

Extracción de características para reconocimiento visual.

M.A. Vicente, C. Fernández, R. Puerto, A. Gil
Universidad Miguel Hernández

División Ingeniería de Sistemas y Automática
Departamento de Ingeniería de Sistemas Industriales, Campus de Elche
Avda. de la Universidad s/n 03202 Elche (Alicante) España
suni@umh.es

Resumen

Se presenta una comparativa del funcionamiento de dos técnicas de extracción de características (PCA/ICA) en la tarea de reconocimiento visual de objetos. Además para cada método se analiza el funcionamiento de dos tipos de subespacios: universal y objeto. La comparativa se realiza utilizando distintos clasificadores y mediante un índice de separabilidad trivial entre clases.

Palabras Clave: PCA, ICA, reconocimiento de objetos

1 INTRODUCCIÓN MOTIVACIÓN

El reconocimiento de objetos es una tarea fundamental en cualquier sistema de visión por computador. El reconocimiento de objetos reales tridimensionales en escenarios controlados es sencillo si la segmentación es factible y se dispone de modelo visuales 3D de los objetos [12][7]. Sin embargo, en escenarios no estructurados es inviable aplicar tales técnicas basadas en modelo debido a la dificultad de segmentar adecuadamente el objeto de la escena. Las técnicas de reconocimiento de objetos basadas en la apariencia son una alternativa a las técnicas basadas en modelo cuando la obtención de modelos geométricos de los objetos no es posible, y cuando estos se hallan en escenarios no controlados.

Los primeros sistemas de reconocimiento basados en la apariencia utilizaron el análisis de componentes principales (PCA) como técnica de extracción de características para reducir la dimensión de los modelos o clases de los objetos [9][13], recientemente algunos autores prefieren utilizar como método de extracción de características el análisis de componentes independientes (ICA) [3][4]. Este artículo presenta los resultados obtenidos tras

comparar el rendimiento de ambas técnicas de extracción de características en el ámbito del reconocimiento visual de objetos. Estos métodos son también utilizados con frecuencia en el reconocimiento de caras, existiendo en la literatura conclusiones contradictorias al respecto [5].

En [9] se resuelve el problema de la generación automática de modelos visuales basados en la apariencia de los objetos para su posterior reconocimiento y localización de su pose mediante el uso de PCA. Así, los objetos se modelan mediante su proyección en dos tipos de eigenespacios diferentes: el *eigenespacio universal*, que se obtiene utilizando un conjunto de imágenes de todos los objetos de interés, y el *eigenespacio objeto*, que se calcula a partir de imágenes pertenecientes a un mismo objeto. En [9] el eigenespacio universal se utiliza para discriminar entre objetos mientras que el eigenespacio objeto se utiliza para estimar la pose del objeto, sin embargo, los eigenespacios objeto también pueden utilizarse para el reconocimiento aunque necesiten de clasificadores más complejos. Para realizar la comparativa entre PCA/ICA se utiliza la estructura del sistema de reconocimiento de Murase utilizando los objetos de la librería COIL-100 [10]. Los resultados obtenidos demuestran claramente como ICA supera a PCA si se utilizan subespacios objeto para la tarea de reconocimiento. La razón puede encontrarse en la capacidad de separación entre clases de ICA establecida por Bressan [4].

2 RECONOCIMIENTO DE OBJETOS A PARTIR DE SU APARIENCIA VISUAL

La apariencia de un objeto 3D en una imagen 2D depende de su forma, color, su pose en la escena global, sus propiedades reflectivas y las características de la iluminación. La imagen de un objeto puede considerarse como un vector de píxeles




Figura 1: Las imágenes de los objetos son puntos en el espacio multidimensional N^2

donde el valor de cada componente del vector es el valor en escala de grises (u otro canal de color) correspondiente al píxel. Así, una imagen $N \times N$ constituye un vector de dimensión N^2 . De esta manera, la imagen está situada en un espacio N -dimensional, donde N es el número de píxeles de la imagen (y la longitud del vector). Esta representación vectorial de la imagen se considera el espacio original de la imagen (ver figura 1). El espacio original de una imagen es uno solo de los muchos espacios en los que puede examinarse una imagen. En los sistemas basados en la apariencia, la imagen completa del objeto se proyecta en un espacio de menor dimensión que el original para así reducir el tamaño del vector representativo del objeto, la técnica o el subespacio utilizado con más frecuencia es el creado por los eigenvectores de la matriz de covarianza de la imágenes de entrenamiento de los objetos (PCA [9],[13]), el creado por los vectores obtenidos mediante un análisis LDA (discriminantes de Fisher, [6]) o el creado mediante técnicas de ICA ([8]).

