

Uso de SVM para detección de fallas en una unidad controladora de luz LED

Jorge L. Gutiérrez Palomino, Óscar Hernández-Uribe

Centro de Tecnología Avanzada,
Posgrado CIATEQ A.C.,
México

jorgeluis.gutierrezpalomino@gmail.com,
oscar.hernandez@ciateq.mx

Resumen. Los algoritmos de aprendizaje automático supervisado son cada vez más usados utilizados para resolver problemas de clasificación y predicción en la industria automotriz. En el desarrollo de sistemas de iluminación para el automóvil, como lo son las Unidades Controladoras de luz LED es común desarrollar algoritmos para la detección de fallas de sus propios sensores y/o dispositivos internos; por lo que su detección depende de una correcta caracterización del algoritmo. Por lo que el presente experimento hace uso de los algoritmos de clasificación máquinas de vectores de soporte y regresión logística para el modelado del algoritmo de detección de fallas del tipo circuito abierto en una matriz LED. Dentro de los resultados obtenidos, se identifican las variables con mayor relación para la detección de la falla anteriormente mencionada, así como su exactitud y precisión en escenarios de atenuación de luminosidad donde el algoritmo presenta vulnerabilidad.

Palabras clave: Aprendizaje automático, falla circuito abierto, controlador LED.

Using SVM for Fault Detection in a LED Light Controller Unit

Abstract. Supervised machine learning algorithms are increasingly used to solve classification and prediction problems in the automotive industry. In the development of automotive lighting systems, such as LED Light Controller Units, it is common to develop algorithms for detecting faults in their own sensors and/or internal devices; therefore, their detection depends on a correct characterization of the algorithm. This experiment uses support vector machine and logistic regression classification algorithms to model an open-circuit fault detection algorithm in an LED array. The results identify the variables most closely related to the detection of the aforementioned fault, as well as its accuracy and precision in dimming scenarios where the algorithm exhibits vulnerability.

Keywords: Machine learning, open-circuit fault, LED controller.

1. Introducción

La industria automotriz está creando sistemas eléctricos y electrónicos cada vez más complejos, que deben cumplir con normas para garantizar su funcionamiento y la seguridad de las personas [1]. Además, se está enfocando en la eficiencia y reducción de costos integrando soluciones con el internet de las cosas (IoT) y la inteligencia artificial [2]. Por ejemplo, Kumar y Jain [3] usan máquinas de vectores de soporte (SVM), para clasificar el comportamiento de conducción de un conductor (consumo de combustible, patrones de frenado, estabilidad de dirección y velocidad). Gong et al. [4] proponen un modelo de aprendizaje profundo (DL) aplicado a la predicción de fallas, tales como funcionamiento anormal del motor. Abdulkareem et al. [5] presentan un análisis usando SVM para la detección de fallos en los sensores de velocidad en vehículos. Safavi et al. [6] utilizan dos arquitecturas de DL y SVM, y Biddle y Fallah [7] usan solo SVM, ambos se enfocan en la detección, aislamiento e identificación de fallas en sistemas multisensores, tales como fallas erráticas en la presión de frenado y ángulo del volante. Kaplan et al. [8] muestra un modelo DL de diagnóstico de fallas en motores de inducción, tales como cortocircuito y circuito abierto.

En México, Continental Automotive cuenta con 21 locaciones de las cuales 3 son centros de desarrollo especializados en el diseño de productos electrónicos para el automóvil [9]. Dentro de su portafolio de productos cuenta con unidades controladoras de luz LED, la cuales son capaces de controlar tiras de LED con voltajes de hasta 75V [10]. La tecnología LED ha tenido gran aceptación en la industria automotriz, brindando mayor confiabilidad y un menor consumo de energía [11]. Sin embargo, los LED son dispositivos semiconductores de unión tipo p-n, donde sus propiedades eléctricas y ópticas dependen de la temperatura, por lo que solo el 30% de la energía sirve para emitir luz [12], ocasionando una degradación eventual en su vida útil y en el rendimiento de iluminación. Para evitarlo y poder generar un funcionamiento estable son necesarias técnicas para el manejo de temperatura [13]. Por lo anterior, se han impulsado soluciones desde distintas perspectivas, tales como el uso de disipadores de calor metálicos y materiales térmicos en el PCB [14,15]. Desde la perspectiva de software como área de investigación, algunos métodos comunes de atenuación son utilizados tales como TRIAC, PWM, PAM y control de corriente [16]. En este artículo, PWM y control de corriente son utilizados haciendo uso de SVM y regresión logística para la detección de fallas en una unidad controladora de luz LED.

