

# Analítica Prescriptiva en Sistemas con Grandes Flujos de Eventos

## Prescriptive Analytics on Systems with Large Event Streams

Presentación: 06/10/2020

Doctorando:

**Esteban Alejandro Schab**

Grupo de Investigación en Inteligencia Computacional e Ingeniería de Software, Facultad Regional Concepción del Uruguay,  
Universidad Tecnológica Nacional - Argentina  
schabe@frcu.utn.edu.ar

Directora:

**María Fabiana Piccoli**

Co-director:

**Carlos Antonio Casanova Pietroboni**

### Resumen

Los procesos de negocio exigen tomar decisiones rápidas para lograr la adaptación constante a los cambios en búsqueda de mejorar el desempeño y aprovechar las oportunidades. Una posibilidad es resolver el proceso computacionalmente. Para ello es necesario producir analíticas que transformen los datos en conocimiento para la toma de decisiones. Existen varios tipos de analíticas, en este trabajo se introduce una línea de investigación enfocada en la analítica prescriptiva, como nivel más avanzado, capaz de calcular acciones a ser ejecutadas en el momento (decisiones operativas) o en el futuro (decisiones tácticas para corto y mediano plazo, decisiones estratégicas para largo plazo) para lograr un objetivo deseado. El cálculo de las acciones involucra el procesamiento del flujo de eventos del negocio en forma de *datastreams*, la aplicación de técnicas y algoritmos de *Soft Computing* e *Inteligencia Computacional* y, derivado de la necesidad de bajos tiempos de respuesta, el empleo de *Computación de Alto Desempeño*.

**Palabras clave:** Inteligencia Computacional. Analíticas. Datastreams. Computación de Alto Desempeño.

### Abstract

Business processes demand quick decisions to achieve constant adaptation to changes in search of improving performance and taking advantage of opportunities. One possibility is to solve the process computationally. This requires producing analytics that transform data into knowledge for decision-making. There are several types of analytics, this work introduce a line of research focused on *prescriptive analytics*, as the more advanced level, capable of calculating actions to be executed at the moment (operational decisions) or in the future (tactical decisions for short and medium term, strategic decisions for long term) to achieve a desired goal. The calculation of actions involves the process of business events flow as *datastreams*, the application of *Soft Computing* and *Computational Intelligence* techniques and algorithms and, derived from the need for low response times, the use of *High Performance Computing*.

**Keywords:** Computational Intelligence. Analytics. Datastreams. High Performance Computing.

## Introducción

La mejora continua y adaptativa de los procesos de negocio resulta clave para mantener la competitividad de las organizaciones. La digitalización de los procesos, así como el incremento en el uso de tecnologías de monitoreo, han generado la producción de una enorme cantidad de datos, los cuales tienen un gran potencial para la mejora de los procesos conducida por analíticas (Gröger, Schwarz & Mitschang, 2014; Saggi & Jain, 2018; Thirathon, Wieder, Matolesy & Ossimitz, 2017).

Las analíticas buscan transformar los datos en conocimiento para la toma de decisiones (Holsapple, Lee-Post, & Pakath, 2014), pudiendo distinguirse cuatro tipos de analíticas según el nivel de automatización del proceso (Minelli, Chambers, & Dhiraj, 2013). Primero, la analítica descriptiva intenta responder qué ha pasado o está pasando y la analítica diagnóstica por qué ha pasado o está pasando. Ambas se basan en el análisis de datos históricos. Luego, la analítica predictiva busca responder qué sucederá. Aplica el conocimiento obtenido a partir de los datos para predecir nuevos datos sobre el presente o el futuro (pronóstico). Ninguno de estos enfoques sugiere acciones concretas a partir de los pronósticos obtenidos, sino que descansan en el juicio subjetivo y las habilidades analíticas del usuario para deducir acciones de mejora. Finalmente, la analítica prescriptiva responde qué debería hacerse para lograr un objetivo. Determina las acciones a ser ejecutadas en el momento (decisiones operativas) o en el futuro (decisiones tácticas para corto y mediano plazo, decisiones estratégicas para largo plazo) para lograr el o los objetivos deseados.



Figura 1: Modelo de madurez de las analíticas.

En el área de datos masivos (o *Big Data*), se identifica como área emergente el *procesamiento de datastreams*, también llamado *Data Stream Mining* (Bifet & Read, 2018; Ramírez-Gallego, Krawczyk, García, Wozniak & Herrera, 2017; Kolajo, Daramola & Adebisi, 2019). Un *datastream* es una representación digital y transmisión continua de datos, los cuales describen una clase de eventos relacionada (Pigni, Piccoli, & Watson, 2016). Mediante el procesamiento de estos *datastreams* se puede lograr la respuesta en tiempo real a los eventos en forma de toma de decisiones. La ejecución de los algoritmos para la generación de analíticas debe ser lo suficientemente rápida como para procesar los *datastreams* generados de manera continua por el sistema, lo que implica el uso de técnicas y herramientas de *Computación de Alto Desempeño* (HPC).