2.1 SUBESPACIOS OBJETO

Cada uno de los objetos puede representarse utilizando su proyección en el subespacio objeto. Este subespacio es construido a partir de un conjunto de imágenes del mismo objeto en diferentes poses o vistas. El conjunto de M imágenes de entrenamiento, \vec{x}_m , constituye el grupo G_j :

$$G_j = \{\vec{x}_1, \vec{x}_2, \dots, \vec{x}_M\} \quad (1)$$

y existirán tantos conjuntos como diferentes objetos sean los que utilice el sistema de reconocimiento.

Con \vec{x}_m , se denota el vector imagen que agrupa las matrices de color de la imagen original:

$$\vec{x}_m = \begin{pmatrix} X_R \\ X_G \\ X_B \end{pmatrix} \quad (2)$$

La figura 2 muestra un posible conjunto de entrenamiento para el objeto nº 14 de la COIL-100. Cada imagen, \vec{x}_m , del conjunto de entrenamiento es filtrada por el canal de características seleccionado para representar la apariencia del objeto:

$$\vec{f}_m = F_{channel}(\vec{x}_m) \quad (3)$$

Algunos canales de características típicos son [1]: la imagen en un espacio de color modificado, el histograma de la imagen, la imagen de bordes o áreas especiales de la imagen agrupadas en ventanas [3][11]. Una vez seleccionado el canal de características, el nuevo conjunto de M vectores de entrenamiento G_j' se define mediante la expresión:

$$G_j' = \{\vec{f}_1, \vec{f}_2, \dots, \vec{f}_M\} \quad (4)$$

El subespacio objeto, W , se calcula a partir de G_j' para cada objeto j , extrayendo las componentes principales (PC) o las componentes independientes (IC). A continuación, todas las imágenes de



Figura 2: Un ejemplo de conjunto de enterramiento del objeto 14 de la COIL-100




Figura 3: Trayectoria del objeto 14 en un subespacio objeto utilizando PCA

entrenamiento son proyectadas en su propio subespacio objeto, generando un vector multidimensional de menor número de componentes y que representa la trayectoria del objeto en función de su vista (rotación) en el espacio multidimensional de características seleccionado. Cada una de estas proyecciones se obtiene mediante:

$$\vec{p}_m = W \cdot \vec{f}_m \quad (5)$$

donde W es la matriz que agrupa a las PC's o IC's de cada objeto.

En la figura 3 se muestra una trayectoria en el subespacio objeto del objeto n° 14, utilizando sólo 3 dimensiones.

2.2 SUBESPACIO UNIVERSAL

El subespacio universal se obtiene a partir de un conjunto de entrenamiento de imágenes pertenecientes a objetos diferentes. El conjunto de J imágenes de entrenamiento se define por U :

$$U = \{ \vec{f}_1, \vec{f}_2, \dots, \vec{f}_j \} \quad (6)$$

El subespacio universal, W , se genera también mediante extracción de PCs o ICs. Pero en este caso solo hay un subespacio para todas las imágenes. Por lo tanto, el modelo de cada objeto se compone de sus vistas proyectadas en el subespacio universal.

3 EXTRACCIÓN DE CARACTERÍSTICAS UTILIZANDO TRANSFORMACIONES LINEALES

3.1 PCA

El eigenspacio o subespacio PCA se obtiene calculando los eigenvectores de la matriz de covarianzas creada con los vectores de las imágenes de entrenamiento. Los eigenvectores correspondientes a eigenvalores no nulos de la matriz de covarianzas forman una base ortonormal donde los vectores de entrenamiento originales (de tamaño N^2) son proyectados reduciendo su dimensión original ($M \ll N^2$). Luego en la técnica de PCA, W es la matriz que contiene los eigenvectores no nulos. En el presente trabajo se ha utilizado el método *snapshot* [13] para calcular el eigenspacio.

