

Estado del Arte: Metodos para el reconocimiento biométrico facial

UNIVERSIDAD POLITÉCNICA SALESIANA – SEDE CUENCA
ELECTRÓNICA ANALÓGICA II

Cabrera Sarmiento Jhosselyn Lissbeth, jcabreras4@est.ups.edu.ec
Solis Peña Miguel Patricio, msolisp@est.ups.edu.ec

Abstract—El reconocimiento biométrico facial es un sistema que mediante la inteligencia artificial responde a una autenticación por medio de ciertos patrones, desde ciertas características del individuo o objeto como son las morfológica o que según el comportamiento la hacen únicas en el individuo, en este caso se hablara sobre los métodos de reconocimiento facial y en que algoritmos se basa, a su vez este tipo de reconocimientos se ha vuelto una tendencia ya que es una gran herramienta para el control e investigación dependiendo donde sea su implementación.

Keywords—*Biometría facial, Eigenfaces algorithm, IPCA, PCA.*

I. INTRODUCCION

Los sistemas biométricos se puede decir que son aquellos que brindan una respuesta a un procesamiento de reconocimiento de patrones que nos permiten identificar la identidad de una persona que parte de sus características físicas y de una geometría, dicho mejor este conjunto de características se lo conoce como autenticadores. Existen varios tipos de identificación del individuo, se podría nombrar a los autenticadores dactilares (huella o palma de la mano), autenticador del iris (ojo humano), autenticador facial (rostro), autenticador corporal (todo el cuerpo humano), etc. [1][2][3]

En lo siguiente nos enfocaremos en los métodos de autenticación facial, se hablara sobre los métodos que ya hace mucho se usa, estos son los sistemas de tipo Eigenface que entrelazan el reconocimiento de dichas caras del entrenamiento (rostros captados), y los procesa con el logaritmo eigenface para su respectiva comparación ya que este genera vectores de peso (vectores de características). [1][2][3]

Otra forma de reconocimiento que tenemos es mediante el reconocimiento geométrico del rostro captado. En este método de reconocimiento obtenemos la información mediante dos formas que son por una aproximación de los vectores extraídos por la vista de perfil o por vectores a partir de la vista frontal del individuo. [2][3]

Cuando se emplea cualquiera de estos dos métodos de reconocimiento en el sistema se puede considera que la persona pueda estar en movimiento y aun así se la reconozca, este sistema necesita de una fuente de luz y uno de sus

inconvenientes seria la falta de una iluminación exacta, aun así también existen problemas a personas con cambios faciales bruscos (operaciones faciales). [2]

En la metodología usada con el sistema de reconocimiento por el modelo de eigenfaces y aplicado en la PCA ya sea de alta o baja velocidad siempre se necesita de un procesamiento de imágenes para que estos puedan rendir de una manera más eficiente. [7][8][9][10]

Se dice que el sistema IPCA nace de su antecesor pero con la diferencia de que se aplica una nueva teoría para que este algoritmo funcione de una mejor manera, así evitar el proceso y tiempo de reconocimiento al momento de tomar un gran número de muestras. [9][11][12]

II. MARCO TEORICO

Sistemas de identificación biométrica más populares.- se podría decir que los sistemas más utilizados al momento de la autenticación son: el reconocimiento por huellas dactilares, con la palma de la mano, el reconocimiento facial y el reconocimiento por iris. [1][3]

El reconocimiento facial.- este sistema responde a características morfológicas del individuo a ser autenticado, este tipo de reconocimiento nos responde a dos tipos de cambios temporales: la variación no agresiva y la agresiva; donde la no agresiva consta en analizar las características que son el crecimiento y el envejecimiento del individuo (ya que son de carácter lento) y la agresiva que podría decirse que son cambios como por ejemplo (un accidente y por reconstrucción estética se da un cambio brusco). [1][3][4]

También tenemos el modelo de reconocimiento mediante el sistema eigenfaces que se caracteriza por ser un conjunto de vectores que hacen un reconocimiento de las imágenes captadas por el sensor y esta los ordena de una manera para que se puede autenticar la persona o individuo. Es uno de los sistemas más eficaces al momento de hacer un reconocimiento pero tiene una desventaja ya que necesita procesar las imágenes a una mayor velocidad, también el tiempo

que le toma comparar y si el individuo está en movimiento será menos preciso por lo que ahora se utiliza una implementación de tarjetas gráficas para un mayor número de muestras y una mayor velocidad al procesarlas pero su costo se eleva drásticamente. [1][5][6]

