

Compensación NAP de variabilidad en sistemas de reconocimiento facial en entornos no controlados

Pedro Tome, Ruben Vera-Rodriguez and Julian Fierrez

Biometric Recognition Group-ATVS, EPS, Universidad Autónoma de Madrid,
C/ Francisco Tomás y Valiente 11, 28049 Madrid, España
{pedro.tome, ruben.vera, julian.fierrez}@uam.es

Resumen La variabilidad presente en ambientes sin restricciones representa uno de los desafíos abiertos en los sistemas automáticos de reconocimiento facial. Varias técnicas han sido propuestas en la literatura para hacer frente a esta problemática, la mayoría de ellas tratan de compensar una única fuente específica de variabilidad, por ejemplo, la iluminación o la pose. En este trabajo se presenta un esquema de compensación de variabilidad de carácter general basado en *Nuisance Attribute Projection* (NAP) que puede ser aplicado para compensar cualquier tipo de factor de variabilidad que afecte al rendimiento del reconocimiento facial. Nuestra técnica reduce la variabilidad intra-clase mediante la búsqueda de un subespacio de variabilidad de menor dimensionalidad. Este enfoque es evaluado sobre una base de datos del NIST de una competición de reconocimiento facial de imágenes estáticas llamada "*The Good, the Bad, and the Ugly*" (GBU). Los resultados obtenidos por nuestra implementación de un sistema del estado del arte basado en *Sparse Representation* han mejorado significativamente su rendimiento con la incorporación de nuestra técnica de compensación de variabilidad. Estos resultados también han sido comparados con los de la competición GBU, destacando los beneficios de un adecuado esquema de compensación de variabilidad en este tipo de entornos no controlados ¹.

1. Introducción

La mayoría de las tecnologías biométricas son capaces de proporcionar un funcionamiento satisfactorio en situaciones controladas donde el usuario es cooperativo y las condiciones de adquisición y el entorno pueden ser controlados. Sin embargo, en muchas aplicaciones, los datos biométricos son adquiridos en condiciones no ideales, como por ejemplo, los escenarios de reconocimiento facial sin

¹ Pedro Tome es financiado por una beca FPU del Univ. Autónoma de Madrid y Ruben Vera-Rodriguez es financiado por una beca Juan de la Cierva del Ministerio de Ciencia e Innovación. Este trabajo ha sido parcialmente financiado por los proyectos de Bio-Challenge (TEC2009-11186), Contexts (S2009/TIC-1485), TeraSense (CSD2008-00068) y la Cátedra UAM-Telefónica.

control y sin restricciones [5]. El bajo rendimiento de las tecnologías biométricas en estas situaciones relativamente incontrolada ha limitado su implementación, por lo tanto, una mejora significativa en el rendimiento en situaciones menos controladas es uno de los principales retos de las tecnologías biométricas.

En el caso particular de reconocimiento facial en escenarios no controlados existen numerosas fuentes de variación, que puede ser conocidas o desconocidas y que afectan al rendimiento. Por lo tanto, hay una necesidad de desarrollar métodos capaces de identificar y compensar/eliminar estas fuentes de variabilidad con el fin de garantizar la robusted del sistema en entornos reales sin restricciones y no controlados.

En este trabajo, se presenta un esquema de compensación de variabilidad basado en *Nuisance Attribute Projection* (NAP) aplicado a los sistemas de reconocimiento facial. En este campo, hasta donde sabemos sólo V. Štruc *et al.* en [13] ha aplicado técnicas de compensación basadas en NAP como una técnica de normalización de la iluminación para el reconocimiento facial, que elimina la iluminación inducida por artefactos en dos escenarios controlados. En nuestro caso, el enfoque de compensación NAP propuesto no sólo se utiliza para compensar las variaciones de iluminación, sino también otros factores de variabilidad presentes. En particular, se estudia el escenario no controlado presentado por la competición de caras estáticas NIST - GBU, que consta de tres particiones llamadas: *the Good*, *the Bad* y *the Ugly* [7].

