

Sensor Fusion for Distance Estimation Under Disturbance with Reflective Optical Sensors Using Multi Layer Perceptron (MLP)

J. Mesa, D. Betancur-Vasquez, *Member, IEEE*, J. Botero-Valencia, and J. Valencia-Aguirre

Abstract—There are many methods to perform distance measurement, among them the reflexive optical sensors, which are low cost but present some issues such as nonlinear response, limited operating ranges and the measurement shows sensitivity to infrared or visible radiation. For this reason, this work presents a sensory fusion model combining three reflective optical distance sensors of different ranges, a color sensor (VIS), an ultraviolet radiation sensor (UV) and an Near infrared sensor (NIR) to estimate the distance using a Multi Layer Perceptron (MLP). The purpose of combining different distance sensors is to have a higher overall range and achieve redundancy in some regions, and the objective of the UV-VIS-NIR sensors is to compensate for the radiation at which the distance sensors are exposed to adjust the measurement. With the attained information, the influence of each type of radiation on the distance measurement was evaluated. It is important to estimate the distance in these ranges because in robotics and automation industries, different associated applications are handled. The MLP was trained switching its architecture between four and sixteen neurons per layer, and between three and five hidden layers. Finally the training and selection of several MLP architectures for sensory fusion with an error lower than 1% was presented.

Index Terms—Distance estimation, Infrared sensor, Multi Layer Perceptron (MLP), Reflective optical sensor, Sensor fusion.

I. INTRODUCCIÓN

LOS sistemas automáticos se han convertido en parte esencial de diferentes escenarios, siendo el sector industrial y manufacturero uno de los más importantes. Dentro de los procesos de automatización, los sensores juegan un papel fundamental dado que son los encargados de proporcionar la información del entorno que será utilizada para la toma de decisiones y debido a su importancia, se ha aumentado el interés en desarrollar gran variedad de sensores empleando diferentes tecnologías. En este sentido, se ha comprobado que integrar adecuadamente la información proveniente de múltiples sensores puede proporcionar información más confiable y precisa que al emplear sensores de forma individual [1], [2], [3]. Este enfoque, es conocido como fusión sensorial o fusión de datos [4], [5], [6].

J. Mesa, Grupo AEyCC, Facultad de Ingenierías, Instituto Tecnológico Metropolitano ITM, Medellín, Colombia, mesajoao@gmail.com.

D. Betancur, Grupo AEyCC, Facultad de Ingenierías, Instituto Tecnológico Metropolitano ITM, Medellín, Colombia, danielbetancur@itm.edu.co.

J. S. Botero, Grupo AEyCC, Facultad de Ingenierías, Instituto Tecnológico Metropolitano ITM, Medellín, Colombia, juanbotero@itm.edu.co.

J. Valencia, Grupo AEyCC, Facultad de Ingenierías, Instituto Tecnológico Metropolitano ITM, Medellín, Colombia, julianavalencia@itm.edu.co.

Para realizar la fusión de los datos se han empleado técnicas tales como los filtros de Kalman, la lógica difusa y el aprendizaje de máquina [7], [8], [9], [10], [11]. En la literatura también se encuentran propuestas para realizar compensación de medidas indirectas, tal como se presenta en [12]. Por otro lado, las redes neuronales artificiales han surgido como una excelente herramienta para fusión de datos de múltiples sensores [13], y se han empleado en aplicaciones como diagnóstico de fallas y monitoreo [14], [15], [16], [17], [18]. Sin embargo, a pesar de las ventajas de la fusión sensorial tanto la incertidumbre como la imprecisión siguen formando parte del proceso de recolección información a través de sensores, dado que condiciones del entorno tales como fallas de los dispositivos, problemas de comunicación e incluso condiciones climáticas, pueden influir en este aspecto. Es así, como aún existen una serie de problemas que hacen que la fusión de datos sea una tarea desafiante y la mayoría de estos problemas surgen de los datos a fusionar, la imperfección y la diversidad de las tecnologías de sensores [5], [19], por lo que se hace necesario considerar variables externas y cuantificar algunas de las perturbaciones con el fin de realizar el ajuste del valor final de la medida al cuantificar.