PCA permite utilizar como modelo del objeto un vector de características de menor dimensión que el original. Un conjunto reducido (las clases obtenidas de las imágenes de entrenamiento) es más fácil de analizar e interpretar que las variables originales (las imágenes de entrenamiento propias).

3.2 ICA

El análisis de componentes independientes de un vector aleatorio multidimensional N^2 es una transformación lineal que minimiza la dependencia estadística entre sus componentes. Este tipo de análisis tiene una gran variedad de aplicaciones como el análisis y la compresión de datos multivariantes, la

separación ciega de fuentes, la eliminación de ruido, etc.

Si el vector aleatorio que se desea representar mediante ICA no tiene ruido y esta centrado, el modelo ICA puede expresarse como:

$$\vec{x} = A \cdot \vec{s} \quad (7)$$

donde \vec{x} es el vector aleatorio que representa nuestros datos (vector de características de la imagen), \vec{s} es el vector de componentes independientes de dimensión $M \leq N^2$, y A es la matriz mezcla. La pseudoinversa de A , representada por W , se denomina la matriz proyección y proporciona una manera alternativa de representar el modelo ICA:

$$W \cdot \vec{x} = \vec{s} \quad (8)$$

Para la estimación de la matriz de proyección se han propuesto diferentes funciones de coste como no-gaussianidad, máxima verosimilitud, información mutua y métodos tensoriales. En este trabajo se ha utilizado el algoritmo FastICA [8], que recibe su nombre por la rapidez con que trabaja, mucho mayor que otros algoritmos de ICA.

4 RESULTADOS EXPERIMENTALES

Para realizar una comparativa detallada de la separación entre clases (u objetos) en cada uno de los dos tipos de subespacios y los dos métodos de extracción de características se han utilizado diversos clasificadores típicos y además se ha definido un índice de separabilidad de clases trivial que representa el grado de separación de una cierta clase y se puede expresar como:

$$ratio_a_j = \log \left[\frac{\max(d_j)}{\min(D_j)} \right] \quad (9)$$

donde $ratio_a_j$ es el índice de separabilidad para la clase j , d_j es la distancia euclídea entre dos vectores pertenecientes a la misma clase j (distancias entre elementos de la misma clase) y D_j es la distancia euclídea entre dos vectores pertenecientes a clases diferentes, (solo uno de ellos pertenece a la clase j). Valores altos de a_j representan clases separables con facilidad, y particularmente, cuando a_j es mayor que 0, las clases pueden separarse con cualquier clasificador lineal.




Figura 4: Representación bidimensional del índice de separabilidad trivial

y a partir de la ecuación anterior también se puede utilizar otro índice de separabilidad menos restrictivo utilizando las medias de las clases:

$$ratio_b_j = \log \left[\frac{\text{media}(d_j)}{\text{media}(D_j)} \right] \quad (10)$$

4.1 COMPARATIVA CON SUBESPACIOS UNIVERSALES

Para obtener una comparativa del funcionamiento de PCA e ICA con subespacios universales se calcularon diversos subespacios utilizando la vista principal de cada uno de los objetos con conjuntos de objetos diferentes (desde 10 a 100 objetos de la COIL-100) y utilizando diversos canales de características (color, forma, textura y apariencia) descritos con detalle en [16]. El resto de las vistas se utilizaron como ejemplos de test y el clasificador utilizado fue el vecino más cercano (k-NN con k=1 y la norma L2 como medida de distancia).

En las figuras 5 y 6 se muestra un resumen de los resultados experimentales de ambos métodos de extracción de características con subespacios universales utilizando el canal de apariencia I (imagen en niveles de gris): se aprecia que ambas técnicas funcionan de manera muy similar. En la figura 5 aparece la tasa de éxito en el reconocimiento utilizando PCA e ICA frente al número de objetos presentes en el sistema de reconocimiento y utilizando sólo 10 componentes para representar cada subespacio. Según aumenta el número de objetos, se reduce el porcentaje de éxito en la clasificación para ambas técnicas. En la figura 6 se muestra la influencia del número de componentes (dimensión) del subespacio en el reconocimiento correcto de los objetos utilizando un conjunto de 20 objetos y variando la dimensión del subespacio de 2 a 20 componentes. Tal como se esperaba, el porcentaje de aciertos en el reconocimiento se incrementa

conforme aumenta la dimensión del subespacio universal. Experimentos similares con conjuntos de objetos mayores (hasta 100 objetos) y empleando el resto de canales muestran resultados similares.




