



**Universidad Tecnológica Nacional**  
**Rectorado**  
**Secretaría de Ciencia, Tecnología y**  
**Posgrado**

**SISTEMA DE INFORMACION DE CIENCIA Y**  
**TECNOLOGIA (SICyT)**

**FORMULARIO PARA PROYECTOS DE INVESTIGACIÓN Y DESARROLLO**

**Código del Proyecto: EIUTIME0004481TC**

1. Unidad Científico-Tecnológica  
FR Mendoza - LABORATORIO DHARMA

### **2. Denominación del PID**

Aprendizaje de redes de Markov basado en independencias

### **3. Resumen Técnico del PID**

El presente es un proyecto de investigación básica en el área de Aprendizaje Automático, mas específicamente, consiste en el desarrollo de algoritmos para el aprendizaje automático a partir de observaciones de redes de Markov. Estas redes son una herramienta computacional para el modelado eficiente de distribuciones de probabilidad, que utiliza grafos no dirigidos para facilitar la representación de problemas complejos. Estas redes codifican en sus nodos al conjunto de variables aleatorias de la distribución, y en sus aristas al conjunto total de independencias condicionales existentes entre las variables aleatorias. Con estas redes es posible factorizar distribuciones de probabilidad conjuntas como productorias de funciones de sub-conjuntos de variables aleatorias, resultando en una reducción drástica de la dimensionalidad, y con ello en un aumento exponencial en la eficiencia de tres aspectos: (i) cómputo de inferencia probabilística a partir de esta distribución, (ii) memoria para almacenar los parámetros numéricos de la red, y (iii) cantidad de observaciones necesarias para estimar con precisión suficiente sus parámetros numéricos.. Esta investigación es la mas antigua de nuestro laboratorio, con sus inicios en la investigación doctoral del director del laboratorio (y el propuesto para este proyecto), el Dr. Bromberg, allá por el año 2002. En instancias anteriores de esta temática de investigación se formó dos doctores (Dr Schlüter y Dr Edera), ambos Ingenieros en Sistemas egresados de nuestra FRM, y miembros del presente proyecto. Actualmente se suma la becaria doctoral Ing. Strappa. Todo esto lleva a que el proyecto esté compuesto por tres líneas de investigación en el área. Todas ellas apuntan al diseño de algoritmos que aprendan las estructuras de Markov de manera efectiva y eficiente en términos de datos, permitiendo obtener con ellos estructuras de mejor calidad que las obtenidas por los algoritmos del estado del arte.

### **4. Programa**

Electrónica, Informática y Comunicaciones

### **5. Proyecto**

Tipo de Proyecto: UTN (PID UTN) CON INCORPORACION EN PROGRAMA INCENTIVOS

Tipo de Actividad: Investigación Básica

### **Campos de Aplicación:**

<b>Rubro</b>	<b>Descrip. Actividad</b>	<b>Otra (especificada)</b>
PROMOCION GENERAL DEL CONOCIMIENTO	Varias ciencias (Especificar)	Aplicaciones que requieran modelado probabilístico

### **Disciplinas Científicas:**

<b>Rubro</b>	<b>Disciplina Científica</b>	<b>Otras Disciplinas Científicas</b>
MATEMÁTICA	Estadística	-
MATEMÁTICA	Métodos numéricos y computación	-
MATEMÁTICA	Probabilidad	-
CIENCIAS DE LA COMPUTACIÓN E INFORMÁTICA	Inteligencia Artificial	-
CIENCIAS DE LA COMPUTACIÓN E	Estructuras de datos y Algoritmos	-

INFORMÁTICA	Estructuras de datos y Algoritmos	-
CIENCIAS DE LA COMPUTACIÓN E INFORMÁTICA	Computación Numérica y Simbólica	-