En este trabajo se propone un modelo de fusión sensorial que combina la información proveniente de tres sensores de distancia óptico reflexivos de bajo costo, cuyo desempeño usualmente se ve afectado por su respuesta no lineal, sus rangos de trabajo limitados y su sensibilidad a las perturbaciones por radiación infrarroja o visible. Los rangos de funcionamiento de los sensores elegidos son diferentes, pero presentan áreas de redundancia con el fin de generar una salida más exacta. Además de los sensores de distancia, también es considerada la información proveniente de un sensor de color (VIS), un sensor de radiación ultravioleta (UV) y un sensor de radiación infrarroja (IR). El propósito de usar estos sensores complementarios es cuantificar el nivel de las perturbaciones externas y brindar información al sistema para aplicar la compensación. Un Perceptrón Multicapa (Multi Layer Perceptron -MLP) [20] fue empleado para estimar la medida de distancia, considerando como entrada la información proveniente de los 6 sensores, de manera que la respuesta de la red compensen las perturbaciones debidas a la presencia de radiación externa, como se ha utilizado en otras investigaciones [21]. Además, se han visto diferentes aplicaciones de las redes neuronales artificiales en recientes estudios, para el uso cotidiano en la industria y espacios cerrados [22][23].

Para obtener un conjunto de entrenamiento representativo,

se adquirieron datos con un actuador lineal como referencia y se realizaron experimentos en presencia de diferentes fuentes de radiación externas que afectan la medida de los sensores de distancia. Se realizaron pruebas con dos funciones activación para el MLP, ajustando también la cantidad de capas ocultas y la cantidad de neuronas por capa. Los resultados obtenidos demuestran que emplear la información proveniente de los sensores VIS, UV e IR permite compensar la medida de forma adecuada para contrarrestar las perturbaciones que se pueden presentar debido a las condiciones de iluminación.

En la Sección II del documento se presentan los materiales y la metodología utilizada para crear la base de datos. En la Sección II-D se describe el desarrollo del experimento y se discuten los resultados más importantes. Por último se presentan las conclusiones generales del trabajo desarrollado.

II. MATERIALES Y MÉTODOS

A. Sensores de Distancia

Los sensores GP2Y0A41SK0F (S_1), GP2Y0A21YK0F (S_2) y GP2Y0A02YK0F (S_3) son sensores de distancia infrarrojos ópticos reflexivos. Estos utilizan una combinación integrada de un *Position Sensitive Detector* (PSD), un *Infrared Emitting Diode* (IRED) y un circuito de procesamiento de señales, que mezclado con el método de triangulación hace que factores como el tiempo de funcionamiento y la temperatura del ambiente tengan menor influencia en la medida. En la Figura 1 se muestran los sensores de distancia y en la Tabla I se presentan las especificaciones técnicas más significativas.



Fig. 1. a) GP2Y0A02YK0F b) GP2Y0A21YK0F y c) GP2Y0A41SK0F.

TABLA I
CARACTERÍSTICAS DE LOS SENSORES ÓPTICOS IR

| Referencia | GP2Y0A02YK0F | GP2Y0A21YK0F | GP2Y0A41SK0F |
|-------------|--------------|--------------|--------------|
| Rango | 3 a 40 cm | 10 a 80 cm | 20 a 150 cm |
| Voltaje | 4.5 a 5.5 V | 4.5 a 5.5 V | 4.5 a 5.5 V |
| Interfaz | Análoga | Análoga | Análoga |
| Corriente | 30 mA | 30 mA | 33 mA |
| Temperatura | -10 a 60 °C | -10 a 60 °C | -10 a 60 °C |

B. Sensores UV-VIS-NIR

En cuanto a las medidas de radiación, el primer módulo usa el sensor GUAVA-S12D que cuenta con una amplia gama espectral, este es comúnmente usado para detectar la intensidad UV. El segundo es un módulo VIS-NIR basado en el sensor de luminosidad TSL2561, que mide intensidad VIS y la convierte en una señal digital con una interfaz I2C directa. Combinando dos foto-diodos en un solo circuito integrado CMOS, logra medir por separado la luz ambiente en el espectro visible y la componente IR. Adicionalmente, es utilizado un sensor VIS RGB TCS3200 con protección y lente, el cual es un

convertidor de luz a frecuencia que combina fotodiodos de silicio reconfigurables y un convertidor de corriente a frecuencia en un único circuito integrado monolítico CMOS. Tiene un arreglo de foto-detectores, cada uno con filtro rojo, verde, azul o transparente, y la salida es una onda proporcional a la intensidad de la luz (irradiancia). En la Figura 2 se muestran los sensores de radiación y en la Tabla II se muestran sus características más relevantes.




