

Procesamiento inteligente de flujos de datos vía sistemas argumentativos

José N. Paredes, Fabio R. Gallo, Gerardo I. Simari, y Marcelo A. Falappa
{jose.paredes,fabio.gallo,gis,mfalappa}@cs.uns.edu.ar

Departamento de Ciencias e Ingeniería de la Computación (UNS), Argentina
Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), Argentina
Instituto de Ciencias e Ingeniería de la Computación (UNS-CONICET), Argentina

Resumen Con el avance de las tecnologías de la información se hace cada vez más fácil generar y procesar datos con mayor precisión acerca de lo que ocurre en un dominio complejo. Las aplicaciones que se desarrollan en estos entornos se caracterizan por recibir grandes cantidades de datos en poco tiempo, con altas tasas de cambio, como así también incertidumbre e incompletitud; a este tipo de torrente de datos – que no se puede almacenar para ser procesado más adelante – se los conoce con el nombre de “flujos”. En este trabajo presentamos una propuesta para realizar procesamiento de flujos de manera inteligente a través de sistemas argumentativos, proponiendo una combinación novedosa de (i) técnicas de procesamiento de flujos de datos y eventos complejos, (ii) herramientas de argumentación estructurada, (iii) razonamiento probabilístico y (iv) operadores de revisión de creencias.

Palabras clave: Procesamiento de flujo de datos, Argumentación Estructurada, Razonamiento bajo incertidumbre, Revisión de creencias.

1. Introducción y Motivación

En la actualidad, a medida que las personas desarrollan sus actividades diarias se va produciendo una gran cantidad de información digital heterógena, densa, y muy frecuente, la cual va dejando huellas a partir de registros de llamadas, mensajes de texto, uso de GPS, publicaciones en redes sociales, y muchas otras fuentes más. Claramente, estas huellas pueden ser utilizadas para describir detalles menos evidentes del mundo que nos rodea, siempre teniendo en cuenta no violar las restricciones de privacidad de cada persona.

A su vez, el hecho de que cada vez haya más dispositivos al alcance de todas las personas para producir información más abundante hace que empresas u organismos implementen tecnologías que generan datos acerca de lo que ocurre en el entorno cotidiano. En este contexto surge un dominio de aplicación que intenta aprovechar tal situación pero requiere que el *procesamiento de los flujos de datos* (PFD) se lleve a cabo en un período de tiempo muchas veces pequeño. Ahora bien, debido a las características mencionadas no es posible o necesario procesar *toda* la información entrante; por lo tanto, los sistemas que se desarrollan en

estos entornos utilizan un concepto conocido como *ventana de datos*, las cuales permiten definir el conjunto de datos que está disponible para su procesamiento durante un lapso de tiempo. Sin embargo, si se quisiera utilizar esta información para aprovechar el valor semántico de la mejor manera posible, el PFD clásico no es suficiente; por consiguiente, proponemos utilizar técnicas de representación de conocimiento y razonamiento para este fin. La *argumentación* se encuentra dentro de esta categoría, y sus orígenes están vinculados con filósofos de la antigüedad que estudiaron la naturaleza involucrada en la actividad humana de dialogar. Concretamente, la argumentación se basa en procesos dialécticos que permite elaborar argumentos a favor y en contra de una determinada posición. Luego, es posible ponderar cada argumento en relación a otros que pueden debilitar esta posición y fortalecer una contraria. Como resultado se puede determinar cuáles son las conclusiones ganadoras luego de realizar todo este proceso. Este enfoque proporciona un acercamiento para manejar información incompleta y posiblemente contradictoria; como ventaja adicional, se puede acceder a las *explicaciones* del proceso que se utilizó para llegar a una determinada conclusión. En la literatura se han propuesto muchas formas de llevar a cabo este proceso, las cuales se dividen principalmente en *abstractas* [8] y *concretas* [10]; las primeras se caracterizan por el análisis de los argumentos disponibles y la relación de ataque entre ellos, mientras que las últimas asumen la disponibilidad de la *estructura interna* de cada argumento.