### Palabras Clave

Redes-Markovianas Distribuciones-Multivariadas Aprendizaje-Automático

### 6. Fechas de realización

Inicio	Fin	Duración	Fecha de Homologación
01/01/2017	31/12/2019	36 meses	-

### 7. Aprobación/ Acreditación / Homologación / Reconocimiento (para ser completado por la SCTyP - Rectorado)

#### 7.1 Aprobación / Acreditación / Reconocimiento (para ser completado por la FR cuando se posea N° Resolución)

N° de Resolución de aprobación de la FR:

#### 7.2 Homologación (para ser completado por la SCTyP - Rectorado)

Código SCTyP : EIUTIME0004481TC

Disposición SCTyP:

Código Ministerio:

### 8. Estado (para ser completado por la SCTyP - Rectorado)

EN TRÁMITE

### 9. Aavales (presentación obligatoria de aavales)

### 10. Personal Científico Tecnológico que participa en el PID

Apellido y Nombre	Cargo	Hs/Sem	Fecha Alta	Fecha Baja	Otros Cargos
BROMBERG, FACUNDO	DIRECTOR	40	01/01/2017	31/12/2019	
PEREZ, SEBASTIÁN	BECARIO POSGRADO - DOCTORAL EN EL PAÍS	5	01/01/2017	31/12/2019	
SCHLUTER, FEDERICO	INVESTIGADOR FORMADO	40	01/01/2017	31/12/2019	
EDERA, ALEJANDRO	INVESTIGADOR FORMADO	20	01/01/2017	31/12/2019	-
DIEDRICHS ESCUDERO, ANA LAURA	BECARIO POSGRADO - DOCTORAL EN EL PAÍS	5	01/01/2017	31/12/2019	-
ABRAHAM, LEANDRO	BECARIO POSGRADO - DOCTORAL EN EL PAÍS	5	01/01/2017	31/12/2019	-
DIAZ, CARLOS ARIEL	BECARIO POSGRADO - DOCTORAL EN EL PAÍS	5	01/01/2017	31/12/2019	-
STRAPPA FIGUEROA, YANELA DAIANA	BECARIO POSGRADO - DOCTORAL EN EL PAÍS	40	01/01/2017	31/12/2019	-
RIBAS, ALEXANDRE	BECARIO POSGRADO - DOCTORAL EN EL PAÍS	5	01/01/2017	31/12/2019	-

### 11. Datos de la investigación

#### Estado actual de concimiento del tema

Las redes de Markov son una herramienta computacional para el modelado eficiente de distribuciones de probabilidad, que utiliza grafos no dirigidos para facilitar la representación de problemas complejos. Estas redes codifican en sus nodos al conjunto de variables aleatorias de la distribución, y en sus aristas al conjunto total de independencias condicionales existentes entre las variables aleatorias. Con estas redes es posible factorizar distribuciones de probabilidad conjuntas como productorias de funciones de sub-conjuntos de variables aleatorias, resultando en la práctica en una reducción drástica de la dimensionalidad, y con ello en un aumento exponencial en la eficiencia de tres aspectos: (i) cómputo de inferencia probabilística a partir de esta distribución, (ii) memoria para almacenar los parámetros numéricos de la red, y (iii) cantidad de observaciones necesarias para estimar con precisión suficiente sus parámetros numéricos.

Estos modelos han sido diseñados para ser manipulados por sistemas expertos, utilizando teoría de la probabilidad para razonar eficientemente bajo condiciones de incertidumbre. Pueden verse algunos ejemplos de su aplicación en áreas como visión computacional y análisis de imágenes [4, 5], computación evolutiva [6], bioinformática [7] y biomedicina [8, 9], entre muchas otras [10]. Sin embargo, una limitación importante para el uso de estos modelos es que en la práctica resulta complejo diseñarlos manualmente, ya que el conocimiento de expertos no siempre es suficiente, sumado al hecho de que muchos dominios reales poseen una gran dimensionalidad. Por esto, el aprendizaje de redes de Markov a partir de datos es un tópico que ha tomado gran relevancia, ya que no solo resulta ser un mecanismo exitoso para el descubrimiento de nuevo conocimiento, sino de que la disponibilidad de datos digitales es cada vez mayor.