## Desarrollo

La línea de investigación en la que se enmarca la tesis en desarrollo se basa en la Optimización de procesos de negocio por recomendación. En este contexto, los *datastreams* abren nuevas y amplias oportunidades para la creación de valor en las organizaciones. Como se mencionó, mediante su procesamiento se puede conseguir la respuesta en tiempo real a los eventos en forma de toma de decisiones.

Como se destaca en (Wrench, Stahl, Di Fatta, Karthikeyan, & Nauck, 2016), cuando se habla de los eventos del negocio, se pueden encontrar desde definiciones muy amplias como "algo que sucede" hasta otras más detalladas como la de (Hinze, Sachs, & Buchmann, 2009) "un cambio significativo en el estado del sistema", y la de (Etzion & Niblett, 2010) "una ocurrencia dentro de un sistema o dominio particular; es algo que ha sucedido o se considera que sucedió en ese dominio".

Una secuencia o flujo de eventos (*Event Stream*) es una serie ordenada y potencialmente ilimitada de eventos (Owens, 2007; Yu, Li, Gu, & Hong, 2011). Los flujos de eventos se generan y utilizan en muchas aplicaciones. Un caso de particular interés es el de los bancos y otros sistemas de atención al público (Olanrewaju, 2014). En ellos la generación de *datastreams* es causada por los sistemas de gestión de atención implementados. Estos sistemas en general utilizan modelos relacionales de bases de datos y, si bien permiten la elaboración de analíticas, puede resultar inapropiada su implementación debido a que el desempeño del sistema de atención, especialmente en un contexto de *Software as a Service* (SaaS) (Turner, Budgen, & Brereton, 2003), puede colapsar ante las continuas consultas para realizar el monitoreo. Por tal motivo, la generación y el procesamiento de los eventos en forma de *datastreams* como una componente paralela al sistema de atención puede ser la tecnología de base para permitir un monitoreo eficiente, sin deterioro del desempeño del sistema en general. Otro caso de interés es el problema de enrutamiento de vehículos (VRP, *Vehicle Routing Problem*) (Braekers, Ramaekers, & Van Nieuwenhuysse, 2016) con suministro de información y reencaminamiento en tiempo real, orientado a la búsqueda de un paradigma de movilidad inteligente (Melo, Macedo, & Baptista, 2017). Dentro de este problema se pueden estudiar de forma particular o en conjunto la logística urbana, el transporte de personas y los conductores individuales. En este caso los *datastreams* son generados de forma distribuida por cada agente involucrado y pueden ser procesados de forma centralizada o distribuida dependiendo del esquema elegido y los recursos disponibles.

Los grandes volúmenes de datos generados pueden ser utilizados en algoritmos de aprendizaje supervisado o no supervisado para la generación de analíticas, particularmente las descriptivas y predictivas. Existe, sin embargo, una dificultad en lo relativo a las analíticas prescriptivas: no cuentan con un "profesor" que les diga qué acción tomar en cada circunstancia. Un tipo de aprendizaje que no necesita de un profesor es el llamado aprendizaje por refuerzo. En este esquema es el propio agente quien es capaz de juzgar y criticar sus acciones con base en sus percepciones y de alguna medida de aptitud, recompensa o refuerzo. La tarea del aprendizaje por refuerzo es usar recompensas observadas para aprender una política óptima (o aproximadamente óptima) del entorno, sin asumir ningún conocimiento *a priori* (Russell & Norvig, 2004). Esta política le dice al agente qué hacer en cada estado posible a alcanzar. Por lo tanto, se juzga al aprendizaje por refuerzo como una herramienta muy útil para la elaboración de analíticas prescriptivas, ya que ambos comparten el mismo objetivo.

A pesar de los grandes avances tecnológicos, en general, las analíticas de procesos existentes dentro de la industria actual no aprovechan completamente el conocimiento oculto en los grandes volúmenes de datos con los que cuentan (Gröger, Schwarz, & Mitschang, 2014) debido a las siguientes limitaciones:

- a. No hacen uso de técnicas prescriptivas para transformar los resultados del análisis en acciones de mejora concretas, dejando este paso completamente a criterio del juicio subjetivo del usuario.
- b. Hacen un uso intensivo de datos de sistemas en producción, generando un deterioro en el desempeño de las herramientas de software que soportan los procesos.
- c. La optimización es conducida *a posteriori*, después de completado el proceso, en contraste a la mejora proactiva durante la ejecución del proceso.

