

Detección de anomalías en telemetría satelital utilizando Memoria Temporal Jerárquica



Pablo Soligo, Jorge S. Ierache, Martín Becerra, Diego Sanz

Grupo de Investigación y Desarrollo de Software Aeroespacial (GIDSA).
Departamento de Ingeniería e Investigaciones Tecnológicas (DIIT).
Universidad Nacional de La Matanza (UNLaM).

1. Contexto

La Universidad Nacional de La Matanza (UNLaM) como socio académico de la Comisión Nacional de Actividades Espaciales (CONAE) dicta una Maestría en Desarrollos Informáticos de Aplicación Espacial (MDIAE). Las experiencias realizadas en la maestría propiciaron la creación del Grupo de Investigación y Desarrollo de Software Aeroespacial (GIDSA). Este grupo está dedicado a investigar e implementar prototipos de software alternativos de bajo costo basados en las soluciones normalmente utilizadas en la industria del software de propósito general.

2. Introducción

La detección automática y, potencialmente sobre software de vuelo [5], de anomalías es una tarea crucial en la operación [7]. Históricamente se ha usado el control de límites [5] como su estrategia más extendida, estrategia simple y eficiente pero que posee limitaciones; no contempla el contexto, ni los datos históricos. La telemetría histórica puede dar señales de fallas futuras [4] y a medida que las misiones aumentan su tamaño, ya sea por complejidad del satélite o por cantidad (Constelaciones), más compleja y confusa puede ser la tarea de operadores e ingenieros [2]. La figura 1 muestra el crecimiento de la cantidad de variables (*channels*) que es necesario administrar en diferentes misiones de la Agencia Espacial Europea, del Inglés European Space Agency (ESA).