En este trabajo proponemos combinar las áreas de procesamiento de flujos de datos y argumentación, dando origen a un desarrollo novedoso dentro del área de *procesamiento inteligente de flujos de datos* (PIFD) [5]. Tomamos como base el formalismo DeLP3E planteado en [21,22], el cual divide la base de conocimiento (KB) en dos partes diferentes pero a la vez interrelacionadas: el *modelo del entorno* (EM), el cual es utilizado para definir relaciones entre eventos que, por su naturaleza, deben manejarse con modelos de incertidumbre; y por otro lado, el *modelo analítico* (AM), el cual maneja información potencialmente contradictoria mediante un análisis argumentativo basado en el formalismo DeLP con presuposiciones (PreDeLP) [15]. Este último tiene la posibilidad también de ofrecer las explicaciones que justifican una respuesta ante una determinada consulta. Desde el punto de vista del PFD, los contenidos tanto del EM como del AM pueden verse afectados por las altas tasas de información nueva; por lo tanto, los principales obstáculos que se interponen en el camino son una combinación de los que surgen en cada una de las siguientes áreas:

- (i) *Incompletitud, inconsistencia e incertidumbre*: se debe razonar con información que muchas veces es o bien insuficiente para alcanzar conclusiones certeras, ofrece datos contradictorios, o incluso describe fenómenos inherentemente inciertos (tales como los mercados financieros).
- (ii) *Volumen y velocidad*: la cantidad de información, proveniente de distintas fuentes a altas tasas, hace que sea imposible almacenarla toda para un procesamiento minucioso posterior; se debe entonces tomar la decisión de qué almacenar y qué desechar para que el sistema funcione de la mejor manera posible.

- (iii) *Dinámica de creencias*: como consecuencia de los dos primeros puntos se deriva la necesidad de manejar adecuadamente la dinámica de las creencias del sistema; los operadores de revisión y consolidación en general están pensados para entornos con tasas de cambio mucho menores.
- (iv) *Tratabilidad computacional*: el uso de herramientas ricas de representación de conocimiento y razonamiento generalmente implica pagar un costo en cuanto a complejidad computacional; esto es aun más central en los modelos de razonamiento probabilístico. Se deben desarrollar mecanismos por los cuales se puedan obtener aproximaciones y la degradación en su calidad sea lo más gradual posible; además, idealmente el usuario debería poder conocer los efectos que tiene el hecho de realizar compromisos entre tiempo de ejecución y calidad de las respuestas obtenidas.

Ejemplo 1. Considere el vehículo conducido de manera autónoma desarrollado por Google [12]; para poder transitar por las calles de una ciudad, éste requiere una gran cantidad de información acerca del entorno que lo rodea. Para esto cuenta con un conjunto de sensores:

- El LIDAR (*“Laser Imaging Detection and Ranging”*), que permite identificar objetos y medir la distancia a la que se encuentra los mismos utilizando rayos de luz. Específicamente Google hace uso del Velodyne HDL-64E S2, de alta definición, que cuenta con 64 rayos láser y gira sobre sí mismo 360 grados de manera continua hasta 900 vueltas por minuto con el fin de vigilar la situación alrededor del auto; observa 1,3 millones de puntos por segundo, con el fin de construir una imagen tridimensional de las entidades involucradas (peatones, otros vehículos, alumbrado público, árboles, etc). Tiene un alcance de 50m para el pavimento y de 120m para autos y árboles.
- Un GPS y una unidad de medición inercial. Esta unidad mide la aceleración y la velocidad angular mediante acelerómetros, giróscopos y magnetómetros. Es decir, se identifica con precisión hacia dónde se mueve el auto.
- Cuatro radares de onda de radio; tres están ubicados en el paragolpes delantero, uno en la parte frontal y los otros dos en las esquinas laterales respectivamente. En el paragolpes trasero va colocado el cuarto y último radar. Su función es identificar objetos y medir distancias alrededor del auto.