Figura 5: Eigenespacios universales (canal I): tasa de éxito en el reconocimiento para PCA e ICA utilizando solo 10 componentes




Figura 6: Eigenespacios universales (canal I): tasa de éxito en el reconocimiento para PCA e ICA en relación con el número de componentes del subespacio

Los subespacios universales funcionan de manera excepcional con objetos simétricos, es decir, aquellos cuyas vistas o poses son muy parecidas entre sí; pero no funcionan tan bien con objetos con asimetrías importantes en sus vistas. Este fenómeno se muestra en las figuras 7 y 8: los objetos simétricos tienen una tasa de éxito en el reconocimiento del 100% en ambas técnicas de extracción de características, mientras que los objetos no-simétricos se confunden

totalmente. En estas gráficas también es posible apreciar que ICA funciona ligeramente peor que PCA, pues hay 26 objetos simétricos (100%) con PCA y sólo 21 con ICA.




Figura 7: Objetos simétricos con PCA: {2, 4, 5, 18, 24, 25, 26, 30, 32, 33, 34, 35, 47, 50, 56, 58, 61, 64, 70, 72, 83, 86, 87, 88, 94, 95}

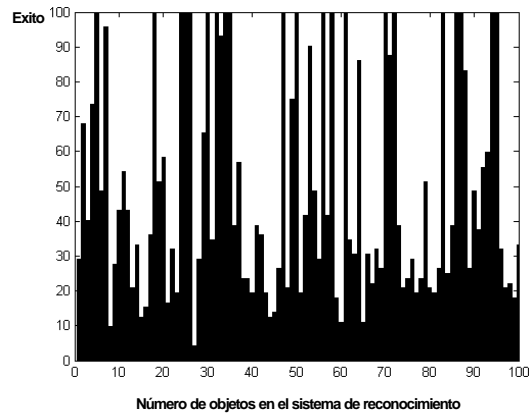


Figura 8: Objetos simétricos con ICA: {5, 18, 24, 25, 26, 30, 32, 34, 35, 47, 50, 56, 58, 61, 70, 72, 83, 86, 87, 94, 95}

En las figuras 9 y 10 se muestran los errores (en %) en el reconocimiento para 4 objetos simétricos y 4 no-simétricos de la COIL-100 en función del tamaño total del sistema (número de objetos a reconocer), se puede apreciar como el error en el reconocimiento para los objetos simétricos es casi nulo e independiente del tamaño del sistema, mientras que para los objetos no-simétricos, el error aumenta conforme aumenta el número total de objetos en el sistema, pues existe mayor posibilidad de confusión

entre los objetos. También se aprecia como el método de ICA funciona ligeramente peor que PCA.

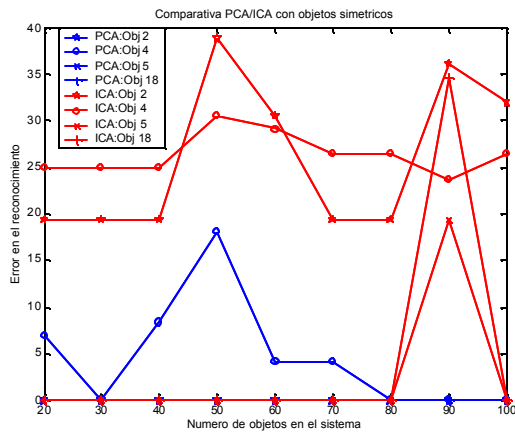


Figura 9: Eigenespacios universales: error (%) en el reconocimiento para PCA e ICA para 4 objetos simétricos