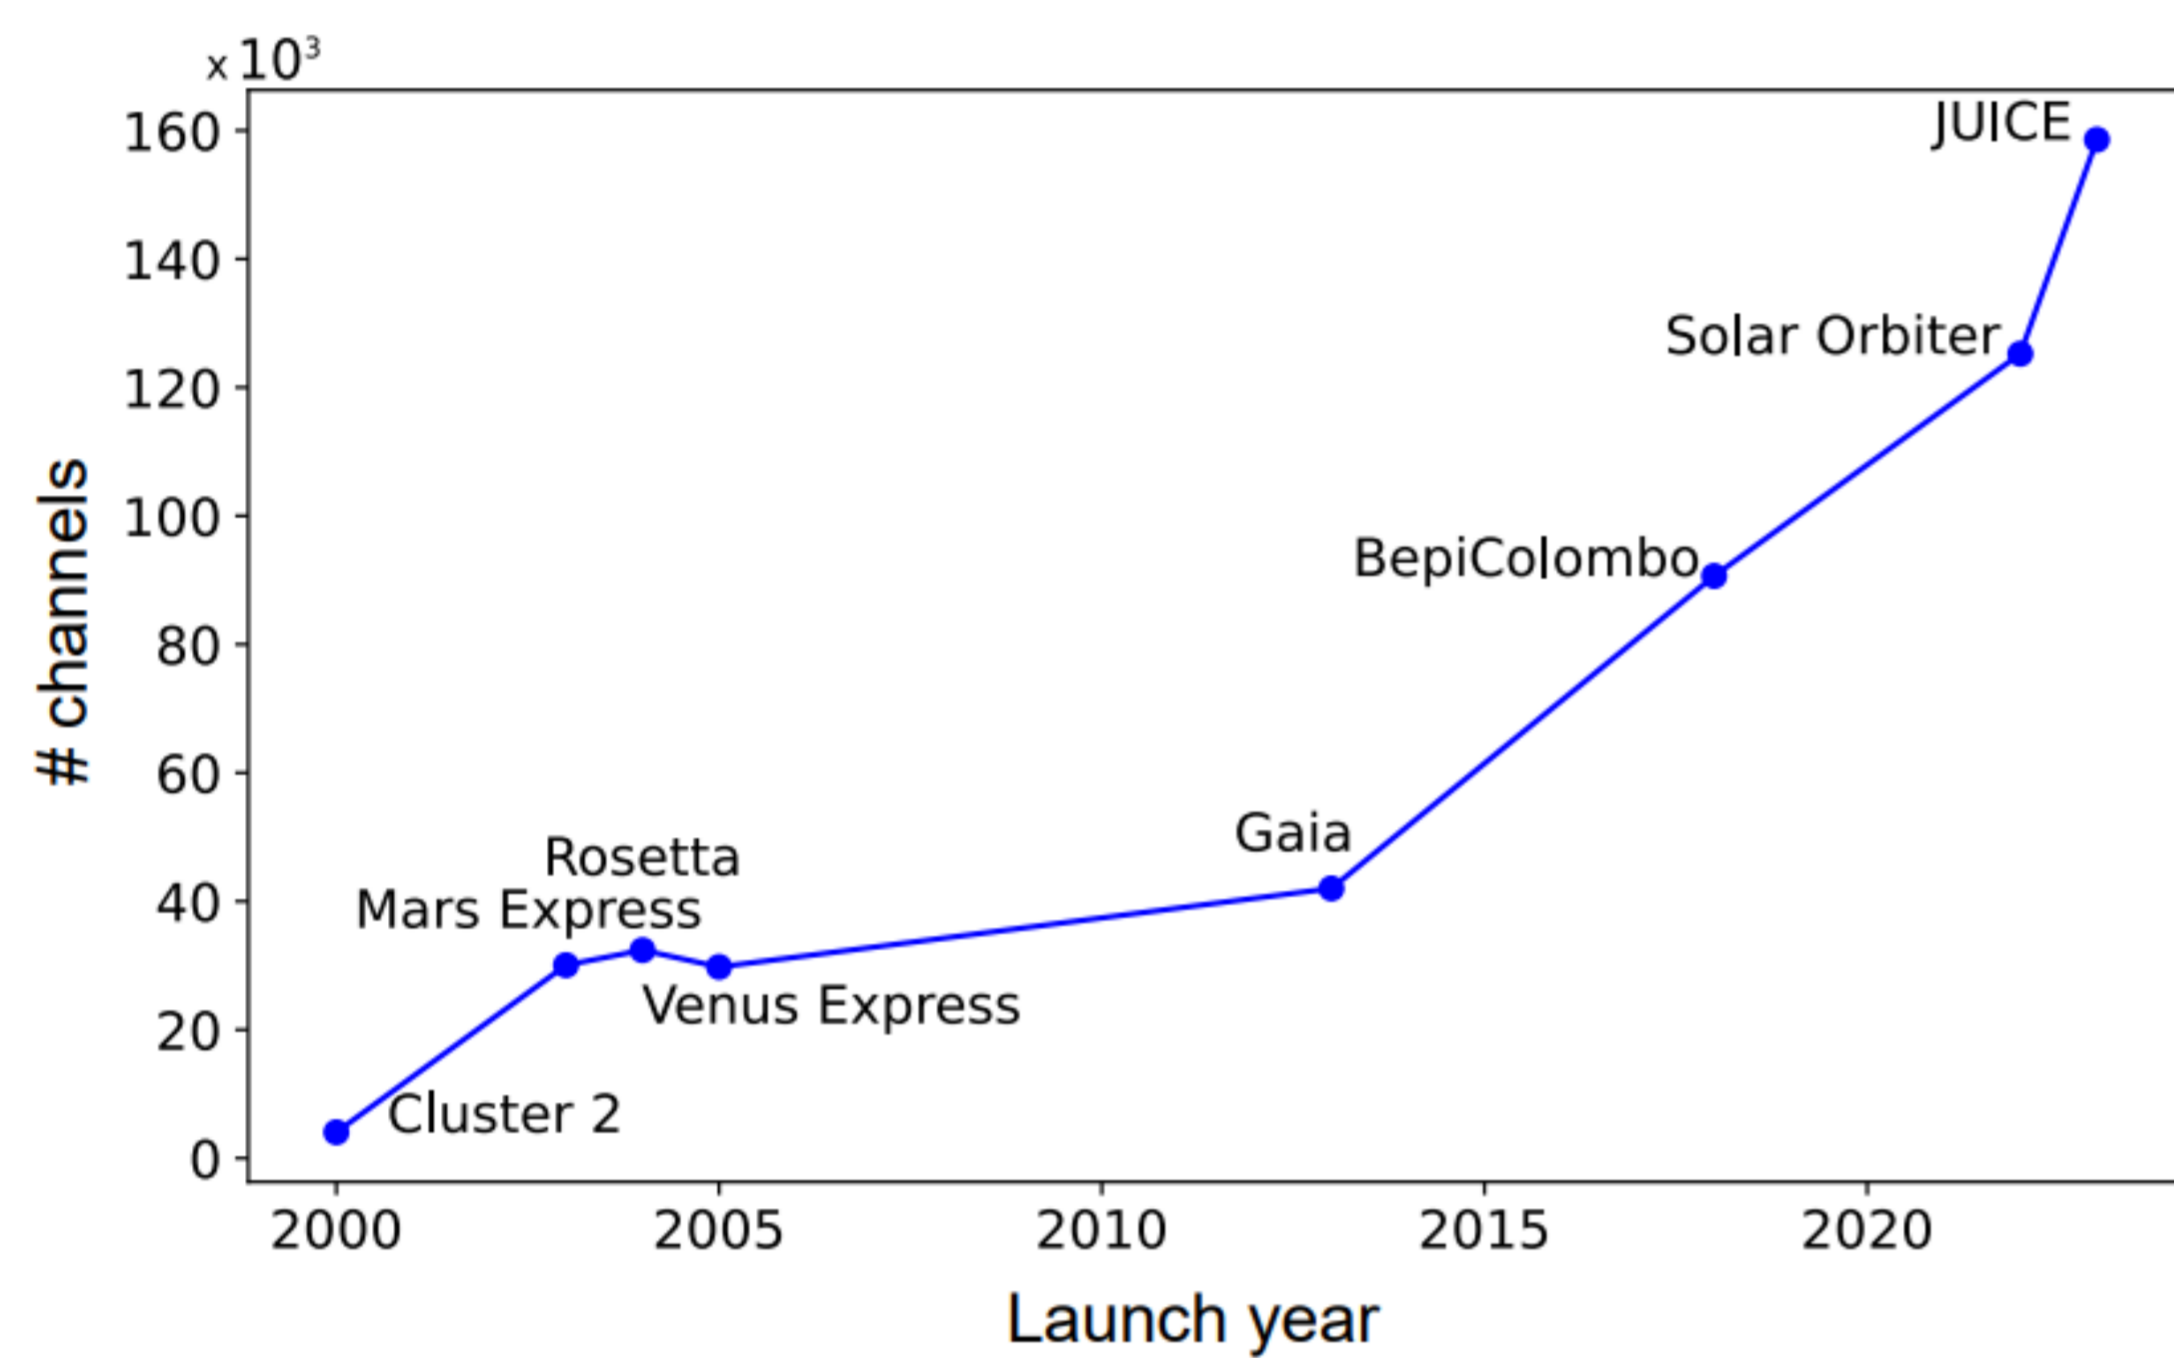


Figura 1: Evolución a través de los años de la cantidad de variables para diferentes misiones de la ESA [5].

3. Líneas de investigación y desarrollo

Las líneas de investigación del grupo han abarcado, entre otros, temas relacionados con la incorporación de herramientas de uso extendido en la industria del software de propósito general a la industria espacial. En este trabajo se ha profundizado en líneas de investigación vinculadas a la detección de anomalías, explorando técnicas de predicción sobre series temporales y realizado una primera aproximación utilizando Memoria Temporal Jerárquica, del inglés Hierarchical Temporal Memory (HTM). HTM es una tecnología de inteligencia artificial inspirada en el funcionamiento del neocórtex [3]. La figura 2 muestra una representación conceptual de un modelo HTM simplificado. En la parte inferior se presenta en forma esquemática la entrada codificada que alimenta al modelo, en este caso un Codificador Escalar Aleatorio Distribuido, del inglés Random Distributed Scalar Encoder (RDSE). En la parte superior se representan el codificador espacial (*Spatial Pooler*) y la memoria temporal (*Temporal Memory*), que son los módulos principales de un modelo HTM. Las neuronas (*cells*) están organizadas en columnas (*Columns* o también descritas como *Minicolumns*). Cada columna contiene múltiples neuronas y pueden activarse en su totalidad (*Bursting*) o, por el contrario, si la fuerza de las conexiones generadas con sus vecinas durante el proceso de aprendizaje lo determina solo la célula ganadora lo hará. El continuo ajuste de las fuerzas de las conexiones y los procesos de inhibición permiten que el modelo aprenda secuencias temporales de patrones de entrada.