En conjunto, estos sensores ofrecen la capacidad de conocer lo que sucede en tiempo real alrededor del vehículo; esto significa que esta información varía en *cada instante* de tiempo, y gran parte de ella sólo es relevante durante un lapso de tiempo relativamente corto, tales como la posición de peatones, otros autos y cortes de calles (por manifestaciones sociales, reparaciones, etc.). Por otro lado, también se debe tener en cuenta información que en general no varía a lo largo del tiempo, como por ejemplo datos provenientes de los mapas. Google invirtió mucho esfuerzo en elaborar mapas, tanto para la elaboración de la herramienta *Google Maps* como también *Street View*; ambas contienen valor semántico que va más allá de un mapa tradicional.

Los sensores generan una gran cantidad de datos; el LIDAR produce 1,3 millones de puntos por segundo para un rango de visión horizontal de 360 grados

y un rango de visión vertical de 26,8 grados, y la salida total generada es de 100 Mbps de paquetes UDP [6]. Esto es un gran volumen que no puede guardarse ni procesarse de manera completa. En este contexto el sistema que conduce el vehículo debe tomar decisiones en tiempo real, pero considerando que la información de la cual dispone se encuentra afectada por la incertidumbre. Además, debe disponer de mecanismos que permitan manejar la nueva información que se incorpore (tales como condiciones climáticas actuales) teniendo en cuenta que se pueden producir contradicciones con los datos ya presentes. ■

2. Hacia una combinación de herramientas

En este trabajo proponemos desarrollar un formalismo de procesamiento inteligente de flujos de datos mediante la combinación de sistemas argumentativos con técnicas de procesamiento de flujos clásico. Como se discutió en la sección anterior, la revisión de creencias y el razonamiento probabilístico son centrales para alcanzar este objetivo. Cada uno de estos temas ha sido tratado en la literatura, generando antecedentes de combinaciones entre ellos; sin embargo, no conocemos ningún antecedente que combine todos al mismo tiempo. En esta sección primero repasamos los trabajos más significativos en este sentido (secciones 2.1–2.4), y luego describimos nuestra propuesta en la sección 2.5

2.1. Argumentación estructurada probabilística

En la literatura existen diversos formalismos para argumentación estructurada; en este trabajo elegimos la programación en lógica rebatible (DeLP, en inglés); aquí haremos una breve introducción, y referimos al lector a [10] para un tratamiento más profundo. Un programa DeLP está compuesto por un conjunto de hechos, reglas estrictas, y reglas rebatibles. Este suele denotarse con $\Pi = (\Theta, \Omega, \Delta)$, donde Θ es el conjunto de hechos, Ω es el conjunto de reglas estrictas, y Δ es el conjunto de reglas rebatibles. Los hechos son literales básicos (es decir, sin variables) que representan información atómica o su negación; siempre son verdaderos y no pueden ser contradictorios. Las reglas estrictas representan información de causa y efecto que siempre vale; se especifican a partir de la combinación de literales básicos de la forma $L_0 \leftarrow L_1, \dots, L_n$, donde L_0 es un literal básico y $\{L_i\}_{i>0}$ es un conjunto de literales básicos. Por otro lado, las reglas rebatibles incluyen conocimiento que vale si no se dispone de información que lo contradiga. Estas son parecidas a las reglas estrictas, pero representan conocimiento más débil. Se especifican de la forma $L_0 \prec L_1, \dots, L_n$, donde L_0 es un literal básico y $\{L_i\}_{i>0}$ es un conjunto de literales básico. La negación fuerte está permitida tanto para reglas estrictas como rebatibles con el fin de representar información contradictoria. A partir de estos conceptos elementales ya se puede hablar de la noción de argumento: un *argumento* para un literal L es un par $\langle A, L \rangle$, donde $A \subseteq \Delta$ consiste de una prueba para L de manera que: (1) L es derivado rebatiblemente a partir de A , (2) $A \cup \Omega$ es no contradictorio, y (3) A es un subconjunto mínimo de Δ que satisface (1) y (2), denotado $\langle A, L \rangle$.