Para el reconocimiento se sigue una serie de pasos que pueden ser explicadas mediante un flujograma a continuación:

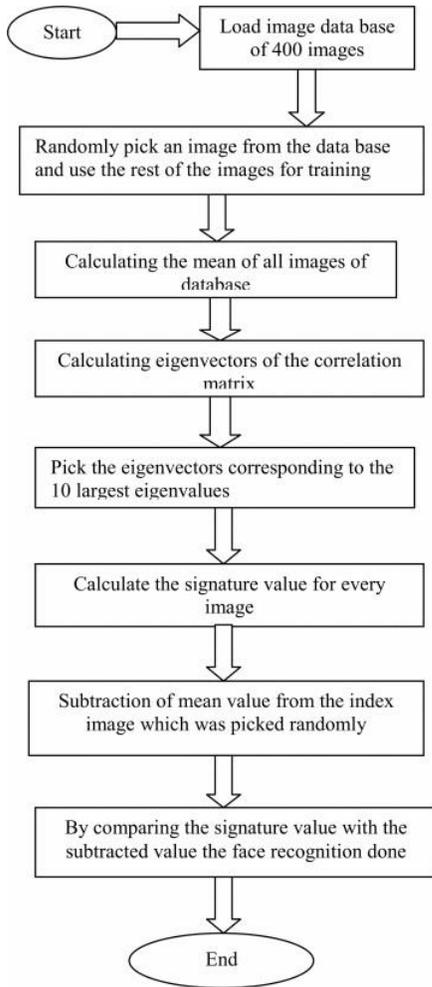


Figura 1. Flujograma del proceso para el sistema de reconocimiento mediante el modelo eigenface básico. [5]

El algoritmo de PCA o conocido también como el análisis de componentes especiales, es uno de los más importantes ya que se lo ha ocupado para la reducción de datos y facilidad de los mismos para su debida compresión, este se fusiona con el reconocimiento facial mediante las eigenfaces ya que regula la detección de personas o cosas mediante patrones que según su configuración se puede aplicar. Existe una mejora de este algoritmo que es el IPCA que es similar al anterior con la diferencia de que utiliza conceptos de la teoría de información de Shannon para su mejora en el rendimiento ya que se comporta mucho mejor. [5][8][12]

III. ANALISIS

Enfoques predominantes

- El geométrico (basado en rasgos)
- EL fotométrico (basado en lo visual). [11]

Análisis de componentes principales

La técnica PCA la cual toma aquella proyección lineal que maximiza la dispersión de todas las imágenes proyectadas. En primer lugar se considera un conjunto de N imágenes con valores en el espacio de imágenes n -dimensional. [7]

$$\{x_i\} i = 1, 2, \dots, N \quad (1)$$

Se asume además que cada una de las imágenes pertenece a una de las clases $\{X_1, X_2, \dots, X_c\}$. Asimismo se considera una transformación lineal que lleva el espacio de imágenes original de n dimensiones al espacio de características de dimensión m , donde $m < n$. Los nuevos vectores de características $y_k \in \mathcal{R}^m$ son definidos por la siguiente transformación lineal [7]

$$y_k = W_{xk}^T \quad k = 1, 2, \dots, N \quad (2)$$

Donde $W \in \mathcal{R}^{n \times m}$ es una matriz con columnas ortonormales. Se define además la matriz de distribución total

$$S_T = \sum_{K=1}^N (x_K - \mu)(x_K - \mu)^T \quad (3)$$

Donde $\mu \in \mathcal{R}^n$ es la media de todas las imágenes de (1). Luego de aplicar la transformación lineal W^T , la distribución de los vectores de características $\{y_1, y_2, \dots, y_N\}$ es $W^T S_T W$. Se toma aquella proyección W_{opt} que maximiza el determinante de la distribución total de la matriz de las imágenes proyectadas, esto es [7]

$$W_{opt} = \arg \max_w |W^T S_T W| = [w_1, w_2 \dots w_m] \quad (4)$$

Donde $\{w_i \mid i = 1, 2, \dots, m\}$ es el conjunto de vectores propios n -dimensionales de S_T correspondiente a los mayores m vectores propios. Dichos vectores propios tienen la misma dimensión que las imágenes originales y se les denomina eigenfaces. En la Figura 1 se muestra las primeras siete eigenfaces obtenidas con un conjunto de imágenes de la base Extended Yale Face Database B. [7]