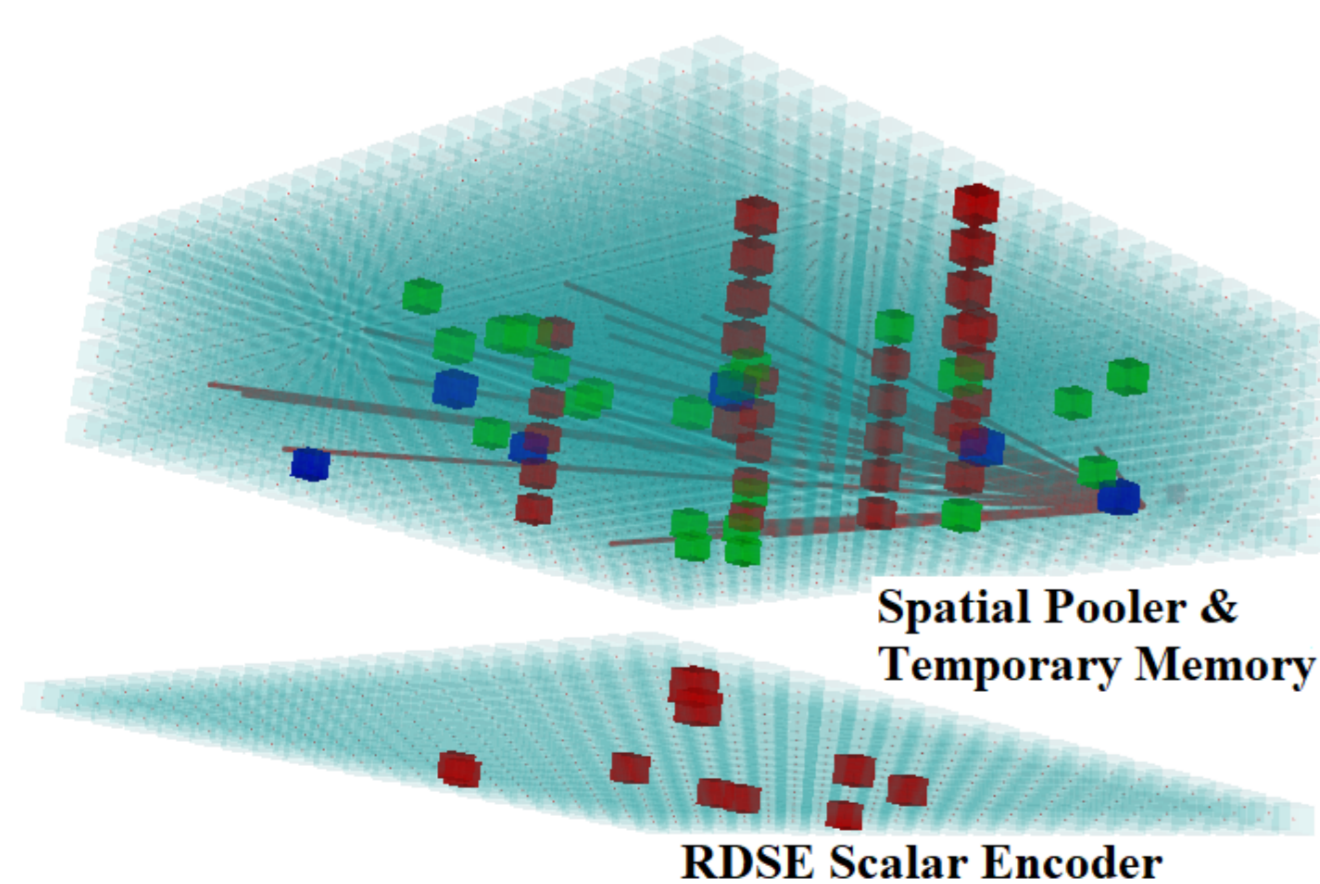


Figura 2: Representación conceptual del codificador, en este caso un codificador RDSE junto con un Spatial Pooler y un Temporal Memory en la sección superior. El color rojo indica una neurona activa, el azul una neurona predictiva y el verde una neurona ganadora. Se presenta una versión simplificada de alto nivel de un modelo HTM[6] con fines ilustrativos; la topología real, el total de neuronas y la cantidad de neuronas por columna puede variar respecto a esta esquematización. La figura es de generación propia utilizando la biblioteca pyvista[8].

4. Resultados obtenidos y esperados

Se espera que los algoritmos implementados o potenciales arquitecturas híbridas propuestas, logren un desempeño similar o superior a los *benchmarks* publicados por la ESA [5] a un costo computacional inferior que habilite su potencial implementación en vuelo. Hoy, variantes de Memoria a Largo Corto Plazo, del inglés Long Short-Term Memory (LSTM) como el Telemanom y Telemanom ESA Pruned ofrecen generalmente los

mejores resultados. Los algoritmos HTM han demostrado una buena capacidad para la detección de patrones sobre series de tiempo univariadas y por tanto es razonable anticipar que su aplicación en la detección de fallas en sistemas espaciales será efectiva.




Figura 3: HTM[6] aplicado a los canales 44, 45 y 46 del dataset de la ESA [1] mostrando capacidad de predicción de anomalías multicanal. El sector sombreado representa las anomalías etiquetadas por la ESA. Las barras muestran la propensión de anomalías detectadas por el modelo y los triángulos lugares donde se supera un umbral predefinido.