El literal L se denomina la *conclusión* soportada por el argumento, y A es el *sopORTE*. Un argumento $\langle B, L \rangle$ es un *subargumento* de $\langle A, L' \rangle$ si y sólo si $B \subseteq A$.

Para manejar incertidumbre probabilística se puede tomar el modelo planteado en [21] donde se combina DeLP con variables de comportamiento aleatorio. De esta manera se pueden definir programas DeLP3E denotados como $P = (\Pi_{EM}, \Pi_{AM}, af)$, donde Π_{EM} permite representar conocimiento incierto sujeto a eventos probabilísticos, Π_{AM} permite representar conocimiento estricto y rebatible (programa DeLP), y af es una función, conocida como *función de anotación*, tal que su dominio es el conjunto Π_{AM} y su imagen es un subconjunto de las formulas lógicas fijas que pueden formarse a partir de los elementos definidos en Π_{EM} . A su vez, el conjunto de todas las fórmulas lógicas compuestas por átomos básicos de Π_{EM} define un conjunto de *mundos posibles*. En cada uno de estos mundos existe un subconjunto de elementos de Π_{AM} que son válidos, lo cual determina un programa DeLP (no probabilístico) que existe en ese mundo en cuestión. Esto da lugar a que un literal L pueda estar garantizado en un mundo y en otro no. Es así como la probabilidad de que un literal L esté garantizado resulta de la suma de las probabilidades de los mundos en los que L está garantizado.

Concretamente Π_{EM} debe seguir algún modelo de representación de eventos aleatorios; para este fin se podría utilizar Redes Bayesianas [19], Redes Lógicas de Markov [7], lógica probabilística de Nilsson [18], entre otros.

2.2. Revisión de creencias

El problema que se estudia en el área de revisión de creencias es el de cómo deben cambiar los estados epistémicos de un agente ante una nueva entrada epistémica; en otras palabras, cómo deben revisarse las creencias ante la presencia de información nueva que posiblemente contradice las creencias establecidas hasta el momento. Tradicionalmente, los estados epistémicos han tomado la forma o bien de conjuntos de creencias (conjuntos de fórmulas lógicas cerrados bajo consecuencia) [1,11] o bases de creencias (conjuntos no cerrados) [14,13]. Es evidente que el problema de la revisión de creencias aparece constantemente en el mundo real y, por lo tanto, cualquier sistema inteligente que funcione con datos del mismo deberá estar equipado con alguna forma de revisión. La metodología típica consiste en el desarrollo de operadores que toman la base de conocimiento actual y la entrada epistémica, y producen una nueva base de conocimiento que corresponde al resultado de revisar las creencias. Estos operadores en general se caracterizan por las propiedades que deben cumplir (expresadas en la forma de postulados); luego se proponen construcciones algorítmicas y se demuestra formalmente que las dos caracterizaciones son equivalentes: este tipo de resultado lleva el nombre de teorema de representación. Como se mencionó en la sección anterior, es necesario investigar operadores que sean especialmente propicios para funcionar en un entorno de PIFD y, en particular, también con aspectos cuantitativos para sacar el mayor provecho posible al razonamiento probabilístico subyacente; hasta donde conocemos, el único trabajo en esta última línea es la propuesta reciente de [22].