2. Metodología

La propuesta incluye el uso de algoritmos de clasificación SVM y regresión logística, para caracterizar de manera efectiva la detección de fallas del tipo circuito abierto en una matriz LED conectada a un sistema embebido llamado unidad controladora de luz LED (UCLED). El proceso de entrenamiento y validación se realizó utilizando una técnica de validación cruzada, que consistió dividir el conjunto de datos (DS) en dos partes. Para ambos algoritmos un 80% de las muestras se usaron para entrenar el modelo y el restante se reservó para validarlo. La Figura 1, describe el

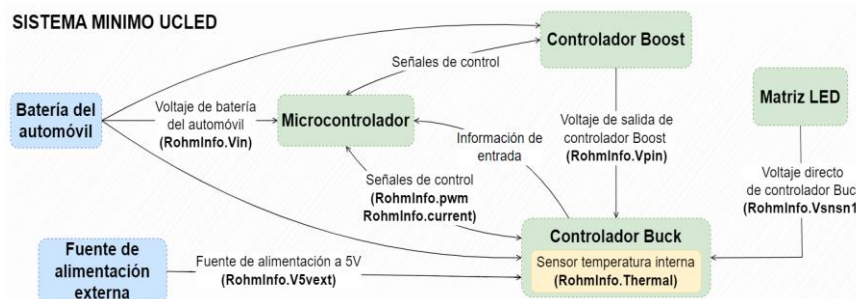


Fig. 1. Sistema mínimo de la unidad controladora LED.

Tabla 1. Conjuntos de datos y variables.

ID	Cantidad LEDs	Corriente mA	PWM %
1	1	150	5
2	7	750	100
3	12	1500	100

sistema mínimo de UCLED, esta se compone de los siguientes elementos: Batería del automóvil; Fuente de alimentación externa de 5 voltios para el controlador Buck; microcontrolador para enviar y recibir información de los controladores; controlador Boost para regular el voltaje de entrada del controlador Buck; controlador Buck, controlador regulador de corriente y PWM de la matriz LED; y la matriz LED, que es la salida.

El controlador Buck a utilizar es el BD18398RUV-M con su circuito de aplicación típico [17]. El microcontrolador de la UCLED envía parámetros de corriente y PWM, recibirá información de voltajes y temperatura por parte del controlador Buck. Con esta información se caracterizó el detector de fallas del tipo circuito abierto en la matriz LED, usando SVM y regresión logística. Programando esto en Python, empleando las bibliotecas de Pandas, Numpy y Scikit-learn, y manejando el DS en formato CSV. Los DS utilizados fueron obtenidos mediante el uso de la herramienta daqIDEA [18]. La respuesta esperada a la salida es verdadero o falso si hay o no una falla del tipo circuito abierto en la matriz LED. En las pruebas se utilizaron 17 DS, induciendo una falla del tipo circuito abierto en la matriz LED, reportamos los resultados de 3 DS. Los DS fueron creados acorde a las siguientes características: modulación PWM, número de leds utilizados y corriente en el controlador Buck.

La Tabla 1 muestra datos cuantitativos de los DS. Cada DS cuenta con alrededor de 500 a 1000 muestras. Las variables de entrada almacenadas en los DS son las siguientes: RohmInfo.current, valor de corriente en el controlador Buck (mA); RohmInfo.pwm, valor de PWM en el controlador Buck (%); RohmInfo.Thermal, valor de temperatura interna del controlador Buck (°C); RohmInfo.V5vext, valor de voltaje externo medido por el controlador Buck (mV); RohmInfo.Vin, valor de voltaje de




Fig. 2. Correlación de variables de DS.

Tabla 2. Resultados exactitud y precisión.

Algoritmo	Configuración	Exactitud	Precisión
SVM	1 led, 150 mA, 5% PWM	0.9889	0.9829
SVM	7 leds, 150 mA, 5% PWM	0.9893	0.9736
SVM	12 leds, 150 mA, 5% PWM	0.9811	0.9898
RegLog	1 led, 150 mA, 5% PWM	0.9981	0.9971
RegLog	7 leds, 150 mA, 5% PWM	0.9936	0.9844
RegLog	12 leds, 150 mA, 5% PWM	0.9641	0.9144




Fig. 3. Matrices de confusión.

batería medido por el controlador Buck (mV); RohmInfo.Vpin, valor de voltaje de salida del controlador Boost (mV); RohmInfo.Vsnsn1, valor de voltaje consumido por la matriz LED (mV).

Las variables de salida almacenadas en los DS son las siguientes: Voltage_diff_out, valor de diferencia de voltaje entre RohmInfo.Vpin y RohmInfo.Vsnsn1; OL_Detect, variable que contiene valor verdadero o falso para la detección de falla del tipo circuito abierto en la matriz LED. Finalmente, se obtienen las métricas de exactitud, precisión y matriz de confusión para la evaluación del modelo.

3. Resultados y conclusiones

Mediante el uso de correlaciones, se observa que las variables relacionadas a la variable de salida son: RohmInfo.Vsnsn1 y RohmInfo.Vpin como se muestra en la

figura 2. Dado que la variable RohmInfo.Vpin tiene un coeficiente no tan cercano a 1, se decide no utilizarla para el entrenamiento de los modelos. Por lo tanto, la variable “x” para el entrenamiento es RohmInfo.Vsnsn1, y la variable “y” es OL_Detect. Los resultados obtenidos de exactitud y precisión son mostrados en la tabla 2; mientras que las matrices de confusión son mostradas en la figura 3.