En la tesis en desarrollo se propone el desarrollo de un modelo de analítica prescriptiva que supere los inconvenientes descritos. Este modelo dirigido por los datos será parte esencial de un proceso de mejora continua basado en la recomendación de acciones operativas y tácticas destinadas a mantener los indicadores de rendimiento del sistema dentro de los valores deseados, en un contexto con grandes flujos de eventos y Computación de Alto Desempeño (HPC).

La construcción del modelo prescriptivo, cuya principal función resulta en la determinación de las acciones a llevar a cabo, hace uso de un modelo predictivo para explorar los futuros cercanos y un modelo descriptivo para calcular la aptitud de dichos estados. Para ello se propone el uso de agentes basados en aprendizaje por refuerzo, y complementar el mismo con técnicas provenientes de la Inteligencia Computacional: redes neuronales como modelos, teoría de conjuntos difusos como lenguaje de especificación, y métodos numéricos y metaheurísticos para el entrenamiento de tales modelos (Ebrahimnejad & Verdegay, 2018; Siddique & Adeli, 2013; Zadeh, 1994).

Debido a la necesidad de dar respuesta a un proceso de negocio dinámico la ejecución de estas técnicas y algoritmos debe ser lo suficientemente rápida como para procesar los *datastreams* que el sistema genera de manera continua y brindar resultados en tiempo real, lo que implica el uso de técnicas y herramientas HPC (Barrionuevo, Lopresti, Miranda, & Piccoli, 2015). Se espera construir y probar algoritmos de procesamiento aplicando computación paralela capaz de reducir los tiempos derivados de entrenar y ejecutar el modelo (Verner, Schuster & Silberstein, 2011; Verner, Schuster, Silberstein & Mendelson, 2012). Para ello es deseable facilitar el desarrollo de una solución paralela portable, de costo predecible, capaz de explotar las ventajas de modernos ambientes HPC a través de herramientas y “frameworks de computación” de alto nivel (Kurgalin & Borzunov, 2019; Pacheco, 2011).

## Conclusiones

Partiendo de la necesidad de la mejora continua y adaptativa de los procesos de negocio como clave para mantener la competitividad de las organizaciones, se describieron las limitaciones por las que las analíticas de procesos existentes dentro de la industria actual no aprovechan completamente el conocimiento oculto en los grandes volúmenes de datos con los que cuentan.

Se introdujeron las nuevas y amplias oportunidades que abre el procesamiento de eventos del negocio en forma de *datastreams* y la generación de analíticas avanzadas a partir de los mismos para optimizar la toma de decisiones. Se presentaron dos casos de interés. En primer lugar, el de los bancos y otros sistemas de atención al público, en los que la generación de *datastreams* es causada por los sistemas de gestión de atención implementados. Por otro lado, el problema de enrutamiento de vehículos con suministro de información y reencaminamiento en tiempo real, orientado a la búsqueda de un paradigma de movilidad inteligente, en el cual los *datastreams* son generados de forma distribuida por cada agente involucrado y pueden ser procesados de forma centralizada o distribuida dependiendo del esquema elegido y los recursos disponibles.

Se propuso un modelo dirigido por los datos como parte esencial de un proceso de mejora continua basado en la recomendación automática de acciones operativas y tácticas destinadas a mantener los indicadores de rendimiento del sistema dentro de los valores deseados, en un contexto con grandes flujos de eventos.

Para la construcción del modelo prescriptivo, encargado de determinar las acciones a llevar a cabo para optimizar el rendimiento del sistema, se introdujo el uso de agentes basados en aprendizaje por refuerzo y la necesidad de complementar el mismo con técnicas provenientes de la Inteligencia Computacional: redes neuronales como modelos, teoría de conjuntos difusos como lenguaje de especificación, y métodos numéricos y metaheurísticos para el entrenamiento de tales modelos. Se especificó la necesidad de aplicar técnicas y herramientas HPC a la ejecución de estas técnicas y algoritmos dada la necesidad de dar respuesta a un proceso de negocio dinámico en tiempo real. En esta dirección se espera construir y probar algoritmos de procesamiento aplicando computación paralela capaz de reducir los tiempos derivados de entrenar y ejecutar cada modelo.