Fig. 2. De izquierda a derecha: Sensor UV, Sensor VIS-NIR, Sensor de color RGB.

TABLA II
CARACTERÍSTICAS DE LOS SENSORES DE LUZ

| Referencia | GUVA-S12SD | TSL2561 | TCS3200 |
|-----------------|--------------|--------------|-----------------------|
| Rango espectral | 240 a 370 nm | 750 a 850 nm | Ver siguiente párrafo |
| Voltaje | 3.0 a 5.1 V | 3.3 a 5.1 V | 2.7 a 5.5 V |
| Interfaz | Análoga | I2C | Digital TTL |
| Corriente | 0.31 mA | 0.4 a 0.6 mA | 1.4 a 2 mA |
| Temperatura | -30 a 85 °C | -30 a 70 °C | -40 a 70 °C |

Los valores del rango espectral del sensor TCS3200 son: rojo: 600 a 850 nm, verde: 850 a 900 nm, azul: 850 a 1000 nm. Debido que este sensor cuenta con 3 canales que reciben luz RGB.

C. Sistema de Posicionamiento y Ensamble

Un sistema de desplazamiento lineal de alta precisión fue empleado con el fin de tener una referencia confiable de la distancia entre los sensores y la superficie reflectante. Adicionalmente, este sistema fue utilizado para construir el conjunto de entrenamiento de forma automática.

Como se observa en el esquema de la Figura 3, el sistema utiliza un tornillo sin fin (7) que genera un recorrido de 900 mm con la ayuda de un motor paso a paso (8) controlado mediante un Microstep ST-M5045, el cual está configurado para una resolución de 0.18 °. Sobre el eje lineal se encuentran los tres sensores de distancia (1, 2 y 3) y los tres sensores de radiación UV-NIR-VIS (4, 5, 6), cuyas mediciones son empleadas para entrenar el MLP.




Fig. 3. Diagrama del sistema de posicionamiento lineal con los diferentes sensores.

Por otro lado, en la Figura 4 se presenta el diseño mecánico en el cual los sensores fueron posicionados estratégicamente para la toma de los datos. Se puede observar que los sensores de distancia y de radiación se ubican en el mismo plano teniendo en cuenta que se pretende que la información de radiación sirva como información para corregir la medida de distancia. El montaje entonces se desplazaba por medio de un motor paso a paso de alta precisión y un tornillo sin fin de paso 1.25, el cual se muestra en la figura 3, (el motor no se muestra en la figura, se encuentra acoplado al tornillo sin fin).




Fig. 4. Montaje mecánico para la adquisición de datos.

D. Conjunto de Entrenamiento

El proceso de adquisición de datos se realiza tomando 20 muestras cada 1 cm, desplazando el sistema en el rango entre 3 cm a 90 cm. Los sensores se ubican de forma que se encuentren bajo la misma radiación, puesto que la posición de la fuente en un ambiente real sería desconocida. Adicionalmente, las condiciones de iluminación fueron modificadas para conocer su influencia en la respuesta de los diferentes sensores de distancia.

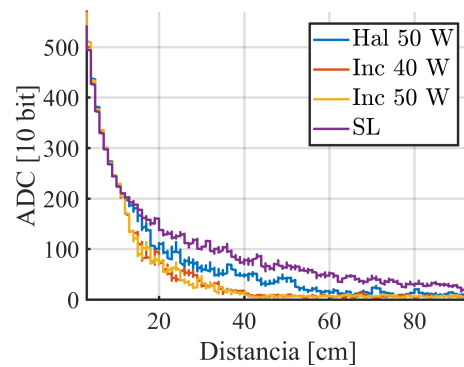
Por tal motivo, el procedimiento de adquisición fue repetido cuatro veces, una por cada fuente de luz: Halógena 50 W (HAL 50 W), Incandescente de 40 W (Inc 40 W), Incandescente 50 W (Inc 50 W) y sin presencia de luz (SL). Así se obtiene un conjunto de datos $\mathbf{X}_{1820 \times 10}$ donde las columnas de \mathbf{X} están conformadas por las señales provenientes de los diferentes sensores en el siguiente orden: $[S_1 S_2 S_3 UV VIS_1 NIR_1 R G B T]$.