La figura 3 ilustra las pruebas exploratorias realizadas sobre los dataset de la ESA. Sin

explorar aún la optimización exhaustiva de hiperparámetros ni codificaciones de entradas alternativas, el modelo HTM muestra una capacidad prometedora para la detección de anomalías multicanal. En la figura 3 se puede observar una detección especialmente desafiante [5] utilizando los canales 44, 45 y 46 del dataset de la ESA [1]. El sector sombreado representa las anomalías etiquetadas por la ESA. Las barras muestran la propensión de anomalías detectadas por el modelo y los triángulos lugares donde se supera un umbral predefinido.

La métrica sugerida por la ESA para evaluar el desempeño de los modelos de detección de anomalías a nivel evento (*event-wise*) es una puntuación F con $\beta = 0.5$ [5]. Aunque en estas pruebas el modelo HTM ha alcanzado una puntuación de 1.0, no se debe generar aquí una falsa ilusión de progreso. Los resultados son una primera aproximación que puede sufrir de sobre ajuste. La detección de la anomalía se realizó manteniendo el estado de aprendizaje durante toda la serie. La densidad realista de anotaciones cercana al 1.8% (Sean anomalías o eventos raros) sobre un total de 774.856.895 puntos dificulta a la fecha el análisis exhaustivo de una parametrización con grados de libertad ajustados y por consiguiente la evaluación objetiva del desempeño del modelo.

5. Trabajo a Futuro

Las pruebas realizadas muestran una degradación en los tiempos de ejecución a medida que las series se vuelven más largas. Problemas de sobre entrenamiento del modelo por parametrizaciones demasiado permisivas en términos de complejidad pueden estar contribuyendo a este comportamiento. El control de los periodos de exploración y explotación adecuados y mantener constante la complejidad son aspectos clave a investigar. Por otro lado, enfoques alternativos como combinar resultados de detecciones de anomalías individuales para cada canal, técnicas de preprocesamiento y reducción de la dimensionalidad vía Análisis de Componentes Principales, del inglés Principal Component Analysis (PCA) o suavizado de datos representan alternativas que merecen ser exploradas.

Las fechas no fueron codificadas por no tener en principio carácter predictivo. Sin embargo, el tiempo entre muestras y la pérdida de regularidad si puede ser indicativo de anomalía que no ha sido tenido en cuenta y que, adicionalmente, puede ser un auxiliar para cumplir con el requerimiento no mandatorio R8 indicado por los ingenieros de operaciones: "Algorithm should natively handle irregular timestamps and varying sampling rates" [5].

6. Recursos humanos

El equipo está conformado por dos investigadores formados, dos investigadores en formación y se encuentra en proceso de radicación una futura tesis de doctorado vinculada a la investigación presentada en este trabajo.

Agradecimientos

Agradecemos al departamento de ingeniería e investigaciones tecnológicas (DIIT) de la UNLaM por apoyar las investigaciones

Referencias

- [1] G. D. Canio, K. Kotowski, and C. Haskamp. Esa anomaly dataset, 6 2024.
- [2] L. C. Brighenti, A. D. Evans, M. D. Moretto, and M. F. Ferrari. Advances in context aware spacecraft telemetry checking. In *2018 IAC*, 2018.
- [3] J. Hawkins, S. Ahmad, S. Purdy, and A. Lavin. Biological and machine intelligence (bami). Initial online release 0.4, 2016.
- [4] K. Hundman, V. Constantinou, C. Laporte, I. Colwell, and T. Soderstrom. Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding. In *Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining*, pages 387–395, 2018.
- [5] K. Kotowski, C. Haskamp, J. Andrzejewski, B. Ruszczak, J. Nalepa, D. Lakey, P. Collins, A. Kolmas, M. Bartesaghi, J. Martinez-Heras, et al. European space agency benchmark for anomaly detection in satellite telemetry. *arXiv preprint arXiv:2406.17826*, 2024.
- [6] M. Otahal, D. Keeney, D. McDougall, et al. HTM.core implementation of Hierarchical Temporal Memory. <https://github.com/htm-community/htm.core/>, 2019.
- [7] S. Schmidl, P. Wenig, and T. Papenbrock. Anomaly detection in time series: a comprehensive evaluation. *Proceedings of the VLDB Endowment*, 15:1779–1797, 2022.
- [8] B. Sullivan and A. Kaszynski. PyVista: 3D plotting and mesh analysis through a streamlined interface for the Visualization Toolkit (VTK). *Journal of Open Source Software*, 4(37):1450, May 2019.