Como conclusión, se deduce que la variable RohmInfo.Vsnsn1 es más que suficiente para crear una estrategia en base a voltajes para la detección de fallas de circuito abierto en la matriz LED. Al haber una falla, el valor de RohmInfo.Vsnsn1 tiende a acercarse al valor de RohmInfo.Vpin, por lo que un valor de umbral finamente ajustado entre ambos valores permite una correcta detección de la falla. Esta solución por software podría minimizar gastos en el uso de dispositivos más complejos para realizar la misma función.

Referencias

1. Damsgaard, H.J., Grenier, A., Katare, D., Taufique, Z., Shakibhamedan, S., Troccoli, T., Chatzitsompanis, G., Kanduri, A., Ometov, A., Ding, A.Y., Taherinejad, N., Karakonstantis, G., Woods, R., Nurmi, J.: Adaptive approximate computing in edge AI and IoT applications: A review. *Journal of Systems Architecture* 150, 103114 (2024). DOI: 10.1016/j.sysarc.2024.103114.
2. Ullah, I., Adhikari, D., Su, X., Palmieri, F., Wu, C., Choi, C.: Integration of data science with the intelligent IoT (IIoT): Current challenges and future perspectives. *Digital Communications and Networks* 11(2), 280–298 (2025). DOI: 10.1016/j.dcan.2024.02.007.
3. Kumar, R., Jain, A.: Driving behavior analysis and classification by vehicle OBD data using machine learning. *The Journal of Supercomputing* 79(16), 18800–18819 (2023). DOI: 10.1007/s11227-023-05364-3.
4. Gong, C.S.A., Su, C.H.S., Chen, Y.H., Guu, D.Y.: How to implement automotive fault diagnosis using artificial intelligence scheme. *Micromachines* 13(9), 1380 (2022). DOI: 10.3390/mi13091380.
5. Abdulkareem, A.Q., Humod, A.T., Ahmed, O.A.: Robust pattern recognition based fault detection and isolation method for ABS speed sensor. *International Journal of Automotive Technology* 23(6), 1747–1754 (2022). DOI: 10.1007/s12239-022-0152-5.
6. Safavi, S., Safavi, M.A., Hamid, H., Fallah, S.: Multi-sensor fault detection, identification, isolation and health forecasting for autonomous vehicles. *Sensors* 21(7), 2547 (2021). DOI: 10.3390/s21072547.
7. Biddle, L., Fallah, S.: A novel fault detection, identification and prediction approach for autonomous vehicle controllers using SVM. *Automotive Innovation* 4(3), 301–314 (2021). DOI: 10.1007/s42154-021-00138-0.
8. Kaplan, H., Tehrani, K., Jamshidi, M.: A fault diagnosis design based on deep learning approach for electric vehicle applications. *Energies* 14(20), 6599 (2021). DOI: 10.3390/en14206599.
9. Continental AG: Continental Mexico. <https://www.continental.com/es-mx/compania/continental-mexico/>
10. Continental AG: Continental focuses on LED innovations. <https://www.continental.com/en/press/press-releases/2014-02-28-full-led/>
11. Yong, P.C.: Led lamps replace incandescent bulbs in automotive applications. *ATZautotechnology* 1(6), 56–57 (2001). DOI: 10.1007/BF03246657.

12. Jeong, S.-H., Kim, J.-Y., Xiao, X., Kim, Y.-S.: Junction temperature control for the automotive LED lamp based on the current feed forward strategy. *Optik* 232, 166535 (2021). DOI: 10.1016/j.ijleo.2021.166535.
13. Wang, J., Cai, Y.X., Li, X.H., Zhao, X.J., Zhang, C.: Design of automotive headlamp with high-power LEDs. *International Journal of Automotive Technology* 15(4), 673–681 (2014). DOI: 10.1007/s12239-014-0070-2.
14. Huang, D.-S., Chen, T.-C., Tsai, L.-T., Lin, M.-T.: Design of fins with a grooved heat pipe for dissipation of heat from high-powered automotive LED headlights. *Energy Conversion and Management* 180, 550–558 (2019). DOI: 10.1016/j.enconman.2018.11.021.
15. Sevilgen, G., Kiliç, M., Aktaş, M.: Dual-separated cooling channel performance evaluation for high-power LED PCB in automotive headlight. *Case Studies in Thermal Engineering* 25, 100985 (2021). DOI: 10.1016/j.csite.2021.100985.
16. Hsia, S.-C., Chen, K.-C.: Universal dimmable driving system for various power LEDs using digital adaptation. *Electrical Engineering* 105, 151–161 (2023). DOI: 10.1007/s00202-022-01655-9.
17. ROHM Co., Ltd.: BD18398RUV-M 3ch current LED driver with SPI for automotive. <https://www.rohm.com/products/power-management/led-drivers/step-down-buck/bd18398ruv-m-product>
18. iSYSTEM: daqIDEA - Visualization Tool. <https://www.isystem.com/products/software/daqidea.html>