La información suministrada por los sensores de UV-VIS-NIR muestra cambios significativos en los datos NIR en comparación a los de UV y VIS, comprobando que la respuesta de los sensores ópticos reflexivos es afectada por la luz infrarroja en mayor proporción. Como información adicional, la condición ambiental del experimento se mantuvo con un sistema de aire acondicionado controlado, con un set point de 25 grados centígrados. En la Tabla III se describe la arquitectura empleada para las diferentes fuentes de luz, cada una de las cuales fue probada variando la cantidad de capas ocultas entre tres, cuatro y cinco. El propósito de entrenar diferentes arquitecturas, es encontrar un compromiso entre rendimiento y el tamaño de la implementación, es decir, el error y la capacidad de cálculo necesaria para el despliegue de la red. El entrenamiento de las diferentes arquitecturas se hizo empleando Matlab®2018b y el Deep Learning Toolbox version 12.0.

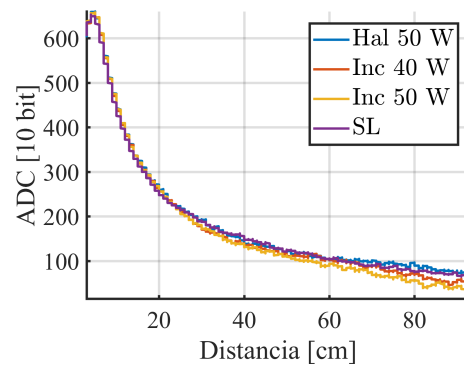
TABLA III
ARQUITECTURAS DE ENTRENAMIENTO

| Tipo de luz | Número de neuronas por capa | | | | |
|-----------------------|-----------------------------|---|----|----|----|
| Luz Incandescente 40W | 4 | 8 | 12 | 16 | 20 |
| Luz Halógena | 4 | 8 | 12 | 16 | 20 |
| Luz incandescente 50W | 4 | 8 | 12 | 16 | 20 |
| Sin luz | 4 | 8 | 12 | 16 | 20 |


En la Figura 5, se muestra la curva de respuesta de cada sensor respecto a cada fuente de iluminación. Se puede observar que la influencia de la iluminación afecta significativamente la respuesta del sensor, aunque la respuesta del sensor no es lineal, esta no debería cambiar en diferentes condiciones de iluminación.



(a) S1



(b) S2



(c) S3

Fig. 5. Respuesta de los sensores.

Por otra parte, en la Figura 6 se observa la cuantificación de radiación infrarroja a la que se encuentra expuesto el sistema para cada una de las fuentes de luz. Como se puede observar radiación IR de la fuente Halógena es alta en comparación con las fuentes Incandescentes.




Fig. 6. Radiación Infrarroja (IR).

III. RESULTADOS

En la sección III-A se presentan los resultados obtenidos al evaluar el desempeño del Perceptrón Multicapa (MLP) variando sus parámetros, de manera que se encuentre la arquitectura con el mejor desempeño de acuerdo con el criterio elegido para su evaluación. Por otra parte, en la sección III-B se presenta la respuesta al emplear los dos tipos de fuentes mas significativas en el experimento, de manera que sea posible conocer su influencia en el desempeño del MLP.

A. Entrenamiento

Como se mencionó anteriormente, diferentes arquitecturas de un MLP fueron entrenadas variando tanto la cantidad de capas ocultas como la cantidad de neuronas por capa. Adicionalmente, fueron consideradas dos funciones de activación, la función Tangencial Sigmoidica (tansig) y la función Lineal (purelin) obteniendo finalmente quince arquitecturas para cada tipo de función de activación.