2.3. Procesamiento inteligente de flujos de datos

Si bien cada vez se tiene más información disponible a través de la Web o dispositivos móviles, responder preguntas que en principio parecen sencillas se vuelve sumamente complicado. Por ejemplo, se puede llegar a tener la información disponible de los clicks que hace un usuario al navegar la Web, y a partir de éstos uno podría pensar que puede saber cuáles son sus intereses, qué noticias atraen su atención, y tal vez de forma más general determinar cuál es el patrón que siguen los lectores con noticias relacionadas. Sin embargo, este tipo de consultas requiere de sistemas que puedan manejar la naturaleza del mundo real que cambia de manera muy rápida y ofrece obstáculos a nivel semántico. Si bien los datos que cambian rápidamente pueden ser analizados por *sistemas de procesamiento de flujos de datos* especializados en tiempo real [2,4], estos sistemas no pueden realizar tareas de procesamiento *inteligente* (complejas). Con este fin, en la última década se ha investigado y desarrollado sistemas con tales características [5,3]; por otra parte, en [9] se analizan distintas técnicas de procesamiento de *eventos complejos* bajo incertidumbre. Los autores tuvieron en cuenta técnicas basadas en autómatas y en lógicas, considerando la incertidumbre relativa a la imperfección en las reglas que definen los eventos, y la incompletitud y errores derivados del flujo de datos. Como se puede apreciar, la diferencia principal con nuestra propuesta es que estas técnicas sólo realizan un procesamiento con un contenido de nivel semántico muy bajo. Estos desarrollos han planteado soluciones iniciales y delineado los problemas más importantes a resolver; sin embargo, el área de PIFD está todavía en sus primeras etapas de evolución.

2.4. Sistemas argumentativos estructurados en entornos dinámicos

El problema de realizar un procesamiento inteligente de datos provenientes de flujos con valor semántico significativo es sumamente complejo debido a las características de frecuencia y volumen elevado de datos. En la línea de investigación planteada en [20,17,16] los autores trabajaron sobre un formalismo para representar y razonar sobre conocimiento cambiante mediante la *activación y desactivación* de argumentos de acuerdo a la evidencia disponible. Sin embargo, si bien el modelo tiene en cuenta un contexto cambiante, la dinámica del conocimiento considerada no tiene velocidad alta ni tampoco se considera grandes cantidades de datos de entrada, por lo que la complejidad computacional no es un aspecto central. Además, tampoco consideran datos que estén afectados por la incertidumbre.

2.5. Modelo propuesto

Nuestra propuesta se resume en la figura 1, la cual muestra el funcionamiento general del modelo planteado. Se tiene un sistema de procesamiento de flujos que genera eventos y los notifica ya sea a AM_t o a EM_t . AM_p contiene hechos, presuposiciones, reglas estrictas y reglas rebatibles relativas a conocimiento que