Nuestra investigación se centra en un enfoque específico de aprendizaje de redes de Markov basado en independencias probabilísticas [11, 12, 13, 14, 15, 16, 17]. Estos algoritmos aprenden la estructura de independencias del modelo basados en lineamientos teóricos que permiten aprender la estructura de un modo eficiente, robusto, y con garantías analíticas de correctitud, a partir de la ejecución de un conjunto de tests estadísticos de independencias probabilística condicional ejecutados sobre los datos. De manera intuitiva esto resulta del hecho de que el grafo de la red de Markov codifica justamente estas independencias condicionales. Comúnmente, los resultados de dichos tests son utilizados como restricciones que guían una búsqueda en el espacio de las estructuras de independencia posibles, convergiendo a una estructura que satisface los resultados de

todos los tests. Estos algoritmos garantizan que la estructura aprendida es correcta bajo la suposición de que los tests estadísticos son correctos. No obstante, un hecho muy común en la práctica suele ser que los datos disponibles no son suficientes para obtener resultados correctos para los tests estadísticos. Cuando esto sucede, los algoritmos basados en independencia acumulan y propagan suposiciones de independencia incorrectas, resultando en el aprendizaje de una red con gran cantidad de errores estructurales. Errores en estas estructuras se propagan en errores en la factorización de la distribución que representa, resultando en errores en la codificación probabilística del conocimiento.

- [4] D. Anguelov, B. Taskar, V. Chatalbashev, D. Koller, D. Gupta, G. Heitz, and A. Ng. *Discriminative Learning of Markov Random Fields for Segmentation of 3D Range Data*. Proceedings of the CVPR, 2:169–176, 2005.
- [5] S. Li. *Markov random field modeling in image analysis*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2001.
- [6] P. Larrañaga, H. Karshenas, C. Bielza, and R. Santana. *A review on probabilistic graphical models in evolutionary computation*. Journal of Heuristics, 18(5):795–819, 2012.
- [7] R. Mourad, C. Sinoquet, and P. Leray. Probabilistic graphical models for genetic association studies. Briefings in bioinformatics, 13(1):20–33, 2012.
- [8] M. Schmidt, K. Murphy, G. Fung, and R. Rosales. *Structure learning in random fields for heart motion abnormality detection*. In Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on, pages 1–8, June 2008.
- [9] J. Van Haaren, J. Davis, M. Lappenschaar, and A. Hommersom. *Exploring disease interactions using Markov networks*. In Workshops at the Twenty-Seventh AAAI Conference on Artificial Intelligence, 2013.
- [10] P. Larrañaga and S. Moral. *Probabilistic graphical models in artificial intelligence*. Applied soft computing, 11(2):1511–1528, 2011.
- [11] P. Spirtes, C. Glymour, and R. Scheines. *Causation, Prediction, and Search*. Adaptive Computation and Machine Learning Series. MIT Press, 2000.
- [12] F. Bromberg, D. Margaritis, and V. Honavar. *Efficient Markov network structure discovery using independence tests*. JAIR, 35:449–485, July 2009.
- [13] P. Gandhi, F. Bromberg, and D. Margaritis. *Learning Markov Network Structure using Few Independence Tests*. In SIAM International Conference on Data Mining, pages 680–691, 2008.
- [14] D. Margaritis and F. Bromberg. *Efficient Markov Network Discovery Using Particle Filters*. Comp. Intel., 25(4):367–394, 2009.
- [15] F. Bromberg and D. Margaritis. *Improving the Reliability of Causal Discovery from Small Data Sets using Argumentation*. JMLR, 10:301–340, Feb 2009.
- [16] F. Schlüter. *A survey on independence-based Markov networks learning*. Artificial Intelligence Review, pages 1–25, 2012.
- [17] F. Schlüter, F. Bromberg, and A. Edera. *The IBMAP approach for Markov network structure learning*. Annals of Mathematics and Artificial Intelligence, pages 1–27, 2014.