Variar los parámetros del MLP hace posible conocer ventajas de desempeño de la red con respecto al tiempo de computo y al porcentaje de error obtenido. En este trabajo, el criterio utilizado para establecer la mejor arquitectura fue el error cuadrático medio (Mean Square Error - MSE).

Por otra parte, es importante destacar que los MLP permiten fusionar información proveniente de diferentes fuentes y al tiempo realizar tareas de filtrado o discriminación. Esto se logra a través del proceso de entrenamiento y las correlaciones que el MLP pueda encontrar entre las entradas y la salida deseada, razón por la cual la capacidad de ajuste está directamente ligada a la construcción del conjunto de entrenamiento. En este caso y como ventaja del método presentado, la implementación de la adquisición de las muestras sobre un sistema de posicionamiento automático permite la construcción de un conjunto de datos grande y un posterior ajuste o adaptación de la red si se requieren evaluar nuevas perturbaciones.

La Tabla IV muestra el desempeño de la red para la función Tangencial Sigmoidica. El MSE es obtenido al comparar la respuesta del MLP versus la línea de referencia, la cual es obtenida con base en el incremento mínimo del motor paso a paso de alta precisión. De acuerdo con los resultados obtenidos se observa que en general el error se reduce al aumentar la cantidad de neuronas por capa, sin embargo, se presenta una excepción para la arquitectura con 3 capas ocultas, dado que en este caso el error más alto se obtuvo con 12 neuronas. Como se puede observar, para esta función de activación el error mas bajo se obtiene con 5 capas ocultas y 16 neuronas por capa con un MSE de 0,96%. Las siguientes tablas muestran el error de entrenamiento de las diferentes redes, diferente al error de validación que se muestra en la sección de validación.

TABLA IV
MSE - FUNCIÓN TANGENCIAL SIGMOIDEA

| Neuronas por capa | Número de capas ocultas | | |
|-------------------|-------------------------|------|------|
| | 3 | 4 | 5 |
| 4 | 1,32 | 3,84 | 4,49 |
| 8 | 1,05 | 1,06 | 4,55 |
| 12 | 3,66 | 1,03 | 1,33 |
| 16 | 1,09 | 0,98 | 0,96 |
| 20 | 1,02 | 1,04 | 1,16 |

De igual forma, en la Tabla V se presenta el desempeño para la función Lineal. En este caso se obtiene el menor error para la arquitectura con 5 capas ocultas y 12 neuronas por capa, con un MSE de 6,57%. No obstante, las variaciones en la cantidad de capas ocultas y la cantidad de neuronas por capa no genera cambios significativos en el desempeño final del sistema, y en general el valor del error es mayor en comparación con la función Tangencial Sigmoidica. A pesar de la diferencia en el desempeño se consideró necesario y oportuno evaluar el comportamiento de la función Lineal debido a su bajo costo computacional y a la facilidad de implementación en sistemas embebidos.

TABLA V
MSE - FUNCIÓN LINEAL

| Neuronas por capa | Número de capas ocultas | | |
|-------------------|-------------------------|------|------|
| | 3 | 4 | 5 |
| 4 | 6,68 | 6,64 | 6,64 |
| 8 | 6,62 | 6,63 | 6,62 |
| 12 | 6,64 | 6,61 | 6,57 |
| 16 | 6,62 | 6,61 | 6,63 |
| 20 | 6,63 | 6,62 | 6,68 |

B. Validación de Arquitectura Implementada

A continuación, se presenta la respuesta simulada de la red en la salida del conversor análogo digital (ADC) con respecto al valor de la distancia real para la función Tangencial Sigmoidica y para la función Lineal. En ambos casos se muestran los resultados tanto con iluminación halógena como con iluminación incandescente. La información entonces representa la implementación de la red entrenada anteriormente, dividiendo los datos en 70% para el entrenamiento y 30% para la validación. Como dato adicional, la validación se realizó fuera de línea, en un procesador Intel core i7.