El rendimiento del esquema de compensación de variabilidad propuesto es evaluado sobre un sistema del estado del arte basado en *Sparse Representation* [14]. Los resultados obtenidos muestran que la compensación de variabilidad usando NAP en combinación con este sistema es un enfoque muy interesante en entornos no controlados de reconocimiento facial.

El documento está estructurado de la siguiente manera. En la Sec. 2 se describen brevemente los factores de variabilidad encontrados en la competición GBU. La Sec. 3 describe el método de compensación de variabilidad usando NAP. En la Sec. 4 se describe el sistema de reconocimiento basado en *Sparse Representation*. La Sec. 5 presenta el protocolo experimental seguido de la evaluación del rendimiento del sistema. En la Sec. 6 se presentan los resultados experimentales obtenidos, y finalmente las conclusiones son resumidas en la Sec. 7.

2. Variabilidad en ambientes sin restricciones

El reconocimiento facial en ambientes sin restricciones es una problemática complicada que ha suscitado un interés creciente dentro la comunidad investigadora.

Algunos estudios recientes en este campo son las competiciones "*Multiple Biometric Grand Challenge*" (MBGC 2009) [6] y el "*Face Recognition Vendor Test*" (FRVT 2006) [8], cuyo enfoque de la investigación se está centrando en el reconocimiento facial en condiciones menos restringidas. Como resultado de la evolución de estas competiciones NIST se diseñó un nuevo desafío llamado GBU, que consiste en tres particiones denominadas *the Good*, *the Bad*, y *the Ugly*.

La partición *Good* consiste de pares de imágenes de caras de la misma persona que son fáciles de comparar (basándose en el rendimiento de los mejores sistemas de la competición FRVT 2006), la partición *Bad* contiene pares de imágenes de la cara de una persona que tienen dificultad media de comparación; y por último, la partición de *Ugly* está formada por las comparaciones más complicadas/difíciles de parejas de caras.

Varias técnicas han sido presentadas en la literatura para compensar la variabilidad presente en este tipo de escenarios [11,12,4,15]. Sin embargo, la mayoría de estas técnicas se centran en una única fuente de variabilidad aislada, por ejemplo, la iluminación, la compensación de la pose, etc.

En este trabajo, se presenta un enfoque de compensación de variabilidad usando *Nuisance Attribute Projection* (NAP) para eliminar la variabilidad inducida en los sistemas de reconocimiento facial no controlados.

3. NAP para compensación de la variabilidad

3.1. Nuisance Attribute Projection (NAP)

Nuisance Attribute Projection (NAP) es una poderosa herramienta utilizada tradicionalmente en el campo del reconocimiento de locutor para la compensación de los efectos de canal sin importar su fuente [9,10], que se suponen que se encuentran en un subespacio de variabilidad de pocas dimensiones. En otros campos como la biometría en escenarios a distancia y sin restricciones, las fuentes de variabilidad son en su mayoría desconocidas y se encuentran entremezcladas, por lo tanto, en este trabajo tratamos de comprender hasta qué punto las técnicas de compensación de variabilidad son útiles.

Considerando un conjunto de datos X de n vectores imagen de tamaño N píxeles, donde $X \in \mathfrak{R}^{n \times N}$. La técnica NAP trata de eliminar cualquier distorsión no deseada en las imágenes de la siguiente manera:

$$X' = P(XM), \quad (1)$$

donde X' indica los nuevos datos cuya componente en el subespacio de variabilidad ha sido eliminada, M denota una matriz que contiene en cada una de sus columnas la media global de las imágenes en X y P representa la matriz de proyección $n \times n$:

$$P = I - VV^T = I - \sum_{i=1}^d v_i v_i^T. \quad (2)$$

En este caso, I denota la matriz de identidad $n \times n$, v_i representa la dirección i -ésima de la base del subespacio de variabilidad V de tamaño d definido por NAP.

