

Capítulo 6

Conclusiones

La mayor contribución de este trabajo al estado de arte de la identificación de llantos de niños es la utilidad que tienen las características no lineales para incrementar la precisión de la clasificación. Esto puede observarse en la Tabla 4.1 y Tabla 4.2.

Los datos de la Tabla 4.1 indican que la precisión de clasificación en los llantos Normales y de Asfixia aumentan en general entre 1% y 3%. Sin embargo, puede observarse que este incremento no se da en los llantos de sordera. Analizando los datos de las Tablas 4.3 y 4.5 es posible identificar como la varianza en los llantos de sordera es menor en comparación con los normales y los de asfixia, esto indica que las características de este tipo de llanto son muy parecidas entre sí. En consecuencia, el algoritmo clasificador no tiene suficiente información discriminante que le permita decidir con mayor precisión la categoría a la cual pertenece.

La clasificación de llantos de hambre y dolor por otro lado, reportan un aumento entre 1% y 4% al agregar las características no lineales. No obstante, esto se logró gracias a que

el algoritmo se entrenó en todo momento con la matriz que contenía los llantos de asfixia y se variaba la segunda matriz entre llantos de hambre o de dolor. De no haber realizado el procedimiento antes mencionado, el porcentaje de clasificación sería aproximadamente de 70%. La razón de este bajo porcentaje se debe a que sus características no lineales son muy similares y por lo tanto no puede diferenciar fácilmente entre ambas categorías, esto se puede observar en el datos estadísticos de las Tablas 4.4 y 4.6. Debido a que estos dos llantos son considerados de tipo normal era de esperarse un bajo porcentaje de clasificación entre ellos.

La identificación de llantos resulta ser una técnica efectiva que permite reconocer la causa del llanto de manera pronta,eficiente y no invasiva. Evidentemente, aún queda mucho trabajo por delante, por ejemplo con más información es posible que la clasificación del algoritmo mejore o en su defecto considerar nuevas alternativas de extracción y clasificación.

Por ejemplo, en este trabajo se utilizó un algoritmo *boosting* para la clasificación debido a su bajo costo de cómputo, su simplicidad para ser implementado y la facilidad con que se podrían transferir los nodos entrenados a un FPGA (Field Programmable Gate Array) [Kadlcek and Fucik, 2013] y así desarrollar un sistema embebido. No obstante, debido a la múltiple dimensionalidad de las características utilizadas, podría considerarse la posibilidad de utilizar un método clasificador que logre adaptarse mejor a esta condición y quizá alcanzar el 100% de precisión; por ejemplo: las Redes Neuronales o las Redes Bayesianas. Todas estas observaciones pretenden contribuir a las bases metodológicas de líneas de investigación futuras.