La respuesta mostrada en las figuras 7, 8, 9 y 10 corresponden a las arquitecturas con 5 capas ocultas. Adicionalmente, las gráficas presentan las medidas entregadas por los sensores S2 y S3 (respuesta original), filtrados previamente con el cálculo de una función exponencial doble, para luego promediar los datos de manera que se realice un suavizado de los mismos. La respuesta ideal del sensor, que es el propósito de este trabajo, es que la respuesta del MLP obedezca a una función lineal y que esta no se perturbe por la radiación de fuentes externas.

En la Figuras 7 y 8 se encuentran los resultados obtenidos para las arquitecturas del MLP evaluadas con la fuente de iluminación halógena y los dos tipos de funciones de activación. En este sentido, se puede observar que algunas arquitecturas presentan menor dispersión en su comportamiento de acuerdo con la función de activación empleada, y como se mencionó en la sección anterior la función de activación Lineal presenta errores más altos que la función Tangencial Sigmoidea.

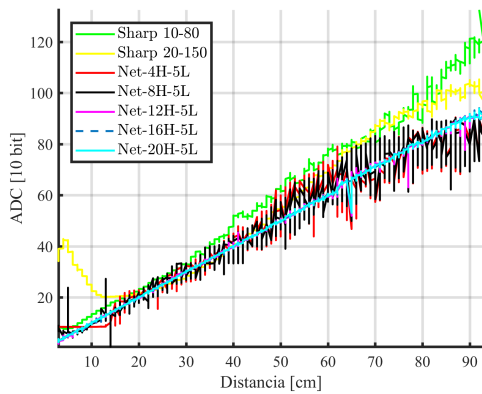


Fig. 7. Iluminación HAL - TANSIG.




Fig. 8. Iluminación HAL - LIN.

En las Figuras 9 y 10 se hace evidente que con la fuente de luz incandescente se aumenta el error de la medida en los sensores, en comparación con la respuesta de los mismos a la fuente de luz halógena. Por ejemplo, para el valor de distancia de 90 cm con la luz halógena el sensor S2 genera una medida cercana a 120, mientras que con la luz incandescente la salida del sensor esta alrededor de 200. Este error en la medida de los

sensores se reduce en un porcentaje considerable al emplear el MLP entrenado con las señales de los múltiples sensores, para las dos fuentes de luz y para las dos funciones de activación. Sin embargo, en las figuras también es posible observar que la salida de la red entrenada con la función Tangencial Sigmoidea es muy cercana a la respuesta ideal, a diferencia de la respuesta del sistema entrenado con la función Lineal.

También es posible observar que la respuesta de las redes frente al cambio en el tipo de fuente de luz no genera perturbaciones importantes, demostrando que las mismas realizan una buena compensación.




Fig. 9. Iluminación INC - TANSIG.

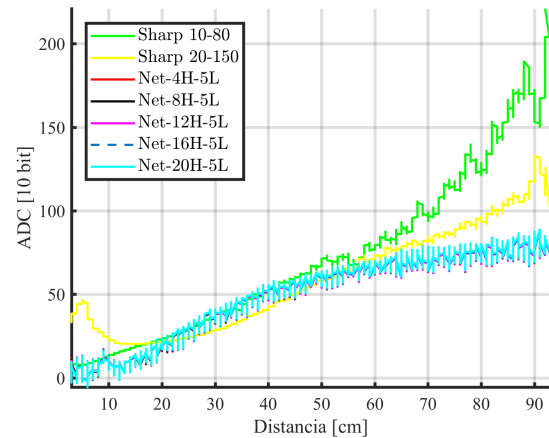


Fig. 10. Iluminación INC - LIN.

IV. CONCLUSIONES

En la búsqueda de la adquisición de datos por medio de sensores de bajo costo, la implementación de modelos de estimación basados en fusión sensorial y utilizando MLP ayudan a mejorar la precisión de las medidas, llegando a un error cuadrático medio de 0.96%.

Se evidenció que, después de realizar la toma de datos con diferentes fuentes de radiación, la luz incandescente afecta el desempeño de este tipo de sensores, y también se hizo evidente como el MLP tiene la capacidad compensar este tipo de perturbaciones.