Supongamos una matriz de datos X que tiene n_{C_j} imágenes de muestra de la clase j -ésima, cuyas etiquetas de clase son C_1, C_2, \dots, C_r , entonces, para cada uno de estas imágenes se puede escribir:

$$x_{C_j,k} = x'_{C_j,k} + e_k, \quad (3)$$

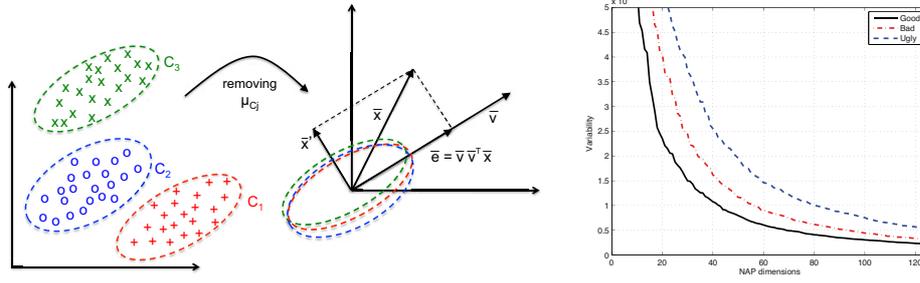


Figura 1. (*Izquierda*) Ilustración esquemática del funcionamiento de NAP en un espacio de 2 dimensiones. Primeramente, cada distribución es centrada en el origen eliminando la media global μ_{C_j} de cada clase. El vector resultante de la muestra compensada (\bar{x}) está formado por dos componentes: el vector de datos de entrada (\bar{x}) y el vector que representa la componente del subespacio de variabilidad (\bar{e}). El vector \bar{v} representa el primer autovector del subespacio de variabilidad estimado. (*Derecha*) Autovectores de los datos de entrenamiento de los conjuntos: *Good*, *Bad* y *Ugly*.

donde C_j representa la etiqueta de la clase de la imagen, k indica el índice de imagen de la clase j -ésima, $x'_{C_j,k}$ representa la parte libre de variabilidad de $x_{C_j,k}$, y e_k representa el vector de codificación de los efectos de la variabilidad para la imagen k -ésima de la clase j -ésima. La Figura 1 (*izquierda*), describe gráficamente el procedimiento.

Asumiendo que los efectos no deseados de la variabilidad dentro de cada clase coinciden y que pueden ser modelados por una distribución de Gaussiana, entonces, la base del subespacio de variabilidad definido por la matriz V , puede estimarse a partir de los primeros d autovectores (direcciones NAP de variabilidad $v_i (i = 1, 2, \dots, d)$) de la matriz Σ_t :

$$\Sigma_t = \sum_{j=1}^r \sum_{k=1}^{n_{C_j}} (X_{C_j,k} - \mu_{C_j})(X_{C_j,k} - \mu_{C_j})^T, \quad (4)$$

donde el valor medio μ_{C_j} ($j = 1, 2, \dots, r$) de cada una de las r clases representa una estimación libre de variabilidad de una imagen de la clase j . Esto se realiza normalmente mediante el uso de *Principal Component Analysis* (PCA). La Figura 1 (*derecha*) muestra los autovectores asociados a sus respectivos autovalores del subespacio de variabilidad NAP estimado.

3.2. Eliminando los efectos de la variabilidad

En el caso considerado en este trabajo, hemos separado los canales YCbCr de las imágenes y el sistema de compensación NAP se ha aplicado sólo sobre la componente de luminancia (Y) de las imágenes.