### Grado de Avance

A fin de mejorar la calidad del aprendizaje de estructuras de redes de Markov basado en independencias, nuestra investigación pretende combatir el hecho de que los tests estadísticos de independencia frecuentemente son inexactos. La motivación se basa en la importante mejora en la eficiencia que implica el enfoque de aprendizaje basado en independencias frente a alternativas. En sus estadios iniciales esta investigación dió sus primeros frutos durante el desarrollo de la tesis doctoral del director del presente proyecto, ya en el año 2009 [12, 13, 14, 15]. Luego ya enmarcada en la investigación doctoral del Dr Schlüter (miembro del presente proyecto) esta investigación resultó en una revisión completa del estado del arte, que fue publicada en la revista Artificial Intelligence Review [16]. En este trabajo se analizan y discuten las limitaciones de los algoritmos existentes, proponiendo una serie de problemas abiertos que motivaron nuestros siguientes trabajos en el área. Posteriormente, se trabajó en el desarrollo del enfoque IBMAP (por sus siglas en inglés, independence-based maximum-a-posteriori), que ataca el problema de la falla de estos algoritmos en condiciones de insuficiencia de datos. Resultados parciales de este trabajo fueron publicados en la International Conference on Tools with Artificial Intelligence [30]. Luego se trabajó en una versión extendida de este trabajo, donde se explica el enfoque en más profundidad, y se presenta una serie de resultados experimentales más contundentes. Este trabajo se encuentra actualmente publicado en la revista Annals of Mathematics and Artificial Intelligence [17].

A partir de la permanente necesidad de mejorar la calidad de los modelos aprendidos desde los datos, el enfoque IBMAP propone una alternativa a los algoritmos tradicionales (que descartan la estructura correcta cada vez que ejecutan un test erróneo), asignando probabilidades a todas las estructuras posibles, sin descartar ninguna. Para esto, se diseñó una función de puntaje de estructuras basada en tests estadísticos denominada IB-score (puntaje basado en independencias). Esta función permite computar de un modo computacionalmente eficiente y aproximado la probabilidad a posteriori de una estructura, dados los datos, i.e.  $\Pr(G|D)$ , combinando los resultados de un conjunto de tests estadísticos. De este modo, las diferentes estructuras poseen un puntaje más alto o más bajo según las probabilidades de las independencias que codifican. El enfoque IBMAP consiste entonces en la maximización del IB-score en el espacio de todas las estructuras posibles. A modo de instanciación del enfoque, pueden utilizarse diversos algoritmos de optimización para la maximización del IB-score. En [17] se demuestra que utilizando dicho enfoque con una búsqueda simple de Ascensión de Colinas se obtienen mejoras significativas en la calidad de las estructuras aprendidas, respecto a otros algoritmos basados en independencias del estado del arte.

Durante el desarrollo de este enfoque también se trabajó en el testeo de la calidad y performance de IBMAP en una aplicación real de las redes de Markov. Hemos integrado nuestra investigación con el área de algoritmos evolutivos, aplicando IBMAP a los algoritmos EDAs [22, 6] (Estimation of Distribution algorithms). Los EDAs son un tópico novedoso y bien establecido en el campo de los algoritmos evolutivos que pueden utilizar redes de Markov para mejorar su performance [23, 24]. Tras aplicar IBMAP a dichos algoritmos hemos obtenido resultados positivos en la performance de los EDAs, los cuales se han presentado como parte de nuestros resultados experimentales en [17]. Este trabajo de aplicación de IBMAP a un área de otra disciplina se ha llevado a cabo mediante colaboración con el investigador Roberto Santana Hermida, de la Universidad del País Vasco, actualmente co-director de beca postdoctoral de Dr. F. Schlüter. Para finalizar, cabe destacar que en la actualidad los miembros del grupo se encuentran trabajando paralelamente en una línea de investigación complementaria, en la que se ha avanzado con resultados interesantes. Dicha investigación consiste en utilizar algoritmos basados en independencia para aprender distribuciones que no se pueden representar con un simple grafo no dirigido, pero sí con representaciones refinadas