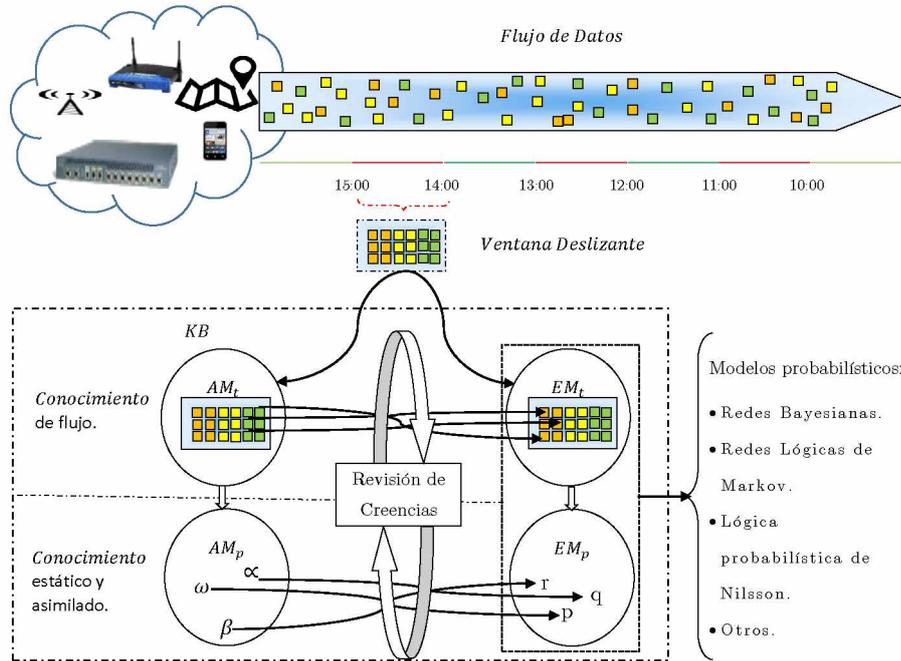


Figura 1. Esquema de un formalismo para combinar técnicas y herramientas de argumentación estructurada, revisión de creencias, razonamiento probabilístico y procesamiento de flujos.

generalmente no varía en el tiempo y ya se encuentra asimilado. Por otro lado, EM_p contiene un modelo probabilístico en relación a variables de comportamiento aleatorio cuya información contenida generalmente tampoco varía en el tiempo y ya se encuentra asimilado. AM_t contiene hechos, presuposiciones, reglas estrictas y reglas rebatibles relativas a conocimiento que generalmente varía en el tiempo y que proviene del flujo. Es importante destacar que los elementos de AM_t pueden pasar a formar parte de AM_p si adquieren una relevancia importante. EM_t contiene un modelo probabilístico en relación a variables de comportamiento aleatorio cuya información contenida generalmente varía en el tiempo y que proviene del flujo. Al igual que en el AM, algunos elementos de EM_t pueden pasar a formar parte de EM_p .

Ejemplo 2. Si se quiere aplicar el modelo planteado en la figura 1 en el ejemplo 1 se podría pensar, de manera muy simplificada, en la siguiente situación: existe un flujo de datos producido a partir de la información obtenida de los sensores del auto conducido de manera autónoma, como puede ser la ubicación de peatones y otros vehículos a una distancia considerada relevante, dirección y velocidad a la que se mueven estos últimos, cortes de calle, señales de tránsito, entre otros; esto se representa y modela en AM_t . También se dispone de conocimiento asimilado,

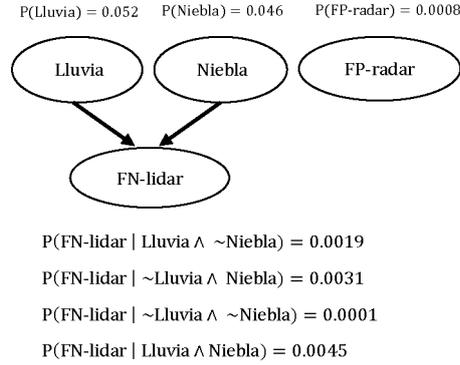


Figura 2. Red Bayesiana utilizada en los modelos EM_p y EM_t del ejemplo 2.

	AM_t	<i>Función de Anotación</i>
Θ :	$\Theta_1 = \text{mi_ubicacion}(t1, \text{posicion}, \text{direccion})$	True
	$\Theta_2 = \text{peaton_en_frente}$	$\sim\text{FP-radar}$
	$\Theta_3 = \sim\text{peaton_en_frente}$	$\sim\text{FN-lidar}$
	AM_p	
Θ :	<i>"Conjunto de hechos que representan el mapa de la ciudad"</i>	True
Ω :	$\Omega_1 = \text{detenerse} \leftarrow \text{peaton_en_frente}$	True
Δ :	$\Delta_1 = \text{ceder_paso} \leftarrow \text{vehiculo_cruzando},$	True

Figura 3. AM_t y AM_p del ejemplo 2, junto con su función de anotación. Los conjuntos de reglas de AM_t son vacíos.

como puede ser la ubicación de cada calle, el sentido de circulación, la ubicación de los semáforos, entre otros; este conocimiento está contenido en AM_p .