Consideramos un conjunto de datos de entrada en X a partir del cual se estiman las direcciones NAP correspondientes a la variabilidad desconocida en los escenarios sin restricciones. En la base de datos GBU sólo cuatro factores

son controlados durante la adquisición: el envejecimiento del sujeto, la pose, cambios de cámara, y las variaciones entre las caras. Otros factores tales como: iluminación, interior/exterior, la distancia,... son considerados como factores de variabilidad no deseados. Estos factores no siempre afectan en el mismo nivel haciendo que la compensación de los mismos sea aún más difícil. Cualquier imagen de entrada x es compensada con respecto a los efectos de la variabilidad estimada mediante la proyección de la misma sobre una serie de direcciones en el subespacio NAP. La Figura 1 (*izquierda*) ilustra gráficamente el procedimiento. Dicho procedimiento de compensación se describe como:

$$x' = P(x\mu) = (I - VV^T)(x - \mu), \quad (5)$$

donde μ representa la media global de las imágenes en X , I denota la matriz identidad y V representa la matriz NAP de compensación. Para eliminar eficazmente los efectos de la variabilidad no deseada, la matriz de datos X debe ser construida de tal forma que incluya el mayor número disponible de imágenes capturadas en diferentes condiciones de variabilidad.

4. Sistema de reconocimiento de caras - SRC

Se ha utilizado como base de verificación un sistema del estado del arte basado en *Sparse Representation Classification* (SRC) [2,14].

Esencialmente, este tipo de sistemas generan un subespacio cara usando todas las imágenes de entrenamiento conocidas, de forma que para una imagen de una cara incógnita tratan de reconstruir la imagen de baja densidad.

La motivación de este modelo es que dadas suficientes muestras de entrenamiento de cada persona, cualquier muestra de test nueva de un usuario se encontrará aproximadamente en la envolvente lineal de las muestras de entrenamiento asociadas con dicho usuario.

Una vez que una imagen de test y se adquiere, se puede representar usando muestras de la base de datos por medio de la ecuación lineal $y = Ax_0$, donde la matriz A define los datos de entrenamiento y x_0 representa la solución escasa (*sparse*).

De acuerdo con la hipótesis de que las imágenes de un sujeto dado son suficientes para representarse a sí mismo, la solución x_0 en la ecuación lineal $y = Ax_0$ debe ser muy escasa (*sparse*). Esto puede ser aproximado por la solución del siguiente problema de l^1 minimización:

$$\hat{x}_1 = \operatorname{argmin}_x \|x\|_1 \quad \text{subject to} \quad \|Ax - y\|_2 \leq \varepsilon. \quad (6)$$

Para reconocer una imagen prueba de test, el algoritmo SRC identifica la clase a la que dicha imagen de test pertenece mediante el cálculo del mínimo entre los residuos calculados para cada clase. La robustez del rendimiento del algoritmo SRC se ha demostrado experimentalmente en conjuntos de datos en presencia de ruidos y oclusiones [14].

La solución de la ecuación (6), se aproximó, de una manera eficiente utilizando programación lineal considerando L1-norm en vez de L0-norm. Para este fin, se utilizó el paquete disponible en [1].

5. Protocolo experimental

Los experimentos se llevaron a cabo sobre la base de datos "*The Good, the Bad and the Ugly*" (GBU) [7] incluida en la última competición "NIST - *National Institute of Standard and Technology*" de reconocimiento facial. La competición GBU consiste en tres particiones llamadas *the Good* (pares de caras fáciles de comparar), *the Bad* (pares de caras con cierta dificultad de comparación), y *the Ugly* (pares de caras difíciles de comparar). Cada partición está formada por dos conjuntos de imágenes, un conjunto utilizado como datos de entrenamiento y otro como datos de test, cada una de las cuales contiene 1.085 imágenes de 437 sujetos distintos. La distribución de imágenes por persona en ambos conjuntos (entrenamiento y test) es de 117 sujetos con 1 imagen, 122 sujetos con 2 imágenes, 68 sujetos con 3 imágenes y 130 sujetos con 4 imágenes.

Para los experimentos en este trabajo, hemos utilizado la base de datos GBU, segmentada y proporcionada por la competición "MBGC - *Multiple Biometric Grand Challenge*" [6] comprimida a 20KB, con 120 píxeles entre los centros de los ojos. Las caras fueron normalizadas desde a un tamaño de 408×528 a uno de 168×192 píxeles siguiendo la norma ISO descrita en [3].