para redes de Markov. Estas distribuciones contienen independencias específicas del contexto [31], que son independencias condicionales que en vez de cumplirse sobre todas las asignaciones del conjunto condicionante, solo se cumplen para una dada asignación de este conjunto llamada contexto. Lo interesante de esta investigación es que cuando la distribución presenta dichos patrones de independencia (un hecho sumamente común en la práctica), los algoritmos que aprenden un grafo no dirigido tienden a aprender estructuras muy densas que terminan oscureciendo las independencias de la distribución, con las ineficiencias y errores que lo acompañan. Por esto se trabajó en el desarrollo de un enfoque que propone una representación refinada de la estructura llamada modelos canónicos, y en el desarrollo de algoritmos basados en independencias que aprenden este tipo de modelos. Se realizó una evaluación empírica extensiva, demostrando que este método puede aprender estructuras de muy buen poder predictivo. Los resultados de este trabajo fueron publicados inicialmente en una conferencia internacional [32], obteniendo un premio a mejor trabajo de estudiantes. Posteriormente, publicamos una versión extendida de este trabajo en la revista *International Journal on Artificial Intelligence Tools* [33].

[6] P. Larranaga, H. Karshenas, C. Bielza, and R. Santana. *A review on probabilistic graphical models in evolutionary computation*. *Journal of Heuristics*, 18(5):795–819, 2012.

[12] F. Bromberg, D. Margaritis, and V. Honavar. *Efficient Markov network structure discovery using independence tests*. *JAIR*, 35:449–485, July 2009.

[13] P. Gandhi, F. Bromberg, and D. Margaritis. *Learning Markov Network Structure using Few Independence Tests*. In *SIAM International Conference on Data Mining*, pages 680–691, 2008.

[14] D. Margaritis and F. Bromberg. *Efficient Markov Network Discovery Using Particle Filters*. *Comp. Intel.*, 25(4):367–394, 2009.

[15] F. Bromberg and D. Margaritis. *Improving the Reliability of Causal Discovery from Small Data Sets using Argumentation*. *JMLR*, 10:301–340, Feb 2009.

[16] F. Schlüter. *A survey on independence-based Markov networks learning*. *Artificial Intelligence Review*, pages 1–25, 2012.

[17] F. Schlüter, F. Bromberg, and A. Edera. *The IBCMAP approach for Markov network structure learning*. *Annals of Mathematics and Artificial Intelligence*, pages 1–27, 2014.

[22] H. Muhlenbein and G. Paaß. *From recombination of genes to the estimation of distributions*. In Hans-Michael Voigt, Werner Ebeling, Ingo Rechenberg, and Hans Paul Schwefel, editors, *Parallel Problem Solving from Nature — PPSN IV*, volume 1141 of *Lecture Notes in Computer Science*, pages 178–187. Springer Berlin / Heidelberg, 1996. 10.1007/3-540-61723-X 982.

[23] M. Alden. *MARLEDA: Effective Distribution Estimation Through Markov Random Fields*. PhD thesis, Dept of CS, University of Texas Austin, 2007.

[24] S. Shakya, R. Santana, and J. Lozano. *A markovianity based optimization algorithm*. *Genetic Programming and Evolvable Machines*, 13(2):159–195, 2012.

[30] F. Bromberg, F. Schlüter, and A. Edera. *Independence-based MAP for Markov networks structure discovery*. In *23rd IEEE International Conference on Tools with Artificial Intelligence (ICTAI)*, pages 497–504. IEEE, 2011.

