ejemplo está bien clasificado.

4 Resultados.

Para evaluar la eficacia de la propuesta presentada en este trabajo, hemos considerado el sistema de control de entorno por medio de un apuntador láser presentado en [2]. A su vez, para demostrar la eficacia y mejora en los resultados del sistema presentado en [4] junto con el actual, se ha ampliado la base de ejemplos de 105 imágenes usadas en [4] a un conjunto de 990 imágenes. Este nuevo conjunto ha sido dividido aleatoriamente en 5 subconjuntos, con el 20% de las imágenes para cada uno de ellos. Una vez creado los subconjuntos se ha utilizado la técnica de *5-fold cross-validation* para obtener los resultados de los diferentes sistemas, utilizando en cada iteración del método un total de 792 imágenes de entrenamiento y 198 de test.

La tabla 1 presenta una descripción de los métodos estudiados en este trabajo.

Los parámetros utilizados por los diferentes algoritmos $TM + SBRD_{experto}$ y $TM + SBRD_{ajustado-AG}$ fueron seleccionados de acuerdo con las recomendaciones de los autores utilizadas en [3] y [4]. Por último, el número de evaluaciones utilizadas por el AG en el proceso de ajuste para el algoritmo $TM + SBRD_{ajustado-AG}$ fué de 50.000. Los valores de entrada de los parámetros utilizados en este trabajo son los siguientes:

- Evaluaciones = 50.000
- Tamaño de la población = 50
- Bits por gen = 30
- Factor $\alpha = 1.15$

La tabla 2 presenta los resultados medios del algoritmo $TM + UD$ utilizando el nuevo conjunto de 990 imágenes con una configuración inicial similar a la presentada en [2]. Igualmente, se muestran los resultados medios de los sistemas $TM + SBRD_{experto}$ y $TM + SBRD_{ajustado-AG}$ con

Tabla 1: Técnicas utilizadas en los experimentos.

Ref	Método	Año	Descripción
[2]	$TM + UD$	2008	Template Matching más Umbralización Dinámica
[3]	$TM + SBRD_{experto}$	2010	Template Matching más SBRD diseñado por experto
[4]	$TM + SBRD_{ajustado-AG}$	2010	Template Matching más SBRD diseñado por experto y ajustado por AG
Nuestra propuesta	$TM + SBRD_{apr-AG}$		Template Matching más SBRD basado en aprendizaje

los parámetros utilizados en los trabajos [3] y [4] respectivamente. Podemos observar que las técnicas clásicas como $TM + UD$ tienen mejores resultados que los algoritmos que utilizan un SBRD como $TM + SBRD_{experto}$ y $TM + SBRD_{ajustado-AG}$ utilizando el nuevo y más completo conjunto de imágenes. Ésto se debe a que los sistemas clásicos trabajan con datos heterogéneos tales como brillo y luminosidad de la imagen, sin embargo, el SBRD trabaja con datos con la forma y apariencia de la imagen, tales como similitud a un círculo, entre otros. Este tipo de datos es muy útil cuando se trabaja con algoritmos basados en aprendizaje. Por esta razón, se han combinado técnicas clásicas TM junto con algoritmos de aprendizaje, obteniendo una nueva hibridación llamada $TM + SBRD_{apr-AG}$. Los resultados de este nuevo algoritmo son los mejores que se obtienen para la serie de experimentos presentados en este trabajo, como puede verse en la tabla 3.

Podemos observar que el porcentaje de aciertos en imágenes con punto láser es del 70,50% y en imágenes sin punto láser es de 98,76%, muy cercano al porcentaje óptimo del sistema que sería el 100%.

5 Conclusiones.

En este trabajo se presenta un nuevo modelo híbrido que combina técnicas clásicas como *Template Matching* junto con aprendizaje evolutivo de SBRD para la detección de puntos láser en un sistema de control de entorno. Gracias a este tipo de sistemas, junto con un sistema de control domótico de viviendas, se obtiene un sistema de interacción amigable y fácil de utilizar, así como barato.

El trabajo recoge un estudio completo donde se compara la eficacia de algoritmos que utilizan técnicas clásicas presentados en trabajos anteriores, con los nuevos algoritmos híbridos que combinan técnicas clásicas y aprendizaje evolutivo de SBRDs. Para este estudio se considera un conjunto de datos de 990 imágenes que simula una situación real del sistema de control, donde recogen las diferentes situaciones de luz y distancia que se puede dar en un hogar convencional. Podemos ver que el algoritmo propuesto obtiene mejores resultados que los anteriores, pero el dato más significativo es que este nuevo sistema obtiene una tasa de aciertos del 98,76% en imágenes sin punto láser, reduciendo de esta forma los falsos positivos, tan perjudiciales para el sistema, hasta el porcentaje ideal del 100%.

El nuevo enfoque presentado en este trabajo es particularmente útil para actuar a distancia sobre los dispositivos de una vivienda estándar. Por otra parte, creemos que los resultados muestran una utilidad añadida en la industria, tal como el uso de dispositivos en entornos donde no son fácilmente accesibles, ya que con el puntero láser podrán ser controlados a distancia.

Agradecimientos.