El sistema de referencia consiste en la aplicación del algoritmo de SRC con una etapa de pre-procesado para normalizar la iluminación de la cara por medio de la ecualización del histograma (HQ) en la banda de luminancia (Y) del espacio de color YCbCr. En los experimentos descritos, hemos utilizado las caras normalizadas submuestreadas como vectores de características, debido a que como se demuestra en [14] presentan un buen rendimiento cuando se combinan con SRC. En nuestro caso la relación de submuestreo es $1/8$, obteniendo vectores de características de 504 dimensiones.

El rendimiento del sistema es evaluado utilizando el protocolo experimental descrito por la competición GBU: comparaciones uno a uno con entrenamiento, selección de modelos y ajustes antes de calcular el rendimiento sobre las particiones.

En el protocolo experimental se consideran dos experimentos. En el primer experimento, una matriz de compensación NAP es generada para cada partición de la base de datos utilizando sólo las imágenes de entrenamiento. En el segundo experimento se ha generado una matriz global de compensación NAP (NAP_{gbu}) para las tres particiones juntas usando todas las imágenes de los conjuntos de entrenamiento. En ambos casos se evalúa el rendimiento de nuestro sistema de reconocimiento usando dos dimensiones (d) diferentes de variabilidad NAP, baja compensación $d = 5$ y alta compensación de variabilidad con $d = 125$.

6. Resultados

Los experimentos tienen dos objetivos diferentes: *i*) estudiar los beneficios de los esquemas de compensación de variabilidad en entornos no controlados, y *ii*) demostrar la eficacia de la compensación NAP al considerar múltiples fuentes de variabilidad no controladas.

Nuestro algoritmo de referencia basado en *Sparse Representation* logró mejores resultados que los obtenidos por el algoritmo de referencia de la competición

LRPCA-face GBU [7] en una tasa de falsa aceptación ($FAR = 0.001$). En la partición *Good*, la tasa de verificación de referencia (VR) es de 0.88, para la partición *Bad*, la VR es de 0.29, y la VR en la partición *Ugly* es de 0.06. El Cuadro 1 muestra los resultados comparativos.

6.1. Experimento 1: NAP sobre cada partición

El rendimiento del esquema de compensación NAP se analizó en primer lugar escenario a escenario. Los resultados obtenidos para la partición *Good* están representados en la Figura 2a. En este caso, la compensación de unas pocas dimensiones ($d = 5$) es mucho mejor que compensar muchas ($d = 125$). Esto