[32] A. Edera, F. Schlüter, and F. Bromberg. *Learning Markov networks with context-specific independences*. In *IEEE 25th International Conference on Tools with Artificial Intelligence (ICTAI)*, pages 553–560, Nov 2013.

[33] A. Edera, F. Schlüter, and F. Bromberg. *Learning Markov network structures constrained by context-specific independences*. *International Journal on Artificial Intelligence Tools (IJAIT)*, 2014.

### Objetivos de la investigación

La calidad de las estructuras resultantes de los algoritmos basados en independencias depende fuertemente de la calidad de los tests estadísticos de independencia llevados a cabo durante su ejecución. Se sabe que dichos tests pueden resultar en decisiones incorrectas cuando la cantidad de datos es insuficiente. Si bien la disponibilidad de datos crece continuamente con la innovación en materia de instrumentación digital, los tests estadísticos de independencia requieren cantidades de datos exponenciales en la cantidad de variables que involucran [18]. Debido a la importante mejora en la eficiencia del aprendizaje de estructuras de redes de Markov obtenida por el enfoque basado en independencias, el presente proyecto propone concentrarse en la mejora de la calidad de los modelos producidos por medio de dos caminos complementarios: uno teórico y otro aplicado. La vía teórica propone investigar una forma de extender el impacto del enfoque de máximo a posteriori basado en independencia (IBMAP, por sus siglas en inglés independence-based maximum-a-posteriori) [17]. La vía aplicada propone el estudio del uso de estas tecnologías en el área de los algoritmos evolutivos. Dichos objetivos se detallan a continuación:

**Objetivo específico I:** mejorar mecanismos de puntuación de estructuras (vía teórica).

Esta vía pretende investigar en métodos para mejorar la calidad de las estructuras aprendidas mediante mecanismos de puntuación de estructuras basados en independencia. Este enfoque ya ha sido parcialmente desarrollado en el trabajo de tesis doctoral de F. Schlüter, con el enfoque IBCMAP. Dicho enfoque utiliza un mecanismo de puntaje que computa aproximadamente la probabilidad a posteriori de las posibles estructuras dadas los datos, i.e.,  $\Pr(G|D)$ . El objetivo es desarrollar mecanismos de puntaje que provean una mejor aproximación de  $\Pr(G|D)$ , a fin de obtener mejoras en calidad respecto de IBCMAP. Para ello, el problema se abordará a través del desarrollo de estudios que permitan simular el aprendizaje con datos sintéticos, a fin de visualizar el impacto de las aproximaciones utilizadas. Adicionalmente, se trabajará en el análisis teórico de demostraciones respecto de las propiedades y garantías que poseen los diversos mecanismos de puntaje (los existentes y las alternativas

propuestas).

**Objetivo específico II:** aplicar aprendizaje de estructuras en algoritmos evolutivos (vía aplicada).

En esta vía se pretende realizar un estudio de análisis de la relación entre la calidad de los modelos obtenidos por el aprendizaje de redes de Markov, y el desempeño de los algoritmos de estimación de distribuciones (EDAs, por sus siglas en inglés: Estimation of Distribution Algorithms). Este estudio permitirá proponer recomendaciones relativas al uso específico de los diferentes tipos de algoritmos de aprendizaje para determinadas clases de problemas de optimización. El problema se abordará a través de un estudio comparativo de diferentes algoritmos de aprendizaje de redes de Markov, analizando la capacidad de los mismos para recuperar la estructura correcta (conocida) del problema, evaluando su impacto en el desempeño de los algoritmos EDAs. Se propone utilizar un conjunto de problemas con diversos patrones de interacciones entre sus variables, para analizar los efectos que la calidad de las estructuras aprendidas tienen en el rendimiento de los EDAs. Es oportuno mencionar que se ha acordado trabajar colaborativamente en esta vía de investigación con el Grupo de Sistemas Inteligentes de la Universidad del País Vasco, que ya posee experiencia y numerosas publicaciones en el área de EDAs basados en redes de Markov. Para ello, los Dres. Bromberg y Schlüter visitaremos este laboratorio en Noviembre del año 2016, el Dr. Schlüter por un período de 3 meses financiado por una beca para estancias en el exterior del CONICET, y el Dr. Bromberg por pocos días financiado con los proyectos de Misiones académicas de la SPU.

