

Transformación de Características basada en descomposición de funciones y en inducción de reglas / Feature Transformation by function decomposition and through rule induction

Yoel Caisés-Almaguer

Ricardo Navarro-Rodríguez

PAÍS: Cuba

RESUMEN

Constituye un estudio experimental en entornos variados de las técnicas de Transformación de Características basadas en descomposición de funciones y en inducción de reglas, dos de las técnicas más destacadas en este campo. A partir de ello es posible valorar su comportamiento en cada caso.

PALABRAS CLAVES

TRANSFORMACIÓN DE
CARACTERÍSTICAS;
TRANSFORMACIÓN DE
ATRIBUTOS; TRANSFORMACIÓN
DE RASGOS; DESCOMPOSICIÓN
DE FUNCIONES; INDUCCIÓN DE
REGLAS.

ABSTRACT

This is an experimental study which includes Feature Transformation by function decomposition and Feature Transformation by through rule induction, two of most remarkable techniques in this area. It allows to evaluate its behaviour in different situations.

KEY WORDS:

FEATURE TRANSFORMATION;
FUNCTION DECOMPOSITION;
RULE INDUCTION.

INTRODUCCIÓN

La Transformación de Características es una de las técnicas de Preprocesamiento de la información más empleadas y tiene entre sus metas está enriquecer los datos a través de la obtención de nuevas características a partir de relaciones existentes entre las originales, con el fin de incrementar la efectividad de los procesos de Minería de Datos y Aprendizaje Automático,

partiendo de que la calidad de los datos es un factor esencial para obtener buenos resultados.

Estas técnicas intentan sintetizar la dimensión de una base de datos a través de la obtención de nuevas características a partir de las originales: dado un conjunto A, obtienen a partir de él un conjunto A' que representa el conjunto de características a partir del cual los algoritmos de aprendizaje obtienen un mejor resultado. A' contiene elementos obtenidos a partir de los originales, pero que ofrecen mayor información a los métodos de aprendizaje.

MATERIALES Y MÉTODO

Este estudio de la Transformación de Características para la Minería de Datos se vio apoyado en métodos teóricos y empíricos. Entre los teóricos se incluyen el análisis y síntesis, la inducción y deducción, así como el histórico y lógico. Entre los empíricos se encuentra el estudio de la documentación empleado para la comprensión del tema abordado, su estado actual a nivel mundial, los principales algoritmos que ya existen y las metas y proyecciones futuras, además del experimento: se implementaron algoritmos de Transformación de Características. Las bases de casos resultantes de la aplicación de dichos métodos se sometieron a la acción de distintos algoritmos de aprendizaje, permitiendo llegar a conclusiones evaluativas respecto a la efectividad de cada una de estas técnicas de Transformación de Características.

RESULTADOS DEL TRABAJO

Ambiente experimental

Este estudio radica en un análisis comparativo de los resultados obtenidos por algunos algoritmos de aprendizaje ante distintas variantes bases de casos sometidas a los métodos de Transformación de Características basados en descomposición de funciones y en inducción de reglas, teniendo como criterio la tasa de aciertos de los mismos en la clasificación. Para ello se empleó Weka, una herramienta desarrollada en la universidad de Waikato (Nueva Zelanda) bajo licencia GNU y que cuenta con un conjunto de librerías JAVA para la extracción de conocimiento desde bases de datos, por lo cual es una de las más utilizadas últimamente en el área.

En el experimento se incluyeron cinco bases de casos: Iris, Pima, Thyroid, Wisconsin Breast Cancer y Wine, que resultan ser de las más populares en estudios de Inteligencia Artificial, específicamente en problemas de clasificación:

Iris: constituye una base de casos muy utilizada en experimentos con algoritmos de clasificación y tal vez la más conocida en la literatura de reconocimiento de patrones. Propone clasificar plantas en tres tipos a partir de cuatro variables predictivas: largo y ancho de sépalos y pétalos respectivamente. El dominio de la variable de clasificación es equivalente a los siguientes valores nominales: setosa, virgínica, versicolor.