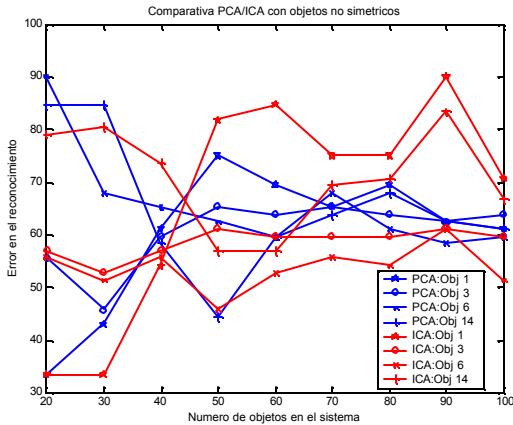


Figura 10: Eigenespacios universales: error (%) en el reconocimiento para PCA e ICA para 4 objetos no-simétricos

Los resultados de separabilidad entre clases (también sólo para el canal I) se resumen en las figuras 11 y 12: PCA e ICA producen clases con separabilidad muy semejante. En la figura 11 se utiliza el $ratio_{a_j}$ para estudiar la separación entre clases, en este caso sólo los objetos 5, 7 y 18 están separados del resto, de forma que cualquier clasificador simple los identificaría sin gran dificultad. Si utilizamos las medias de las clases, $ratio_{b_j}$, la separación intraclasses mejora, como se muestra en la figura 12.

Estas tasas de reconocimiento tan similares para las dos técnicas son debidas a que en la representación mediante ICA, la reducción en la dimensionalidad se obtiene utilizando PCA como un paso de preprocesado previo (blanqueo) al algoritmo de FastICA que busca luego la independencia estadística de los datos, y en el caso del subespacio universal

esto no tiene porqué mejorar los resultados obtenidos con PCA.

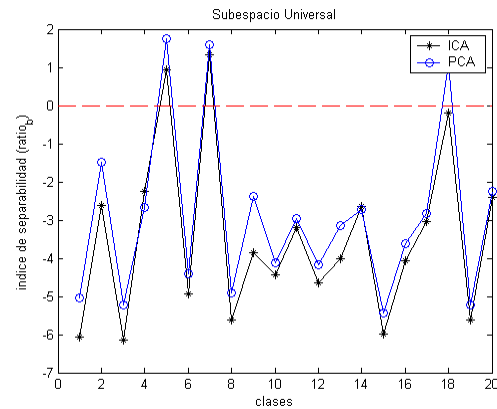


Figura 11: Eigenespacios universales: Índice de separabilidad trivial, $ratio_{a_j}$ para PCA e ICA con los 20 primeros objetos de la COIL-100

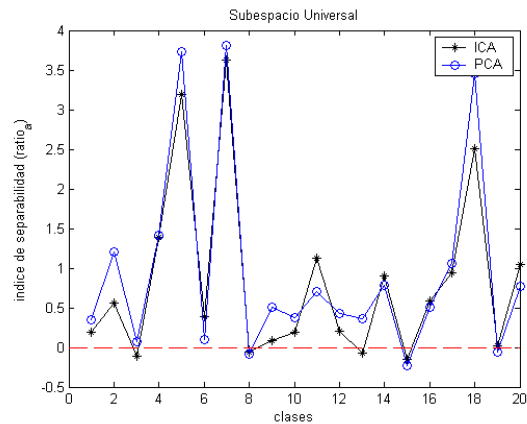


Figura 12: Eigenespacios universales: Índice de separabilidad trivial medio, $ratio_{b_j}$ para PCA e ICA con los 20 primeros objetos de la COIL-100

A modo de conclusión, se puede afirmar que los subespacios universales utilizados junto a una medida de distancia como clasificador pueden ser utilizados para reconocer objetos muy simétricos o que siempre muestren la misma vista a la cámara. Los subespacios universales se utilizan con frecuencia en sistemas de reconocimiento de caras humanas cuando se utilizan vistas frontales de las caras (*mugshots*) como imágenes de entrenamiento.

Si se emplea un clasificador más complejo que el utilizado en esta comparativa, las tasas de éxito pueden mejorarse incluso para los objetos no-simétricos, sin embargo, esto requiere utilizar más vistas durante la fase de entrenamiento del sistema de visión [15].




Figura 13: Valores de las proyecciones ICA sobre un subespacio de 10 componentes. Se aprecia el sparse code: todas las componentes son casi nulas salvo una.