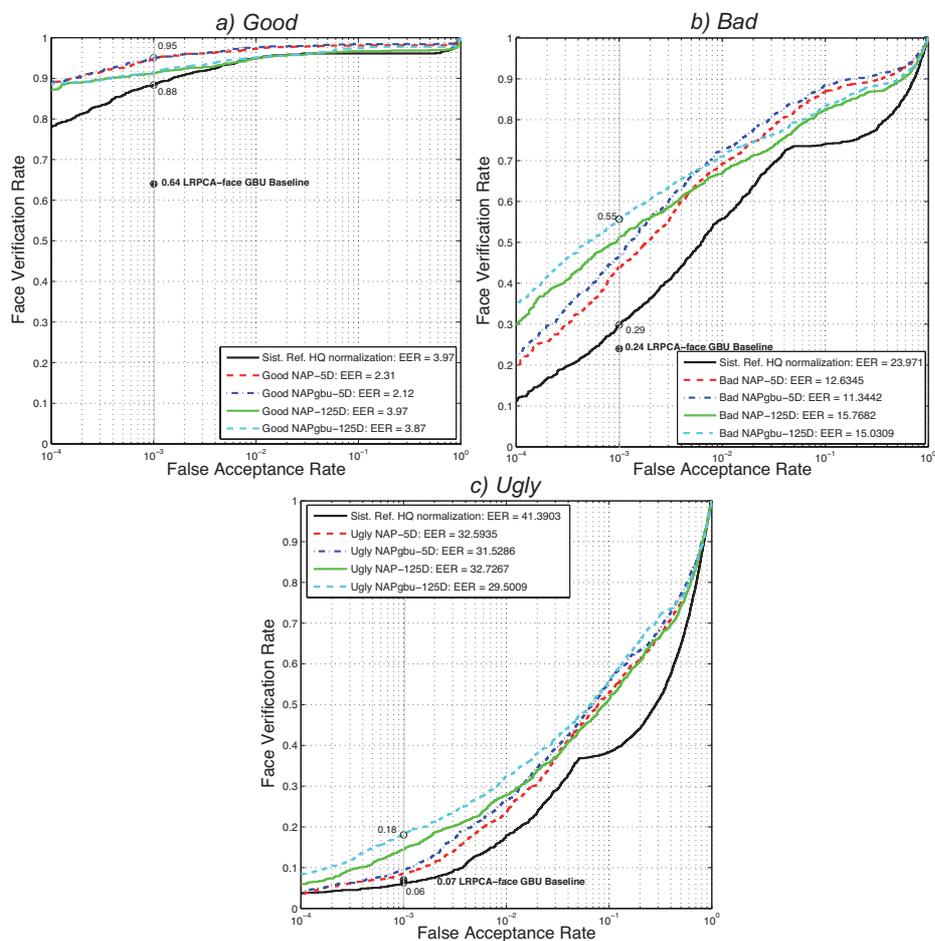


Figura 2. Curvas ROC obtenidas para las tres particiones: *Good* a), *Bad* b) y *Ugly* c). La tasa de verificación para el algoritmo de referencia LRPCA-face GBU [7], nuestro sistema de referencia y la mejor solución NAP son destacadas para una $FAR = 0.001$.

se debe al hecho de que esos datos están más o menos limpios de variabilidad no deseada, de forma que la compensación de muchas dimensiones lleva a una pérdida de información discriminatoria. Como se puede observar en la Figura 1 (*derecha*), los autovalores de la partición *Good* decrementan su valor más rápidamente que en las otras particiones, lo que significa que la variabilidad se concentra en las primeras dimensiones.

Los resultados obtenidos para la partición *Bad* se muestran en la Figura 2b. En este caso, aumenta la variabilidad, lo que significa que hay más dimensiones corruptas con variabilidad. Por lo tanto, se obtienen mejores resultados con la compensación de un mayor número de dimensiones NAP ($d = 125$), trabajan-

Partición	Experimento 1				Experimento 2	
	LRPCA face [7]	Sistema Ref.	Mejor Comp. NAP	Mejora Relativa (%)	Mejor Comp. NAPgbu	Mejora Relativa (%)
<i>Good</i>	0.64	0.88	0.94	6.8	0.95	7.9
<i>Bad</i>	0.24	0.29	0.51	91.6	0.55	89.6
<i>Ugly</i>	0.07	0.06	0.14	133.3	0.18	200

Cuadro 1. Resultado obtenidos en experimentos 1 y 2. Rendimiento del sistema de referencia LRPCA-face [7] frente al nuestro sistema de referencia y los mejores resultados de compensación NAP y NAPgbu, siendo respectivamente $d = 5, 125, 125$ para las particiones *Good*, *Bad* y *Ugly*. Además, es destacada la mejora relativa de la tasa de verificación alcanzada por la compensación NAP y NAPgbu en una FAR = 0.001.