Las arquitecturas utilizadas ofrecen tanto las alternativas para el bajo costo computacional usando la función lineal, como las de mayor robustez para una mayor precisión y exactitud de la respuesta con la función Tangencial Sigmoidea. Dado al previo entrenamiento de la red, es posible implementar el método en sistemas embebidos de bajo costo, logrando aprovechar los recursos de procesamiento en otras tareas y aumentar la frecuencia de muestreo de datos.

REFERENCIAS

- [1] H. You, G. Xin, and W. Guo-hong, "Survey on the progress and prospect of multi-sensor information fusion," *Journal of Aeronautics*, no. 26, pp. 524–530, 2005.
- [2] F. Xiao, "Multi-sensor data fusion based on a generalised belief divergence measure," jun 2018. [Online]. Available: <http://arxiv.org/abs/1806.01563>
- [3] B. Moshiri, "Tutorial A: Sensor data fusion, principles and applications," in *2010 International Symposium on Optomechatronic Technologies*. IEEE, oct 2010, pp. 1–2. [Online]. Available: <http://ieeexplore.ieee.org/document/5687380/>
- [4] H. B. Mitchell, *Data Fusion: Concepts and Ideas*, 2nd ed. Springer Berlin Heidelberg, 2012.
- [5] B. Khaleghi, A. Khamis, F. O. Karray, and S. N. Razavi, "Multisensor data fusion: A review of the state-of-the-art," *Information Fusion*, vol. 14, no. 1, pp. 28 – 44, 2013.
- [6] H. Durrant-Whyte and T. C. Henderson, "Multisensor Data Fusion," in *Springer Handbook of Robotics*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, pp. 585–610. [Online]. Available: http://link.springer.com/10.1007/978-3-540-30301-5_26
- [7] R. Gravina, P. Alinia, H. Ghasemzadeh, and G. Fortino, "Multi-sensor fusion in body sensor networks: State-of-the-art and research challenges," *Information Fusion*, vol. 35, pp. 68 – 80, 2017.
- [8] N.-E. E. Faouzi and L. A. Klein, "Data fusion for its: Techniques and research needs," *Transportation Research Procedia*, vol. 15, pp. 495 – 512, 2016, international Symposium on Enhancing Highway Performance (ISEHP), June 14-16, 2016, Berlin.
- [9] J. A. Duro, J. A. Padget, C. R. Bowen, H. A. Kim, and A. Nassehi, "Multi-sensor data fusion framework for cnc machining monitoring," *Mechanical Systems and Signal Processing*, vol. 66, pp. 505 – 520, 2016.
- [10] T. Schlegl, T. Bretterkieber, M. Neumayer, and H. Zangl, "A novel sensor fusion concept for distance measurement in automotive applications," in *2010 IEEE Sensors*, Nov 2010, pp. 775–778.
- [11] "Multisensor Data Fusion," Tech. Rep. [Online]. Available: <http://www.alaakhamis.org/teaching/SPC418/reading/AdvancedReading.pdf>
- [12] I. Aldaya, G. Campuzano, C. Del-Valle-Soto, A. Aragón-Zavala, and G. Castañón, "Impact of the mobile terminal scheme on millimeter-wave radio over fiber systems based on photonic heterodyning techniques," *Optical and Quantum Electronics*, vol. 49, no. 6, p. 228, may 2017. [Online]. Available: <https://doi.org/10.1007/s11082-017-1058-8>
- [13] K. Kolanowski, A. Świetlicka, R. Kapela, J. Pochmara, and A. Rybarczyk, "Multisensor data fusion using Elman neural networks," *Applied Mathematics and Computation*, vol. 319, pp. 236–244, feb 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0096300317301352>
- [14] Z. Liu, W. Zhang, S. Lin, and T. Q. S. Quek, "Heterogeneous sensor data fusion by deep multimodal encoding," *IEEE Journal of Selected Topics in Signal Processing*, vol. 11, no. 3, pp. 479–491, April 2017.
- [15] L. Jing, T. Wang, M. Zhao, and P. Wang, "An adaptive multi-sensor data fusion method based on deep convolutional neural networks for fault diagnosis of planetary gearbox," *Sensors*, vol. 17, no. 2, 2017. [Online]. Available: <http://www.mdpi.com/1424-8220/17/2/414>
- [16] L. Zhang and H. Gao, "A deep learning-based multi-sensor data fusion method for degradation monitoring of ball screws," in *2016 Prognostics and System Health Management Conference (PHM-Chengdu)*, Oct 2016, pp. 1–6.
- [17] A. Potdar, A. P. Longstaff, S. Fletcher, and N. S. Mian, "Application of multi sensor data fusion based on principal monitoring," in *Laser Metrology and Machine Performance XI, LAMDAMAP 2015*. Huddersfield, UK: EUSPEN, March 2015, pp. 228–237.
- [18] J. S. Botero-Valencia and L. J. Morantes-Guzmán, "Estimación de distancia con sensores ópticos reflexivos usando redes neuronales con funciones de base radial para aplicaciones embebidas," *Ingeniería y Universidad*, vol. 17, pp. 27 – 40, 06 2013.
- [19] D. Liu, Y. Zhu, N. Ni, and J. Liu, "Ordered proposition fusion based on consistency and uncertainty measurements," *Science China Information Sciences*, vol. 60, no. 8, p. 082103, Jul 2017. [Online]. Available: <https://doi.org/10.1007/s11432-016-9101-8>
- [20] R. Kruse, C. Borgelt, F. Klawonn, C. Moewes, M. Steinbrecher, and P. Held, *Multi-Layer Perceptrons*. London: Springer London, 2013, pp. 47–81.
- [21] L. H. G. Patire, N. B. F. Silva, and K. R. L. J. C. Branco, "Data Fusion Techniques Applied to Takeoff and Landing Procedures – A VTOL Case Study," vol. 14, no. 9, pp. 3962–3966, 2016.
- [22] E. M. Kakihata, H. M. Sapia, R. T. Oiakawa, D. R. Pereira, J. P. Papa, V. H. C. De Albuquerque, and F. A. Da Silva, "Intrusion Detection System Based on Flows Using Machine Learning Algorithms," *IEEE Latin America Transactions*, vol. 15, no. 10, pp. 1988–1993, 2017.
- [23] A. S. Brandão and D. C. Jorge, "Artificial Neural Networks Applied to Image Steganography," *IEEE Latin America Transactions*, vol. 14, no. 3, pp. 1361–1366, 2016.