Figura 14: Valores de las proyecciones PCA sobre un subespacio de 10 componentes. Se puede ver como las componentes están ordenadas de mayor a menor varianza

4.2 COMPARATIVA CON SUBESPACIOS OBJETO

Murase en [9] utiliza los subespacios objeto generados con PCA para averiguar la pose o vista del objeto y no para su identificación o reconocimiento, sin embargo, los subespacios objeto también se pueden utilizar para la identificación del objeto en sí como se describe en [14]. Además, en este caso, si se utiliza ICA como método de extracción de características, la técnica del subespacio objeto supera al método de los subespacios universales debido a que las trayectorias ICA de cada clase están más separadas entre sí. La razón puede hallarse en la relación existente entre el sparse code e ICA: el sparse code es una codificación de la información en

la que sólo una cuantas componentes del código están activas (no son nulas). En la figura 13 se observa este fenómeno del sparse code en las trayectorias generadas con ICA (cada objeto dispara una componente, mientras que las restantes son casi nulas). Las trayectorias PCA no presentan este tipo de codificación, sino que codifican la información de manera que las componentes están ordenadas en orden decreciente a la variancia de las imágenes de entrenamiento, como se puede ver en la figura 14.

La figura 15 muestra el índice de separabilidad trivial para todos los objetos (clases) de la COIL-100 utilizando subespacios objeto con el canal I: la mayoría de las clases con ICA están muy cerca o incluso sobrepasan el valor de separación trivial de $a_j = 0$. Sin embargo, en el caso de PCA, la mayoría de los objetos están por debajo de este valor, lo que significa que no es tan sencillo su separación. Este hecho se muestra de nuevo en los gráficos de las figuras 16 y 17, que muestran los valores del índice de separabilidad trivial en función del número de imágenes utilizadas en la generación del subespacio (desde 2 a 24). Puede apreciarse como el índice de separabilidad es negativo para PCA con 24 imágenes de entrenamiento mientras que para ICA es siempre mayor y algunas clases son trivialmente separables con solo 4 componentes.




Figura 15: Índice de separabilidad para los subespacios objeto (canal I) PCA e ICA para la librería de objetos completa. Los subespacios se han obtenido utilizando solo 8 imágenes de entrenamiento por objeto.




Figura 16: Índice de separabilidad para los subespacios objeto (canal I) PCA de los 20 primeros objetos de la COIL100 utilizando trayectorias de diferentes dimensiones (desde 2 a 24 componentes)




Figura 19: Índice de separabilidad para los subespacios objeto (canal de canal de color histograma RGB) ICA de los 20 primeros objetos de la COIL100 utilizando trayectorias de diferentes dimensiones (desde 2 a 24 componentes)




Figura 17: Índice de separabilidad para los subespacios objeto (canal I) ICA de los 20 primeros objetos de la COIL100 utilizando trayectorias de diferentes dimensiones (desde 2 a 24 componentes)




Figura 18: Índice de separabilidad para los subespacios objeto (canal de color histograma RGB) PCA de los 20 primeros objetos de la COIL100 utilizando trayectorias de diferentes dimensiones (desde 2 a 24 componentes)

Por último, las figuras 18 y 19 recogen los valores del índice de separabilidad trivial en función del número de imágenes utilizadas en la generación del subespacio haciendo uso de otro canal de características, en concreto el histograma RGB de las imágenes. Para este canal, los objetos no están tan claramente separados como en el caso del canal I, pero sigue ocurriendo que el método de extracción ICA proporciona mejores resultados que PCA. Con el resto de canales utilizados se obtienen resultados similares.

5 CONCLUSIONES

De este trabajo se obtienen dos conclusiones principales:

- La técnica del subespacio universal con un clasificador basado en distancia es sólo aplicable a objetos simétricos u objetos que siempre muestran la misma vista o pose a la cámara del sistema de visión. En este escenario ICA no mejora los resultados de PCA.
- La técnica del subespacio objeto proporciona mejores resultados utilizando ICA como método de extracción de características. ICA produce un modelo reducido del objeto con codificación sparse; además la separación entre clases (objetos) es más relevante que con PCA, incluso con muy pocas componentes.