Pima: resulta un muestreo sobre diagnóstico de diabetes en una población de Arizona (EEUU) y se rige por los signos propuestos por la Organización Mundial de la Salud (OMS). Todos los pacientes son de sexo femenino y mayores de 21 años. Tiene ocho características de interés clínico y la clase puede arrojar dos valores en correspondencia con la presencia o no de la enfermedad. Vale destacar que los datos son bastante heterogéneos.

Thyroid: permite determinar si un paciente padece hipotiroidismo. La clasificación se realiza en: normal, hiperfunción y funcionamiento anormal.

Wisconsin Breast Cancer: es original de los hospitales de la Universidad de Wisconsin y está destinada al diagnóstico de cáncer de mama. Recoge características citológicas de células de un tumor, obtenidas a partir de la observación microscópica.

Wine: contiene los datos arrojados por un análisis químico de vinos de una misma región italiana pero derivados de tres tipos distintos. Las características representan las cantidades de 13 componentes encontrados en las tres clases de vino. Contiene 2.3 % de los valores ausentes.

Tabla 1. Características de las bases de casos

Base de casos	ejemplos	car	val/car	real	ent	clases	ausentes (%)
Iris	150	4	5	4	0	3	0
Pima	768	8	5	8	0	2	0
Thyroid	215	5	5	5	0	3	0
WBreast Cancer	699	9	5	0	9	2	2.3

Wine	178	13	5	13	0	3	0
------	-----	----	---	----	---	---	---

Para medir el rendimiento del proceso de Transformación de Características se usó la calidad de la clasificación alcanzada con tres algoritmos de aprendizaje, que fueron seleccionados por su representatividad: Naive Bayes (NBayes) e IBk, están basados en la teoría de la probabilidad y en la medida de distancias entre ejemplos respectivamente, y representan la base de muchos otros más complejos. El tercer algoritmo, RIPPER, está basado en inducción de reglas. A continuación se enuncian algunas características de estos.

Naive Bayes es un clasificador simple basado en la aplicación del teorema de Bayes. Usa una suposición muy fuerte: las características son todas independientes entre sí. Por esta razón, se le denomina naive (ingenuo). Simplemente, dadas las probabilidades del conjunto de datos como muestra, aplica una expresión sobre el ejemplo a clasificar y lo asigna a aquella clase que obtenga mayor probabilidad.

El algoritmo de aprendizaje IBk es una variante del k-vecinos más cercanos (kNN) para clasificación. Se basa en la suposición de que los ejemplos cercanos pertenecen a la misma clase. Su fase de aprendizaje es muy simple, pues se limita a almacenar los ejemplos del conjunto de entrenamiento. La de clasificación también es sencilla, aunque más costosa en eficiencia: busca los k ejemplos más cercanos a la instancia que se quiere clasificar y le asigna la clase más frecuente entre ellos.

RIPPER pertenece a la familia de algoritmos secuenciales que inducen reglas por clases, en un orden predeterminado de las mismas. Por defecto, el orden es ascendente, tomando como criterio la frecuencia de las clases y dejando de esta forma la clase más frecuente como la regla por defecto. Durante la clasificación, la regla que primero se cumple asigna la clase a la nueva instancia. La experiencia demuestra que es rápido y ofrece resultados competitivos ante cualquier algoritmo de su tipo.

Por otra parte, los métodos de Transformación de Características basados en descomposición de funciones y en inducción de reglas resultaron de particular interés para el estudio a partir de varias razones:

- Los resultados documentados evidencian un buen rendimiento ante determinados algoritmos de aprendizaje como es el k-vecinos más cercano.