PCA, comúnmente referida al uso de Eigenfaces, es la técnica impulsada por Kirby & Sirovich en 1988. Con PCA, el sondeo y la galería de imágenes deben ser del mismo tamaño y

deben ser normalizadas previamente para alinear los ojos y bocas de los sujetos en las imágenes. [8]

La aproximación de PCA es luego utilizado para reducir la dimensión de los datos por medio de fundamentos de compresión de datos y revela la más efectiva estructura de baja dimensión de los patrones faciales.

Esta reducción en las dimensiones quita información que no es útil y descompone de manera precisa la estructura facial en componentes ortogonales (no correlativos) conocidos como Eigenfaces. Cada imagen facial puede ser representada como una suma ponderada (vector de rasgo) de los eigenfaces, las cuales son almacenadas en un conjunto 1D. [9]

Una imagen de sondeo es comparada con una galería de imágenes midiendo la distancia entre sus respectivos vectores de rasgos. La aproximación PCA típicamente requiere la cara completa de frente para ser presentada cada vez; de otra forma la imagen dará un resultado de bajo rendimiento. La ventaja primaria de esta técnica es que puede reducir los datos necesarios para identificar el individuo a 1/1000 de los datos presentados. [10]

Se dice que cuando se aplica el modelo IPCA para un punto en específico que es de segmentar los algoritmos con el fin de centrar y normalizar solo los pixeles que ocupan caras para obtener un mejor rendimiento, a su vez se han hecho pruebas con el software matemático MATLAB para realizar los experimentos debidos, y según sus análisis y pruebas dan como resultado que el algoritmo IPCA es mucho más eficiente que el PCA para sus áreas de reconocimiento de los individuos. [8][9][12]

Análisis lineal discriminante (Linear Discriminant Analysis, LDA)

LDA o Linear Discriminant Analysis es una técnica de aprendizaje supervisado para clasificar datos. La idea central de LDA es obtener una proyección de los datos en un espacio de menor (o incluso igual) dimensión que los datos entrantes, con el fin de que la separabilidad de las clases sea la mayor posible. Es una técnica supervisada ya que para poder buscar esa proyección se debe entrenar el sistema con patrones etiquetados. Es importante aclarar que LDA no busca en ningún momento minimizar el error de representación cometido, como si lo hacía PCA. Existen varias implementaciones de LDA, entre ellas se encuentra Fisher-LDA [14]

Formalizando, tenemos $x_1 \dots x_n$ patrones d -dimensionales etiquetados en c clases. Cada clase cuenta con N_c patrones. Se busca w , para obtener $y_i = w^T x_i$ proyecciones unidimensionales de los patrones. Lo que busca Fisher-LDA es maximizar la siguiente función objetivo: [14]

$$J(w) = \frac{w^T S_B w}{w^T S_W w}$$

(4)

Donde S_B es la matriz de dispersión inter-clase y S_W es la matriz de dispersión intra-clase. Siendo más precisos: [14]

$$S_B = \sum_c N_c (\mu_c - \mu)(\mu_c - \mu)^T$$

(5)

$$S_W = \sum_{i \in c} \sum_c N_c (x_i - \mu)(x_i - \mu)^T$$

(6)

Siendo μ_c la media de cada clase, μ la media de todos los datos, N_c la cantidad de patrones de la clase c . Fisher-LDA busca encontrar el vector w de proyección que maximice el “cociente” entre la matriz de dispersión inter-clase y la matriz de dispersión intra-clase. Operando se puede ver que el w que maximiza la función objetivo debe cumplir: [14]

$$S_B w = \lambda S_W w$$

(7)

Si S_W es no singular podemos resolver el clásico problema de valores propios para la matriz $S^{-1} W S B$:

$$S_W^{-1} S_B w = \lambda w$$

(8)

Si ahora sustituimos la solución en (4) obtenemos lo siguiente:

$$J(w) = \frac{w^T S_B w}{w^T S_W w} = \lambda_k \frac{w_k^T S_B w_k}{w_k^T S_W w_k} = \lambda_k \text{ con } k = 1 \dots d$$

(9)

Siendo w_k vector propio k de valor propio λ_k . En consecuencia, para maximizar la solución debemos considerar el vector propio con mayor valor propio asociado. [14]