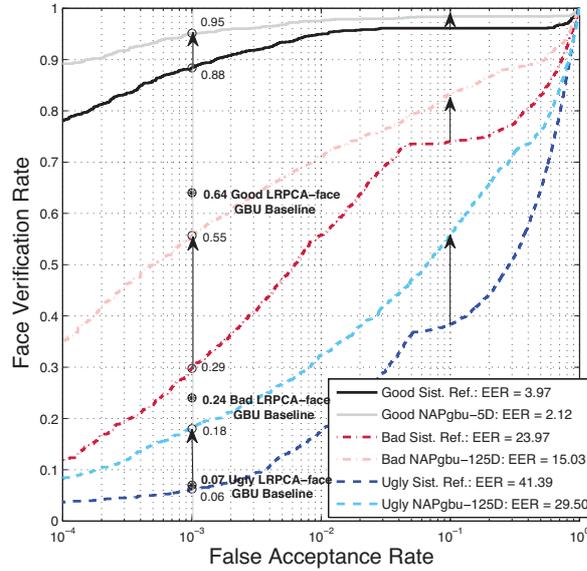


Figura 3. Curva ROC para la mejor solución NAP frente al sistema de referencia (Sist. Ref.) para las tres particiones GBU: *Good*, *Bad* y *Ugly*. El sistema de referencia LRPCA-face GBU [7] es también destacado a una FAR = 0.001.

do en una $FAR = 0.001$. Por otro lado, el EER del sistema es mejor para el caso en que compensamos menos dimensiones ($d = 5$), pero por contrapartida trabajando en un punto de trabajo de FAR mucho más permisivo.

Los resultados obtenidos para el escenario *Ugly* se muestra en la Figura 2c. En este caso, como en el escenario anterior *Bad*, se obtienen mejores resultados cuando se compensan ($d = 125$) dimensiones. Aquí, la tasa de verificación (VR) del sistema de referencia en comparación con el sistema compensado con $d = 125$ mejora desde 0.06 a 0.14 en una $FAR = 0.001$. El Cuadro 1 resume todos los resultados obtenidos en este experimento.

6.2. Experimento 2: NAP sobre todas las particiones juntas

Como se mencionó anteriormente, en este experimento se genera una matriz NAP global de compensación (NAPgbu) combinando los tres conjuntos de entrenamiento (*Good*, *Bad*, y *Ugly*) con el fin de demostrar el potencial del enfoque NAP propuesto en ambientes sin restricciones. Los principales resultados se resumen en el Cuadro 1.

La diferencia entre el bajo o alto número de dimensiones a compensar ($d = 5$ y $d = 125$) respectivamente, mantienen el mismo comportamiento que en el experimento 1 en los tres conjuntos de datos, como podemos ver en la Figura 2.

La compensación NAP elimina la variabilidad intra-clase mediante la proyección de un subespacio de múltiples dimensiones de otro de baja variabilidad. Por esta razón, un subespacio calculado utilizando todos los posibles datos de entrenamiento puede mejorar el efecto de compensación de la variabilidad. Esto se comprueba al observar que el esquema de compensación NAPgbu logra los mejores resultados en todos los escenarios (ver Figuras 2 y 3). Debemos de tener en cuenta que en la partición *Good* de ambos esquemas de compensación propuestos reportan los mismos resultados debido a la baja influencia de las fuentes de variabilidad en este caso.

Como se puede observar en la Figura 3, la partición *Bad* logra la mayor mejora absoluta de VR desde 0.29 hasta 0.55 (con $FAR = 0.001$). Esto se debe posiblemente al hecho que las imágenes contienen una gran cantidad de variabilidad, pero aún es posible lograr unos resultados bastante buenos compensando esa poca variabilidad presente.

Finalmente, en la partición *Ugly*, la relación entre información discriminativa frente al ruido es muy baja. La Figura 3 muestra cómo la VR mejora desde 0.06 hasta 0.18 en una $FAR = 0.001$, logrando mejores resultados que los presentados en [7]. Como se puede observar en el Cuadro 1, la mejora relativa de la tasa de verificación en la partición *Ugly* en este experimento es mayor (200%) que en las otras particiones.