Al mismo tiempo, la información provista por el LIDAR se encuentra afectada por la incertidumbre, de manera que su confiabilidad se ve influida por condiciones climáticas como la presencia de neblina y/o lluvias fuertes. Esto podría representarse por tres variables aleatorias que indiquen la probabilidad de que el LIDAR entregue información categorizada como un falso positivo, la probabilidad de que haya neblina en un determinado momento, y la probabilidad de que haya lluvias fuertes en un determinado momento. Una forma de modelar esto es con una red bayesiana como la que se presenta en la figura 2; este conocimiento es parte de EM_p . Por último, se dispone de información proveniente de eventos aleatorios pero que tiene validez acotada en un período de tiempo; por

ejemplo, información de que efectivamente hay niebla en la posición actual del vehículo; esto forma parte de EM_t .

En la figura 3 presentamos un ejemplo simple del contenido de AM_t y AM_p , junto con una función de anotación. Dicho modelo hace la suposición de que EM_t y EM_p contienen los siguientes átomos: *FN-lidar* (probabilidad de que el LIDAR produzca un falso negativo), *FP-radar* (probabilidad de que un radar de ondas de radio produzca un falso positivo), *Lluvia* (probabilidad de que llueva intensamente) y *Niebla* (probabilidad de que haya niebla). Supongamos que el auto percibe la presencia de niebla; en este caso, en EM_t se instancia la variable *Niebla* con valor *verdadero*. Puede observarse en la figura 3 que en AM_t hay dos átomos que son contradictorios: *peaton_en_frente* y \sim *peaton_en_frente*. Sin embargo su anotación es diferente, el primero existe en los mundos donde no es un falso positivo del radar de ondas de radio, y el segundo en los mundos donde no es un falso negativo del LIDAR. Así, el sistema debería decidir cuál es más probable de acuerdo a la probabilidad de que haya ocurrido un falso negativo del LIDAR (teniendo en cuenta que hay niebla) y a la probabilidad de haya ocurrido un falso positivo del radar de ondas de radio. ■

3. Discusión y trabajo futuro

En este trabajo hemos planteado las dificultades y desafíos involucrados en la generación y procesamiento de conocimiento que se presenta en forma de *flujos*; es decir información con un valor semántico en contextos donde se producen grandes volúmenes de datos con alta frecuencia. La principal contribución es la propuesta de un modelo como punto de partida para realizar procesamiento inteligente de flujo de datos, utilizando técnicas de argumentación para aprovechar el contenido semántico por medio de sus capacidades para manejar información contradictoria y para otorgar explicaciones para las respuestas brindadas, lo cual puede ser muy útil o incluso necesario en ciertos dominios. La novedad de la propuesta radica en que hasta este momento no existen desarrollos que combinen procesamiento de flujos de datos, argumentación estructurada, revisión de creencias, y razonamiento bajo incertidumbre.

Como parte de esta línea de investigación, el trabajo actual y futuro involucra el desarrollo de algoritmos que integren las herramientas existentes para el procesamiento de flujos de datos y de eventos complejos con sistemas argumentativos de manera eficiente, ya que la tratabilidad computacional es un aspecto crucial para su eficacia. Otro objetivo principal es el desarrollo de operadores de revisión de creencia adecuados para entornos con conocimiento sumamente cambiante e incierto, lo cual dependerá también del uso adecuado de modelos probabilísticos eficientes.

Agradecimientos. Este trabajo fue parcialmente financiado por fondos provistos por la Universidad Nacional del Sur y CONICET, Argentina.