Análisis de componentes independientes (ICA)

ICA es una herramienta de análisis cuyo objetivo es descomponer una señal observada (imagen de una cara) en una combinación lineal de fuentes independientes. Surge de la técnica conocida por su sigla BSS, o Blind Separation Source, que intenta obtener las fuentes independientes a partir de combinaciones de las mismas. Mientras que PCA de correlaciona las señales de entrada utilizando estadísticos de segundo orden (minimizando el error cuadrático medio de proyección, i.e.: KLT), ICA minimiza mayores ordenes de dependencia. [14]

El número de observaciones $N(1 \leq i \leq N)$ debe ser mayor o igual al número de fuentes originales $M(1 \leq j \leq M)$. En general se utiliza $N = M$. Asumiendo que cada X_j es una combinación desconocida y diferente de los “vectores fuentes” originales, ICA expande cada señal X_j en una suma

ponderada de vectores fuente. Encontramos aquí una fuerte similitud con PCA. [14]
 Sea S la matriz de señales independientes y X la matriz de observación. Si A es la matriz de combinación desconocida, el modelo de combinación se puede escribir como: [15]

$$X = A * S \quad (10)$$

Asumiendo que las señales fuente son independientes unas de las otras y que la matriz A es invertible, el algoritmo ICA tratar de encontrar la matriz de separación W , tal que: [15]

$$U = W * X = W * A * S \quad (11)$$

Donde U : estimación de las componentes independientes.

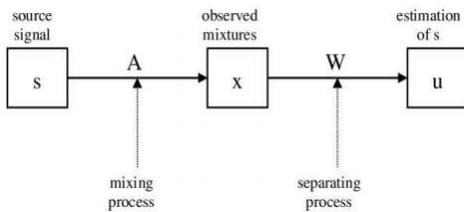


Figura 2: Esquema Blind Source Separation.

La esencia de los algoritmos que implementan ICA es la búsqueda de la matriz W según cierto método iterativo de optimización. Para una matriz U vista como arreglo de vectores, los vectores son estadísticamente independientes cuando [15]

$$f_U(U) = \prod_i f_{U_i}(U_i) \quad (12)$$

En esta implementación de ICA utilizamos el algoritmo FastICA, probablemente uno de los algoritmos más generales, el cual maximiza: [15]

$$J(y) \cong C [E\{G(y)\} - E\{G(v)\}]^2 \quad (13)$$

En donde G : función no cuadrática, v : densidad de probabilidad gaussiana y C es una constante mayor a cero. Se puede demostrar que maximizando una función de estas características se obtiene un óptimo en el sentido de independencia buscado. [15]

FastICA es un algoritmo ampliamente explorado en esta área. Desde el punto de vista de la performance de los algoritmos que implementan ICA se ha demostrado empíricamente que existen diferencias muy pequeñas y que todos obtienen un óptimo muy similar de componentes independientes. [16]

Fisherfaces

Utiliza el Discriminante Lineal de Fisher (FLD) para la reducción de dimensión. Este método selecciona el W de la ecuación de manera que el cociente entre la distribución entre clases y la distribución intra-clases sea máxima. Para esto se define la matriz S_B de distribución entre clases como [17]

$$S_B = \sum_{i=1}^c N_i (\mu_c - \mu)(\mu_c - \mu)^T \quad (14)$$

Y la matriz S_W de distribución intra-clases:

$$S_W = \sum_{i=1}^c \sum_{x_k \in X_i} N_c (x_i - \mu)(x_i - \mu)^T \quad (15)$$

Donde μ_i es la imagen media de la clase X_i , y N_i es el número de imágenes en la clase X_i . Si la matriz S_W es no singular, la proyección W_{opt} se elige como la matriz con columnas ortonormales que maximiza el cociente del determinante de la matriz de distribución entre clases de las imágenes proyectadas y el determinante de la matriz de la distribución intra-clases de las imágenes proyectadas, esto es: [18]

$$W_{opt} = \arg \frac{\max |W^T S_B W|}{|W^T S_W W|} = [w_1, w_2 \dots w_m] \quad (16)$$