7. Conclusions

En el presente trabajo, un enfoque de compensación de variabilidad basado en *Nuisance Attribute Projection* (NAP) ha sido presentado y utilizado para mejorar un sistema de reconocimiento facial del estado del arte basado en *Sparse Representation*. La eficacia de este enfoque se ha estudiado teniendo en cuenta

tres diferentes particiones diseñadas para la competición NIST de reconocimiento facial "*The Good, the Bad, and the Ugly*" (GBU). Para todos los casos, el rendimiento del sistema de referencia es superior al alcanzado por los sistemas de referencia de la competición GBU [7]. Además, la aplicación del enfoque de compensación de variabilidad propuesto basado NAP, hace que el rendimiento del sistema mejore de forma significativa.

La aplicación de la compensación NAP usando todos los datos de entrenamiento de las tres particiones conjuntamente también es analizado, destacando los beneficios de utilizar esquemas de compensación de variabilidad en este tipo de entornos no controlados.

Referencias

1. Candes, E., Romberg, J.: l1-magic: Recovery of sparse signals via convex programming. In: <http://www.acm.caltech.edu/l1magic/> (2005)
2. Huang, K., Aviyente, S.: Sparse representation for signal classification (2006)
3. ISO/IEC JTC 1/SC 37 N 504: Biometric data interchange formats part 5: Face image (March 2004)
4. Li, S.Z., Chu, R., Liao, S., Zhang, L.: Illumination invariant face recognition using near-infrared images. *IEEE Trans. Pattern Anal. Mach. Intell.* 29(4), (2007)
5. Li, S.Z., Schouten, B., Tistarelli, M.: Handbook of Remote Biometrics for Surveillance and Security, chap. Biometrics at a Distance: Issues, Challenges, and Prospects, pp. 3–21. Springer (2009)
6. MBGC: Multiple Biometric Grand Challenge. NIST - National Institute of Standard and Technology (<http://face.nist.gov/mbgc/>)
7. Phillips, P.J., et al.: An introduction to the good, the bad, and the ugly face recognition challenge problem. In: *Int. Conf. on Automatic Face Gesture Recognition and Workshops (FG 2011)*. pp. 346–353 (march 2011)
8. Phillips, P.J., Scruggs, W.T., O'Toole, A.J., Flynn, P.J., Bowyer, K.W., Schott, C.L., Sharpe, M.: FRVT 2006 and ICE 2006 large-scale experimental results. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 99 (2009)
9. Solomonoff, A., Quillen, C., Campbell, W.M.: Channel compensation for svm speaker recognition. In: *In Proceedings on Odyssey: The Speaker and Language Recognition Workshop*. pp. 41–44. Toledo, Spain (2004)
10. Solomonoff, A., Campbell, W.M., Quillen, C.: Nuisance attribute projection. *Speech Communication, Elsevier Science BV* (2007), amsterdam, The Netherlands
11. Tome, P., Fierrez, J., Alonso-Fernandez, F., Ortega-Garcia, J.: Scenario-based score fusion for face recognition at a distance. In: *IEEE Conf. on Comp. Vision and Pattern Recognition Workshops (CVPRW)*. pp. 67–73 (June 2010)
12. Tome, P., Fierrez, J., Fairhurst, M.C., Ortega-Garcia, J.: Acquisition scenario analysis for face recognition at a distance. In: *6th International Symposium on Visual Computing (ISVC)* (November-December 2010)
13. Štruc, V., Vesnicer, B., Mihelič, F., Pavešić, N.: Removing illumination artifacts from face images using the nuisance attribute projection. In: *Proceedings of the IEEE Int. Conf. on Acoustics, Speech and Signal Processing (ICASSP'10)*. pp. 846–849. Dallas, Texas, USA (March 2010)
14. Wright, J., Yang, A.Y., Ganesh, A., Sastry, S.S., Ma, Y.: Robust face recognition via sparse representation. *IEEE Trans. Pattern Anal. Mach. Intell.* 31(2), (2009).
15. Zhang, X., Gao, Y.: Face recognition across pose: A review. *Pattern Recognition* pp. 2876–2896 (2009)