- De los métodos de Transformación de Características basados en descomposición de funciones, el implementado es el que mejores resultados ha tenido. Además, constituye uno de los pocos métodos de este tipo publicados.
- El método basado en inducción de reglas es de los más recientes y hace uso del algoritmo RIPPER a tal efecto, por lo que resulta interesante comprobar su efectividad ante otros algoritmos de aprendizaje.

Descomposición de funciones

El método de Transformación de Características a partir de la descomposición de funciones es uno de los más antiguos. La variante implementada constituye un método de construcción: añade al conjunto de datos original nuevas características. Esto es útil cuando el conjunto de características es insuficiente para el aprendizaje.

Para obtener cada una de las nuevas características se particiona el conjunto X de características originales en dos subconjuntos A y B , con $A \cup B = X$ y $A \cap B = \{\}$. El tamaño de los subconjuntos está dado primeramente por el parámetro b , que define la cardinalidad de B . Su valor es variable y por los resultados experimentales que refieren los creadores del método, se fijó en 2. En consecuencia, el conjunto A resulta de determinar el complemento de B en el conjunto X . Para obtener las nuevas características se generan todas las posibles particiones $A|B$, construyéndose una a partir de cada partición.

Una vez que se tiene $A|B$, corresponde la formación de una matriz de partición que tiene por columnas las combinaciones de B y por filas las de A . Los valores o entradas de la matriz representan las intersecciones de sus filas y columnas en la base de casos original.

Tomando la matriz de partición como referencia se debe construir un grafo de incompatibilidad: sus nodos se corresponden con las columnas en la matriz. Dos nodos se conectan si son incompatibles, lo cual ocurre cuando tienen distintos conjuntos de entradas en la matriz. Para determinar esto se debe tener en cuenta que las entradas marcadas como “-” resultan ser no significativas, lo que indica que pueden tomar cualquier valor, o sea, no influyen en la determinación de correspondencia entre dos conjuntos de entradas.

Obtener y procesar computacionalmente dicha matriz es muy costoso, por lo cual se construye el grafo de incompatibilidad directamente a partir de los datos. El proceso de coloreado del grafo consiste en asignar un color o etiqueta a cada nodo. Para lograrlo se tiene en cuenta que a un nodo ha de asignársele un color distinto al de sus incompatibles, intentando siempre la cantidad mínima de valores.




Figura 1. Descomposición de funciones

Colorear óptimamente un grafo resulta un problema NP-completo. Ello justifica el uso de una heurística basada en el Método de la Influencia del Color. La base de casos original se somete a un ordenamiento de los ejemplos en función de A y luego de la clase. El mismo se llevó a cabo con RadixCounting, una combinación de los métodos de ordenamiento Radix y Counting.

Específicamente para Radix, se empleó ordenamiento LSD (least significant digit), mediante el cual se procesó la base de casos desde el índice de característica menos significativo hacia el más significativo. Se escogió LSD

debido a su alto nivel de estabilidad, condición que también distingue el ordenamiento Counting. La combinación da como lugar un ordenamiento Counting donde el grado de prioridad se halla definido por Radix.

Posteriormente se dividen los ejemplos ordenados en grupos y subgrupos. Los ejemplos con igual A pertenecen a un mismo grupo y los subgrupos están determinados por la clase. Dos vértices del grafo de incompatibilidad están conectados, o sea, son incompatibles, si pertenecen a distintos subgrupos dentro de un mismo grupo. En la figura siguiente se muestra un ejemplo de este proceso con la partición $A = \{x_1\}$ y $B = \{x_2, x_3\}$. En ella las líneas dobles indican los límites de un grupo y las sencillas los subgrupos identificados.




Figura 2. Coloreado del grafo de incompatibilidad

Los números circulados en el grafo corresponden a los valores de la característica construida. Este proceso pretende lograr un mínimo de colores (etiquetas): a un nodo se le asigna el color más frecuente entre sus compatibles.