Donde $\{w_i | i = 1, 2, \dots, m\}$ es el conjunto de valores propios de S_B y S_W correspondiente a los m mayores valores propios $\{\lambda_i | i = 1, 2, \dots, m\}$, esto es:

$$S_B w_i = \lambda_i S_W w_i, \quad i = 1, 2, \dots, m. \quad (17)$$

Se observa entonces, que a lo sumo se tienen $c - 1$ valores propios distintos de cero, y por lo tanto el límite superior de m es $c - 1$, donde c es el número de clases. Para el problema de reconocimiento de caras, se tiene que la matriz $S_W \in \mathcal{R}^{n \times n}$ es siempre singular, dado que el rango de S_W es a lo sumo $N - c$, y en general, el número de imágenes de entrenamiento: N , es mucho más chico que el número de píxeles de cada imagen: n . Por lo tanto puede ser posible elegir una matriz W tal que la distribución intra-clases de las imágenes proyectadas pueda ser exactamente cero. Como alternativa entonces, al criterio establecido en la ecuación, se proyecta el conjunto de imágenes a un espacio de menor dimensión, de manera que la matriz resultante de la distribución intra-clases S_W es no singular. [17]

Utilizando PCA se realiza la reducción de dimensiones del espacio de características a $N - c$ y luego, aplicar FLD definido en (7) para reducir la dimensión a $c-1$. De esta manera W_{opt} es dado por: [18]

$$W_{pca}^T = W_{fld}^T W_{pca}^T \quad (18)$$

Donde:

$$W_{opt} = \arg \frac{\max}{w} \frac{|W^T W_{pca}^T S_B W_{pca} W|}{|W^T W_{pca}^T S_W W_{pca} W|} \quad (19)$$

IV. CONCLUSIONES

Ciertos modelos de reconocimiento son usados para la autenticación por patrones con fotografías captadas para su debido procesamiento y pasan por algunos logaritmos, estos logaritmos son probados para ver su eficacia y podemos decir que el modelo de eigenfaces en PCA no es tan rápido como su nueva implementación que es el sistema IPCA que hace independiente ya que descompone en ciertos vectores para su análisis y hace que la compresión de imágenes sea más rápida y exacta, ya que el PCA no lo hace porque todo lo hace directamente de un solo vector de datos pero este hace más exacto al momento de su autenticación.

Podemos decir también que según esta información que se filtró en este documento servirá para el uso debido de que algoritmo debemos usar para tomar una sabia decisión al momento de implementarlo.

V. BIBLIOGRAFÍA

- [1] Evaluacion de sistemas de reconocimiento biometrico, Virginia Espinosa Duró, Escuela Universitaria de Mataró,(UPC), Conde, C., & Cabello, E. (2004), Verificacion biometrica facial mediante informacion 2D y 3D. In proceedings-international conference on pattern recognition (Vol. 1, pp. 358-361)
- [2] Super-Fast parallel eigenface implementation on GPU for face recognition, Urvesh Devani, Mumbai, India, Parallel, Distributed and Grid Computing (PDGC), 2014 International Conference on.
- [3] Threats models on biometri systems a comparatri study, Dellys Hachemi Nabil; Benatchba Karima; Koudil Mouloud; Bouridane Ahmed, 2012 Fourth International Conference on Computational Aspects of Social Networks (CASoN).
- [4] A FACE MATCHING METHOD BASED ON BIOMETRIC FOR SURGICAL NAVIGATION SYSTEM, Xiaorui Fang; Xukun Shen; Yong Hu, 2014 International Conference on Virtual Reality and Visualization.
- [5] Human skin detection and face recognition using fuzzy logic and eigenface, Arnav Chowdhury; Sanjaya Shankar Tripathy, 2014 International Conference on Green Computing Communication and Electrical Engineering (ICGCEE).
- [6] SUPER-FAST PARALLEL EIGENFACE IMPLEMENTATION ON GPU FOR FACE RECOGNITION, Urvesh Devani; Valmik B. Nikam; B. B. Meshram, 2014 International Conference on Parallel, Distributed and Grid Computing.
- [7] G. Ottado, «Reconocimiento de caras: Eigenfaces y Fisherfaces,» 2010.
- [8] L. Llorente Gimenez, «<http://s3.amazonaws.com/>,» IEEE, 11 05 1998. [En línea]. Available: http://s3.amazonaws.com/academia.edu.documents/34560314/eigenface_s.pdf?AWSAccessKeyId=AKIAIWOWYYGZ2Y53UL3A&Expires=1485214803&Signature=Z3v3sIn3SoyMc7fN3T4%2Bf%2BMQD5o%3D&response-content-disposition=inline%3B%20filename%3DREPRESENTACION_DE_CARRAS_MEDIANTE. [Último acceso: 10 01 2017]
- [9] M. A. Vicente, O. Reinoso, J. S. C. Pérez y J. Azorín, «RECONOCIMIENTO DE OBJETOS 3D,» Universidad Miguel Hernández, España, 2003