## Referencias

- Barrionuevo, M., Lopresti, M., Miranda, N., & Piccoli, M. F. (2015). Solving a big-data problem with gpu: the network traffic analysis. *Journal of Computer Science and Technology*, 15(01), 30–39.
- Bifet, A., & Read, J. (2018). Ubiquitous artificial intelligence and dynamic data streams. *Proceedings of the 12th ACM International Conference on Distributed and Event-Based Systems, DEBS '18* (págs. 1–6). New York, USA: Association for Computing Machinery.
- Braekers, K., Ramaekers, K., & Van Nieuwenhuysse, I. (2016). The vehicle routing problem: State of the art classification and review. *Computers & Industrial Engineering*, 99, 300-313.
- Ebrahimnejad, A., & Verdegay, J. L. (2018). *Fuzzy sets-based methods and techniques for modern analytics*. Springer International Publishing.
- Etzion, O., & Niblett, P. (2010). *Event processing in action*. Manning.
- Gröger, C., Schwarz, H., & Mitschang, B. (2014). Prescriptive analytics for recommendation-based business process optimization. *International Conference on Business Information Systems*, 25–37.
- Hinze, A., Sachs, K., & Buchmann, A. (2009). Event-based applications and enabling technologies. *Proceedings of the Third ACM International Conference on Distributed Event-Based Systems*, 1-15. doi:10.1145/1619258.1619260
- Holsapple, C., Lee-Post, A., & Pakath, R. (2014). A unified foundation for business analytics. *Decision Support Systems*(64), 130-141.
- Kolajo, T., Daramola, O., & Adebisi, A. (2019). Big data stream analysis: a systematic literature review. *Journal of Big Data*, 6(1).
- Kurgalin, S., & Borzunov, S. (2019). *A Practical Approach to High-Performance Computing*. Springer.
- Melo, S., Macedo, J., & Baptista, P. (2017). Guiding cities to pursue a smart mobility paradigm: An example from vehicle routing guidance and its traffic and operational effects. *Research in transportation economics*, 65, 24-33.
- Minelli, M., Chambers, M., & Dhiraj, A. (2013). *Big data, big analytics: emerging business intelligence and analytic trends for today's businesses*. John Wiley & Sons.
- Olanrewaju, T. (1 de julio de 2014 ). The rise of the digital bank. Recuperado el agosto de 2020, de <https://www.mckinsey.com/business-functions/digital-mckinsey/ourinsights/the-rise-of-the-digital-bank/>
- Owens, T. (2007). *Survey of Event Processing*. AIR FORCE RESEARCH LAB ROME NY INFORMATION DIRECTORATE.
- Pacheco, P. (2011). *An Introduction to Parallel Programming*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.
- Pigni, F., Piccoli, G., & Watson, R. (2016). Digital data streams: Creating value from the real-time flow of big data. *California Management Review*, 58(3), 5–25.
- Ramírez-Gallego, S., Krawczyk, B., García, S., Wozniak, M., & Herrera, F. (2017). A survey on data preprocessing for data stream mining: Current status and future directions. *Neurocomputing*, 239, 39 – 57.
- Russell, S., & Norvig, P. (2004). *Inteligencia Artificial: un enfoque moderno*. Pearson Prentice Hall.
- Saggi, M. K., & Jain, S. (2018). A survey towards an integration of big data analytics to big insights for value-creation. *Information Processing & Management*, 54(5), 758-790.
- Siddique, N., & Adeli, H. (2013). *Computational intelligence: synergies of fuzzy logic, neural networks and evolutionary computing*. John Wiley & Sons.
- Thirathon, U., Wieder, B., Matolcsy, Z., & Ossimitz, M.-L. (2017). Impact of big data analytics on decision making and performance. *International Conference on Enterprise Systems, Accounting and Logistics*.
- Turner, M., Budgen, D., & Brereton, P. (2003). Turning software into a service. *Computer*, 36(10), 38-44.
- Verner, U., Schuster, A., & Silberstein, M. (2011). Processing data streams with hard real-time constraints on heterogeneous systems. *Proceedings of the international conference on Supercomputing*, 120-129.

Verner, U., Schuster, A., Silberstein, M., & Mendelson, A. (2012). Scheduling processing of real-time data streams on heterogeneous multi-GPU systems. *Proceedings of the 5th Annual International Systems and Storage Conference*, 1-12.

Wrench, C., Stahl, F., Di Fatta, G., Karthikeyan, V., & Nauck, D. (2016). Data stream mining of event and complex event streams: A survey of existing and future technologies and applications in big data. En *Enterprise big data engineering, analytics, and management* (págs. 24-47). IGI Global.

Yu, G., Li, C.-W., Gu, Y., & Hong, B. (2011). Aggressive complex event processing with confidence over out-of-order streams. *Journal of Computer Science and Technology*, 685–696.

Zadeh, L. (1994). Fuzzy logic, neural networks, and soft computing. *Communications of the ACM*, 37(3), 77-84. doi:10.1145/175247.175255