Los estudios experimentales de este algoritmo, trabajan con datos nominales. Un rasgo de algunas de las bases de casos es que las instancias son muy heterogéneas, excepto para la base de casos Iris. Ello constituye un problema debido a que en su mayoría los grupos identificados fueron unitarios, es decir, de una sola instancia, por lo que no fue posible construir grafos a partir de ellos

que al colorearse dieran lugar a una característica que cumpliera con los requerimientos anteriormente mencionados. Además, esta diferencia entre las instancias provoca que la cantidad de nodos del grafo sea muy elevada, y en los casos que sí ameritaba la creación de los grafos debido a la cantidad de subgrupos identificados, el costo computacional de la coloración era muy alto. De aquí que fuera necesario aplicar discretización como estrategia para agrupar los datos de manera tal que fueran más homogéneos. La discretización utilizada está inspirada en el método para fusificar que utiliza el algoritmo de inducción de reglas difusas SLAVE, según lo cual se añade a cada valor de la característica su correspondiente etiqueta lingüística de acuerdo a los conjuntos difusos definidos para la misma.

Esta variante de descomposición de funciones no tolera el ruido, por lo que fue necesario preprocesar los datos con vistas a su eliminación. Para ello fue utilizado Edited Nearest Neighbor (ENN), como algoritmo extra para el tratamiento del ruido.

Al aplicar este algoritmo basado en descomposición de funciones, se obtuvieron nuevas características que fueron añadidas a la base de casos. Tomando como base los valores de sus dominios, se tuvo en cuenta que la cantidad de valores no excediera a la cantidad de aquellas que le dieron origen, así como que la nueva característica que tuviera un único valor, no fuera agregada por considerarse irrelevante. Es preciso destacar que prácticamente ninguna de las nuevas características obtenidas violó la condición de exceder la cantidad de valores de las que les dieron origen, por lo que fueron tomadas casi en su totalidad para aumentar la descripción de los datos. Asimismo, prácticamente ninguna de las nuevas características resultó ser irrelevante.

Base de casos	No. Características originales	No. Nuevas características
Iris	4	6
Pima	8	28
Thyroid	4	10
WB Cancer	8	13
Wine	12	16

Tabla 2. Cantidad de características originales y nuevas por base de casos

Transformación a partir de inducción de reglas

Para la implementación de este método fue necesario cambiar la representación de las características transformadas por una notación similar teniendo en cuenta que la primera variante no puede ser sometida a los restantes algoritmos de aprendizaje incluidos en el experimento utilizando Weka, debido a que los ejemplos no tienen un tamaño uniforme. La nueva representación indica la relación binaria entre un ejemplo y las distintas reglas obtenidas por RIPPER. En la siguiente figura las características con valor 1 indican que el ejemplo cumple la regla referida.