Referencias

1. Alchourrón, C.E., Gärdenfors, P., Makinson, D.: On the logic of theory change: Partial meet contraction and revision functions. *Journal of symbolic logic* 50(02), 510–530 (1985)
2. Arasu, A., Babu, S., Widom, J.: The CQL continuous query language: Semantic foundations and query execution. *VLDB Journal* 15(2), 121–142 (2006)
3. Barbieri, D.F., Braga, D., Ceri, S., VALLE, E.D., Grossniklaus, M.: C-SPARQL: A continuous query language for rdf data streams. *International Journal of Semantic Computing* 4(01), 3–25 (2010)
4. Cugola, G., Margara, A.: Processing flows of information: From data stream to complex event processing. *ACM Computing Surveys* 44(3), 15 (2012)
5. Della Valle, E., Ceri, S., Harmelen, F.v., Fensel, D.: It’s a streaming world! reasoning upon rapidly changing information. *IEEE Intell. Sys.* 24(6), 83–89 (2009)
6. Deyle, T.: Velodyne HDL-64E laser rangefinder (lidar) pseudo-disassembled. Online blog: <http://www.hizook.com/blog/2009/01/04/velodyne-hdl-64e-laser-rangefinder-lidar-pseudo-disassembled> (2009)
7. Domingos, P., Kok, S., Lowd, D., Poon, H., Richardson, M., Singla, P.: *Markov Logic*, pp. 92–117. Springer Berlin Heidelberg, Berlin, Heidelberg (2008)
8. Dung, P.M.: On the acceptability of arguments and its fundamental role in nonmonotonic reasoning, logic programming and n-person games. *Artificial intelligence* 77(2), 321–357 (1995)
9. Gal, A., Wasserkrug, S., Etzion, O.: Event processing over uncertain data. In: *Reasoning in Event-Based Distributed Systems*, pp. 279–304. Springer (2011)
10. García, A.J., Simari, G.R.: Defeasible logic programming: An argumentative approach. *Theory and practice of logic programming* 4(1+ 2), 95–138 (2004)
11. Gärdenfors, P.: *Belief revision*, vol. 29. Cambridge University Press (2003)
12. Guizzo, E.: How Google’s self-driving car works. *IEEE Spectrum Online*, October 18 (2011)
13. Hansson, S.: Semi-revision. *J. Appl. Non-Class. Log.* 7(1-2), 151–175 (1997)
14. Hansson, S.O.: Kernel contraction. *Journal of Symbolic Logic* 59, 845–859 (9 1994)
15. Martínez, M.V., García, A.J., Simari, G.R.: On the use of presumptions in structured defeasible reasoning. In: *Computational Models of Argument - Proceedings of COMMA 2012*, Vienna, Austria, September 10-12, 2012. pp. 185–196 (2012)
16. Moguillansky, M.O., Rotstein, N.D., Falappa, M.A., García, A.J., Simari, G.R.: Dynamics of knowledge in DeLP through argument theory change. *Theory and Practice of Logic Programming* 13(06), 893–957 (2013)
17. Moguillansky, M.O., Rotstein, N.D., Falappa, M.A., García, A.J., Simari, G.R.: Argument theory change through defeater activation. In: *COMMA*. pp. 359–366 (2010)
18. Nilsson, N.J.: Probabilistic logic. *Artificial intelligence* 28(1), 71–87 (1986)
19. Pearl, J.: *Probabilistic reasoning in intelligent systems: Networks of plausible inference*. (1988)
20. Rotstein, N.D., Moguillansky, M.O., García, A.J., Simari, G.R.: A dynamic argumentation framework. *COMMA* 216, 427–438 (2010)
21. Shakarian, P., Simari, G.I., Moores, G., Paulo, D., Parsons, S., Falappa, M.A., Aleali, A.: Belief revision in structured probabilistic argumentation: Model and application to cyber security. *AMAI, to appear* (2016)
22. Simari, G.I., Shakarian, P., Falappa, M.A.: A quantitative approach to belief revision in structured probabilistic argumentation. *AMAI* 76(3-4), 375–408 (2016)