- [10] A. B. M. Díaz, «Reconocimiento Facial Automático mediante Técnicas de Visión Tridimensional,» UNIVERSIDAD POLITÉCNICA DE MADRID, Madrid, 2004.
- [11] Comité de Seguridad Nacional de los Estados Unidos, «biometria.gov.ar,» Consejo Nacional de Ciencia y Tecnología, 08 2006. [En línea]. Available: <http://www.biometria.gov.ar/metodos-biometricos/facial.aspx>. [Último acceso: 14 01 2017]
- [12] PERFORMANCE EVALUATION OF THE PCA VERSUS IMPROVED PCA (IPCA) IN IMAGE COMPRESSION, AND IN FACE DETECTION AND RECOGNITION, Abdulaziz A. Alorf, 2016 Future Technologies Conference (FTC)
- [13] N. Lopez Perez y J. J. Toro Agudelo , «TECNICAS DE BIOMETRIA BASADAS EN PATRONES FACIALES DEL SER,» Universidad de Pereira , Colombia, 2012.
- [14] M. Delbracio y M. Mateu, «Trabajo Final de Reconocimiento de Patrones: Identifiación utilizando PCA, ICA y LDA,» 2006.
- [15] Helsinki University of Technology, «Laboratory of Computer and Information Science (CIS),» 2008.
- [16] R. Beveridge y . B. Draper, «<http://www.cs.colostate.edu/>,» 23 06 2010. [En línea]. Available: <http://www.cs.colostate.edu/evalfacerec/index10.php>. [Último acceso: 25 01 2017].
- [17] J. Ruiz del Solar y P. Navarrete, « Analysis and comparison of eigenspace-based face recognition approaches. International Journal of Pattern Recognition and Artificial Intelligence,» 2002.
- [18] H. Cho y S. Moon, « Comparison of pca and lda based face recognition algorithms under illumination variations,» 2009.

VI. BIOGRAFÍA

Jhosselyn Lissbeth Cabrera Sarmiento

Nació un 29 de abril de 1996 en el cantón Limón Indanza provincia de Morona Santiago, actualmente tiene 20 años, es la segunda hija de cuatro, sus padres se llaman José Benjamín Cabrera López y Narcisa de Jesús Sarmiento Jara quienes dan todo para que sus hijos tengan una buena educación. Creció en un ambiente de unión, comprensión y apoyo por parte de todos los integrantes de su familia. Desde pequeña lucha por cumplir sus metas, no se da por vencida y su mayor orgullo son sus padres.

Curso el jardín de niños en la Unidad Educativa “Simón Bolívar Jácome”, posteriormente la primera en la Unidad Educativa Salesiana “Albino del Curto”, culminando sus estudios



secundarios en el Colegio Técnico Fisco misional “Rio Santiago”, actualmente se encuentra cursando el tercer año de la carrera de Ing. Eléctrica en la Universidad Politécnica Salesiana - Sede Cuenca.

Uno de sus mayores anhelos es poder colaborar en su hogar, a sus hermanos ya que tiene muy presente el esfuerzo que sus padres hacen por ella, junto con los perances que pueden tener cada miembro de su familia. Está segura de cumplir la meta de ser una profesionista seguir con sus estudios y colaborar a las personas que tiene muchas necesidades, sabe que en este mundo es difícil salir adelante pero con esfuerzo y dedicación todo es posible.

Miguel Patricio Solis Peña



Nació el 22 de Septiembre de 1993 en la ciudad de Cuenca – Ecuador, en la actualidad tiene 23 años, es el segundo hijo de dos, actualmente estudia en la Universidad Politécnica Salesiana (Sede Cuenca), cursa en el tercer año de la carrera de Ingeniería Electrónica en Telecomunicaciones, el junto a unos compañeros de universidad y colegio tienen una empresa (DROT) de ensamblaje y programación de drones(vehículos no tripulados), también por el momento es profesor de talleres en programación de controladores Arduino.