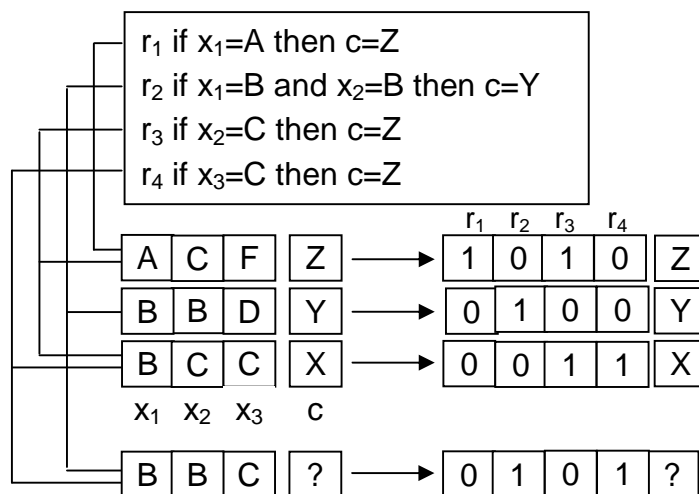


Figura 3. Variante implementada del proceso de codificación de las reglas

IBk en Weka calcula la distancia entre los ejemplos nominales, como es el caso de las bases de casos obtenidas de la acción de este algoritmo, a partir de los elementos iguales. En este caso los únicos valores a considerar son las posiciones con valor 1. Sin embargo, con Weka, aún cuando dos ejemplos no cumplen una determinada regla, se tiene en cuenta en el resultado de la similitud. Debido a esto se decidió implementar una variante de IBk que para determinar la distancia, que solo tiene en cuenta la cantidad de reglas que ambos ejemplos cumplen.

Resultados experimentales

El elemento de evaluación en este experimento lo constituye el porcentaje de clasificación logrado por cada algoritmo de aprendizaje. Los detalles de los resultados aparecen en las tres tablas que aparecen a continuación. La primera columna de las tablas representa las bases de casos y el resto de las columnas las variaciones a las que fueron sometidas: *Original* se refiere a los resultados

obtenidos por el algoritmo de aprendizaje específico de cada tabla para las bases de casos sin la acción de ningún algoritmo de Transformación de Características. *Descomposición de funciones* representa los resultados a partir de bases de casos a las que se le aplicó este algoritmo y la columna *Inducción de reglas* corresponde a los resultados del algoritmo de aprendizaje para bases de casos que fueron sometidas a tal método.

Previo a la aplicación de función de descomposición e inducción de reglas se aseguró que las bases de casos no tuvieran valores ausentes mediante un completamiento basado en el método del valor más común. Se empleó validación cruzada con 10 particiones. Para su aplicación se dividió una misma base de casos en 10. Se tomaron 9 partes, que representan el 90% de los datos, y se usaron en el entrenamiento, quedando restante un 10% para la prueba. El procedimiento se repitió diez veces, quedando siempre fuera del conjunto de entrenamiento una partición de la base de casos, destinada a la prueba.

RIPPER logró igualar los resultados originales para las bases de casos WB Cancer y Wine, sometidas a Transformación a partir de inducción de reglas. Ante el resto de las bases de casos fueron inferiores. El algoritmo basado en descomposición de funciones no incidió positivamente en los resultados de RIPPER: para todas las bases de casos en su estado original se obtuvieron mejores resultados.

En sentido general se aprecia que ninguno de los dos métodos de Transformación de Características mejoró el rendimiento de RIPPER, aunque no se alejaron significativamente de los resultados originales, en especial la transformación a partir de reglas. Es relevante que ambas técnicas se mantuvieron bastante estables, con una desviación estándar de 9.20 en el caso de la transformación a partir de reglas, el mismo valor que se obtuvo ante los datos originales, y un 9.81 para la descomposición de funciones.

Método RIPPER	Base de casos	Original	Descomposición de funciones	Inducción de reglas
	Iris	94	93.33	93.33
	Pima	73.18	70.71	72.79
	Thyroid	92.14	90.69	90.71

	WB Cancer	95.41	94.99	95.41
	Wine	92.71	89.38	92.71
	Promedio	89.49	87.82	88.99
	Desviación	9.20	9.81	9.20

Tabla 3. Resultados de RIPPER

Similares a los resultados obtenidos por RIPPER ante las tres variantes de bases de casos fueron los arrojados por el algoritmo IBk; pero a diferencia del caso anterior, la acción del método basado descomposición de funciones logró mejorar los resultados de IBk ante Pima, Thyroid y WB Cancer, aunque para la segunda solo se produjo un pequeño incremento. Sin embargo, ante Iris los resultados fueron muy inferiores, y en un menor grado también lo fueron ante Wine.

En el caso de la transformación a partir de inducción de reglas se lograron mejoras ante Pima y muy ligeramente con Wine. Igualó el resultado original para WB Cancer y volvió a ser el resultado para Iris el que más se alejó del original.