APÉNDICE: LIBRERÍA COIL -100

La librería COIL-100 [10] está formada por 7200 imágenes en color de 100 objetos reales (72 imágenes/objeto) de apariencia, geometría y color diversos, y con propiedades diferentes de reflexión. Las imágenes han sido adquiridas de manera que entre dos imágenes consecutivas hay una rotación de 5° del objeto. Todas las imágenes tienen un tamaño de 128x128 y han sido previamente procesadas, así, además de la normalización de tamaño, se ha estirado el histograma de cada imagen para que el píxel más brillante corresponda al valor 65535 y las intensidades de los otros píxeles se han adaptado según este escalado. El formato de fichero utilizado es el PPM (portable pix map) de 16 bit en color.

En este artículo se hace referencia a los objetos de la COIL-100 numerándolos de izquierda a derecha y de arriba a abajo, comenzando con el objeto de la esquina superior izquierda (caja rectangular amarilla).



Figura 20: Vistas individuales de cada uno de los objetos de la librería COIL-100

Referencias

- [1] Bartlett W.M., (1997) SEEMORE: Combining color, shape, and texture histogramming in a neurally-inspired approach to visual object recognition, *Neural Computation*, no. 9, pp. 777-804.
- [2] Biederman, I., (1995) Visual object recognition. In: S. F. Kosslyn and D. N. Osherson (Eds.). *An Invitation to Cognitive Science*, 2nd edition, Volume 2., Visual Cognition. MIT Press. Chapter 4, pp. 121-165.
- [3] Bressan M., Guillaumet D. and Vitrià J., (2003) Using an ICA representation of local color histograms for object recognition. *Pattern Recognition* 36(3), pp. 691-701 .
- [4] Bressan M. and Vitrià J., (2003) On the Selection and Classification of Independent Features, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 25 n.10, pp. 1312- 1317.
- [5] Draper B., Baek K., Bartlett M.S. and Beveridge R., (2003) Recognizing Faces with PCA and ICA, *Computer Vision and Image Understanding*, vol.91, pp. 115-137.
- [6] Fisher, R.A., (1936) The use of Multiple Measures in Taxonomic Problems. *Ann. Eugenics*, 7, pp. 179-188.
- [7] Hartley, R., Zisserman, A., (2000) *Multiple View Geometry in Computer Vision*, Cambridge University Press.
- [8] Hyvärinen A., Karhunen J., and Oja E. (2002) "Independent Component Analysis", Wiley-Interscience.
- [9] Murase H. and Nayar S., (1995) "Visual learning and recognition of 3D objects from appearance", *International Journal of Computer Vision*, no.14, pp. 5-24.
- [10] Nene S. A., Nayar S. K. and Murase H. (1996) "Columbia Object Image Library (COIL-100)", Technical Report CUCS006-96, <http://www1.cs.columbia.edu/CAVE/research/oflib/coil-100.html>.
- [11] Ohba K. and Ikeuchi K., (1997) Detectability, Uniqueness, and Reliability of EigenWindows for Stable Verification of Partially Occluded Objects. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 19 n. 19, pp. 1043-1048.
- [12] Tarel, J.P, Cooper, D.B., (2000) The Complex Representation of Algebraic Curves and Its Simple Exploitation for Pose Estimation and Invariant Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.22, No 7, pp. 663-647.
- [13] Turk M. and Pentland A., (1991) Eigenfaces for Recognition, *Journal of Cognitive Neuroscience*, vol. 3, no. 1, pp.71-86.
- [14] Vicente M.A., Reinoso O., García N., Sabater J.M., Fernández C., Jiménez L. (2002) Experiments with COIL database using PCA-

based Object Recognition Techniques, ISRA'2002 3rd International Symposium on Robotics and Automation.

- [15] Vicente M.A. , Reinoso O. , Fernández C., (2003) "Recognition and location of real objects using eigenimages and a neural network classifier", Proceedings of SPIE: Visual Communications and Image Processing, vol. 5150, pp. 385-392.
- [16] Vicente M.A., Fernández C., Reinoso O., (2004), "Identificación de objetos en entornos no estructurados utilizando técnicas basadas en la apariencia ", Actas de la Jornada de la Red Temática Redvision: Seguimiento e identificación de objetos mediante visión por computador, pp 29-38.