Este trabajo ha sido subvencionado por el proyecto TIN2008-06681-C06-01 del Ministerio de Educación y Ciencia y la Consejería de Economía-Comercio e Innovación de la Junta de Extremadura, bajo el proyecto GRU09105.

Referencias

- [1] Chan M., Estève D., Escriba C. and Campo E., A review of smart homes-present state and future challenges, *Computer Methods and Programs in Biomedicine*, vol. 91, no. 1, pp. 55–81, 2008.
- [2] Chávez F., Fernández F., Olague G. and Llano J., An independent and non-intrusive laser pointer environment control device system, *Proceedings of the 5th international conference on Pervasive services (ICPS'08)*. Sorrento, Italy: ACM, pp. 37–46, 2008.
- [3] Chávez F., Fernández F., Alcalá R., Alcalá-Fdez j., Olague G. and Herrera F., Hybrid laser pointer detection algorithm based on template matching and fuzzy rule-based systems for domotic control in real home environments, *Applied Intelligence*, pp. 1–17, 10.1007/s10489-010-0268-6, 2010.
- [4] Chávez F., Fernández F., Alcalá-Fdez J., Alcalá R., Herrera F. and Olague G., Genetic tuning of a laser pointer environment control device system for handicapped people with fuzzy systems, *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2010)*, pp. 1–8, 2010.
- [5] Cerdón O., Herrera F., Magdalena L. and Villar P., A genetic learning process for the scaling factors, granularity and contexts of the fuzzy rule-based system data base, *Information Sciences*, vol. 136, pp. 85–107, 2001.

Tabla 2: Resultados de $TM + UD$

Resultados medios de $TM + UD$				
	Entrenamiento		Test	
	Media	Desviación Estándar	Media	Desviación Estándar
Aciertos Generales	83,48 %	0,01206	83,54 %	0,04705
Tasa de acierto con Punto Láser	67,86 %	0,01575	68,13 %	0,05705
Tasa de acierto sin Punto Láser	98,32 %	0,00481	98,36 %	0,01647
Resultados medios de $TM + SBRD_{experto}$				
	Entrenamiento		Test	
	Media	Desviación Estándar	Media	Desviación Estándar
Aciertos Generales	78,59 %	0,01229	78,59 %	0,04917
Tasa de acierto con Punto Láser	66,21 %	0,01845	66,52 %	0,06770
Tasa de acierto sin Punto Láser	90,35 %	0,00821	90,30 %	0,03226
Resultados medios de $TM + SBRD_{ajustado-AG}$				
	Entrenamiento		Test	
	Media	Desviación Estándar	Media	Desviación Estándar
Aciertos Generales	75,80 %	1,81965	74,97 %	5,03560
Tasa de acierto con Punto Láser	51,44 %	3,59527	50,51 %	6,84627
Tasa de acierto sin Punto Láser	98,91 %	0,33398	98,35 %	1,34530

Tabla 3: Resultados de $TM + SBRD_{apr-AG}$

	Entrenamiento		Test	
	Media	Desviación Estándar	Media	Desviación Estándar
Aciertos Generales	87,27 %	0,78990	84,92 %	2,90425
Tasa de acierto con Punto Láser	73,87 %	1,28823	70,50 %	4,48146
Tasa de acierto sin Punto Láser	100 %	0,00000	98,76 %	1,14364

- [6] Eshelman L., The chc adaptive search algorithm: How to have safe serach when engaging in nontraditional genetic recombination, *Foundations of genetic Algorithms*, vol. 1, pp. 265–283, 1991.
- [7] Herrera F. and Martínez L., A 2-tuple fuzzy linguistic representation model for computing with words, *IEEE Transactions on Fuzzy Systems*, vol. 8, pp. 746–752, 1999.
- [8] Herrera F., Lozano M. and Sánchez A.M., A taxonomy for the crossover operator for real-coded genetic algorithms: An experimental study, *International Journal of Intelligent Systems*, vol. 18, pp. 309–338, 2003.
- [9] Kemp C. et al., A point-and-click interface for the real world: laser designation of objects for mobile manipulation, *Proceedings of the 3rd ACM/IEEE international conference on Human robot interaction (HRI'08)*, pp. 241–248, 2008.
- [10] Kim N. W., Lee S. J., Lee B. G. and Lee J. J., Vision based laser pointer interaction for flexible screens, *Human-Computer Interaction. Interaction Platforms and Techniques, Lecture Notes in Computer Science*, vol. 4551, pp. 845–853, 2007.
- [11] KNX/EIB, <http://www.knx.org>.
- [12] Teng Y. W. and Wang W. J., Constructing a user-friendly ga-based fuzzy system directly from numerical data, *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 34, no. 5, pp. 2060–2070, 2004.
- [13] Wang L. X. and Mendel J. M., Generating fuzzy rules by learning from examples, *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 22, no. 6, pp. 1414–1427, 1992.
- [14] Zadeh L., Outline of a new approach to the analysis of complex systems and decision processes, *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, pp. 28–44, 1973.
- [15] Zhang L., Shi Y., and Chen J., Drag and drop by laser pointer: Seamless interaction with multiple large displays, *Ubiquitous Intelligence and Computing, Lecture Notes in Computer Science*, vol. 4159, pp. 12–20, 2006.