Si se comparan las acciones de los dos métodos de Transformación de Características involucrados, el de descomposición de funciones hizo posible la obtención de mejores resultados por parte de IBk ante las bases de casos Pima, WB Cancer y Thyroid. Sin embargo, los resultados generales demuestran que este algoritmo no logró buenos resultados para IBk, así como tampoco lo hizo la transformación a partir de inducción de reglas que sí tuvo resultados superiores a los del método de descomposición de funciones. En esta ocasión la estabilidad de los dos métodos de transformación fue superior, demostrado por disminuciones de 3.16 y 3.66 de los valores de desviación estándar respecto al original, siendo el más estable la transformación a partir de inducción de reglas.

Método IBk	Base de casos	Original	Descomposición de funciones	Inducción de reglas
	Iris	100	88	94
	Pima	66.93	71.26	72.79
	Thyroid	92.14	92.27	90.71

	WB Cancer	95.41	96.28	95.41
	Wine	92.71	92.12	92.75
	Promedio	89.44	87.99	89.13
	Desviación	12.96	9.8	9.3

Tabla 4. Resultados de IBk

Así como sucedió con los algoritmos de aprendizaje anteriores, NBayes tampoco se favoreció con la aplicación de ninguno de los algoritmos de Transformación de Características a las bases de casos. Solo para WB Cancer, los métodos de descomposición de funciones y la transformación a partir de inducción de reglas lograron que la clasificación mejorara en un 1.69 % y 0.25 % respectivamente.

A pesar de que ambos algoritmos de transformación incumplieron su objetivo, sus resultados no distan mucho de los obtenidos para los datos originales y se mantuvieron con estabilidades similares a la original: el método de transformación a partir de inducción de reglas se comportó ligeramente de modo más estable que el original.

	Base de casos	Original	Descomposición de funciones	Inducción de reglas
Método NBayes	Iris	97.33	94.67	93.33
	Pima	75.8	72.92	72.79
	Thyroid	97.16	92.59	90.71
	WB Cancer	95.16	96.85	95.41
	Wine	96.63	94.97	92.75
	Promedio	92.42	90.4	89
	Desviación	9.33	9.89	9.21

Tabla 5. Resultados de NBayes

CONCLUSIONES

Se realizó un experimento que incluye la implementación de los métodos de Transformación de Características basados en descomposición de funciones e inducción de reglas, y la evaluación de su desempeño ante los algoritmos de

aprendizaje RIPPER, IBk y NBayes, empleándose para ello cinco bases de casos, de las más referenciadas en estudios de este tipo.

Con la aplicación del método basado en descomposición de funciones no se logró mejorar el rendimiento de ninguno de estos algoritmos de aprendizaje.

La Transformación de Características a partir de inducción de reglas tampoco conllevó a un aumento en el desempeño de los métodos de aprendizaje tomados como muestra.

RECOMENDACIONES

A raíz de los resultados obtenidos en el experimento se analizaron posibles caminos a tomar con vistas a mejorar el desempeño de los algoritmos de aprendizaje en la clasificación. Entre estos se pueden citar:

1. Utilizar otro método de discretización sobre los conjuntos de datos sometidos a Transformación de Características por descomposición de funciones. En las pruebas iniciales, se constató que las bases de casos utilizadas son muy heterogéneas, por lo que no fue posible aplicar la descomposición de funciones a los datos en bruto. Sin embargo, en el caso de Iris, esto no fue un problema. Sus datos permitieron obtener muy buenos resultados al menos para RIPPER, lo cual es sin dudas una evidencia de que el método de discretización utilizado pudo influir en los resultados.
2. La variante del método de descomposición de funciones utilizado aumenta el espacio de características. Sería interesante comprobar qué sucedería si las nuevas características sustituyeran jerárquicamente a aquellas que le dieron origen, siempre y cuando cumplieran con los indicadores de calidad que mide el algoritmo.
3. Las bases de casos obtenidas a partir de la aplicación del método de inducción de reglas desechan las variables originales. El uso de estos, según los autores del método, pudiera incidir en el rendimiento de al menos IBk.