de sistemas informáticos.

J. Mesa Ingeniero Mecatrónico, con formación integral, capacidad de análisis e intervención en los sistemas y equipos que integran la mecánica y la electrónica, la informática y el control automático. Destrezas en el diseño e implementación de equipos, sistemas automáticos y automatización de procesos (RPA), conocimiento en domótica e inmótica, medición e instrumentación industrial e instrumentación aplicada en el campo de la investigación; modelamiento, simulación y el control automático de variables, mediante la incorporación



D. Betancur-Vásquez Ingeniero Mecatrónico del Instituto Tecnológico Metropolitano, y candidato a Magister en Automatización y Control Industrial, con experiencia en sistemas de control y robótica, específicamente en robótica móvil, prototipado mecánico y desarrollo electrónico. Actualmente es Docente en el Departamento de Electrónica y Telecomunicaciones de la Facultad de Ingeniería del Instituto Tecnológico Metropolitano y laboratorista en el Laboratorio de Sistemas de Control y Robótica de la misma institución.



J. S. Botero-Valencia Magister en Automatización y Control Industrial, y candidato a doctor en Ingeniería, tiene experiencia en sistemas de control y robótica, específicamente en Internet de las cosas (IoT) y robótica móvil. Actualmente se desempeña como Docente del Departamento de Mecatrónica y Electromecánica de la Facultad de Ingeniería del Instituto Tecnológico Metropolitano, y pertenece al laboratorio de Sistemas de Control y Robótica.



J. Valencia-Aguirre Ingeniera Electrónica y Magister en Ingeniería-Automatización Industrial de la Universidad Nacional de Colombia sede Manizales, donde adquirió experiencia en métodos de aprendizaje de máquina, reconocimiento de patrones y manejo de sistemas de captura de movimiento. Actualmente se desempeña como Docente del Departamento de Mecatrónica y Electromecánica de la Facultad de Ingeniería del Instituto Tecnológico Metropolitano, y pertenece al laboratorio de Sistemas de Control y Robótica.