Además se propone extender las pruebas a otras bases de casos: si bien el número de bases de casos usadas pudiera parecer escaso, por el contrario, resulta apropiado si se tiene en cuenta que las publicaciones en torno a este tema abordan los experimentos con pequeñas cantidades de bases de casos, en muchas ocasiones inferiores a las cinco incluidas en este trabajo. En adición

a lo antes planteado, se encuentra el hecho de que las bases de casos tratadas son de las más empleadas en problemas de clasificación y presentan diferencias entre sí en cuanto a la homogeneidad de sus datos y el número de características. A pesar de todo esto, agregar otras bases de casos al experimento, de seguro conllevará a resultados más exactos y confiables.

Incluir otros algoritmos de aprendizaje, para las técnicas de Transformación de Características implementadas, permitiría evaluar su efectividad a partir de su influencia en los mismos. Así como tomar otros criterios distintos al porcentaje de clasificación podrían aportar mayor certeza para evaluar la efectividad de los métodos de Transformación de Características: en el caso de los algoritmos de inducción de reglas, el tamaño de las reglas es un punto de partida para tal evaluación, a sabiendas de que las mejores reglas son aquellas de menor tamaño, más simplicidad. Otro indicador a tener en cuenta puede ser el tiempo de ejecución del algoritmo. En la realización de las pruebas pudo constatarse que RIPPER varió su tiempo de respuesta ante distintas variantes de una misma base de casos.

BIBLIOGRAFÍA

1. Bosch van den, A. Feature transformation through rule induction: a case study with the k-NN Classifier. Holanda: Tilburg; [S.N.], 2005. 16 h.
2. Bruha, I. From machine learning to knowledge discovery: survey of preprocessing and postprocessing. **Intelligent Data Analysis** (Canadá, Hamilton) 4: 363–374, 2000.
3. Ferri F.J., Albert J.V., Vidal E. Considerations about sample-size sensitivity of a family of edited nearest neighbor rules. **Systems, Man and Cybernetics, IEEE Transactions** (USA). 29(5): 667-672, 1999.
4. Mitchell, T. M. Machine Learning. Book News, I., McGraw-Hill Science/Engineering/Math, 1997.
5. Pérez R. Aprendizaje de reglas difusas usando Algoritmos Genéticos. España: Granada; [S.N.], 1997. 15 h.
6. Liu H., Motoda H. Feature Transformation and Subset Selection. JAPAN: Osaka; [S.N.], 1998. 9 h.
7. Topchy A., Punch W. Dimensionality Reduction via Genetic Value Clustering. USA: Michigan; [S.N.], 2004. 13 h.

8. Wan W., Perkowski M. A new approach to the decomposition of incompletely specified functions based on graph-coloring and local transformations and its application to FPGA mapping. IEEE EURO-DAC '92, Hamburg, 230-235 p. 1992.
9. Zupán B. Feature transformation by function decomposition. Slovenia; University of Ljubljana; [S.N.], 1997. 14 h.

Síntesis curricular de los Autores

MsC. Yoel Caisés-Almaguer (Profesor Asistente) ycaises@facinf.uho.edu.cu

Ing. Ricardo Navarro-Rodríguez rnavarro@facinf.uho.edu.cu

Centro de trabajo de los Autores: Universidad de Holguín "Oscar Lucero Moya". Facultad de Informática y Matemática. Departamento de Informática. Ave XX Aniversario Gaveta Postal 57 Holguín 80100 Cuba. Teléfono: (+53) (24) 48 2672, Fax: (+53) (24) 46 8050.

Fecha de Recepción: 17 noviembre 2009

Fecha de Aprobación: 23 de junio de 2010

Fecha de Publicación: 31 de octubre 2011