[17] **F. Schlüter, F. Bromberg, and A. Edera.** *The IBBMAP approach for Markov network structure learning.* *Annals of Mathematics and Artificial Intelligence*, pages 1–27, 2014.

[18] **A. Agresti.** *Categorical Data Analysis.* Wiley, 2nd edition, 2002.

### Descripción de la metodología

Para continuar logrando avances en la dirección del objetivo general y los dos objetivos específicos del presente plan, se propone las hipótesis de trabajo descriptas a continuación, acompañadas por las respectivas metodologías de investigación a seguir por cada una:

Hipótesis de trabajo I: relajar la suposición de independencias en IB-score mejorará la calidad de las estructuras aprendidas.

Como ya se explico más arriba, el enfoque IBBMAP propone el aprendizaje de la estructura a través de la maximización del IB-score. La función IB-score se construye a partir de la propuesta de un meta-modelo probabilístico que considera variables aleatorias  $I_1, \dots, I_n$  para representar de manera probabilística las aserciones de independencias condicionales, y reemplaza en  $\Pr(G|D)$  a la estructura de independencias  $G$  por el conjunto de variables aleatorias correspondientes a las independencias condicionales codificadas en  $G$ . Esto resulta en una distribución a posteriori equivalente  $\Pr(I_1, \dots, I_n|D)$ , i.e.,  $\Pr(I_1, \dots, I_n|D) = \Pr(G|D)$ . Para poder computar esta distribución, el enfoque IB-MAP asume la independencia mutua entre estas variables, resultando en una productoria de factores del tipo  $\Pr(I_i|D)$  por cada variable  $I_i$ . Esta suposición, si bien drástica, ofrece una manera de computar  $\Pr(I_1, \dots, I_n|D)$ , calculando cada factor de la productoria por medio del test Bayesiano de independencia condicional [34]. Dados los resultados experimentales publicados en [17], la conclusión al respecto es que efectivamente dichas aserciones son independientes entre sí cuando el conjunto de datos es suficientemente grande. En contraste, es muy normal que se den condiciones de escasez de datos, donde las aserciones de independencia utilizadas para computar el IB-score no son necesariamente independientes entre sí (intuitivamente esto es porque con pocos datos, estos no son suficientes para obtener el valor real de dichas independencias). Por esto, esta hipótesis de trabajo propone diseñar nuevas funciones de puntaje de estructuras para mejorar dicha aproximación. La vía de trabajo más promisorio consiste en relajar la suposición de independencias que se hace en el enfoque IBBMAP. Para ello, contemplamos utilizar algunas relaciones lógicas y axiomáticas que existen entre las aserciones de independencia condicional, bien conocidas en la literatura [1], que consisten en relaciones que se cumplen entre cierto conjunto de aserciones de independencia y alguna otra aserción. Estas relaciones claramente invalidan la suposición de independencia entre estas aserciones de independencia.

Detallamos a continuación algunas consideraciones respecto a la metodología de investigación a utilizar a través de ciertos detalles de diseño de nuestros experimentos:

1. Base racional de cada experimento: Para ponderar la calidad y eficiencia de las nuevas funciones de puntaje propuestas se realizarán experimentos para observar la calidad de los modelos obtenidos mediante su maximización. Estos experimentos se realizarán sobre diferentes grados de realismo y dificultad. La calidad de los modelos aprendidos se medirá a través de la distancia de Hamming y la precisión de los modelos, que son las medidas de calidad que se utilizan usualmente en la literatura. El objetivo de estos experimentos es demostrar la hipótesis de que la maximización de funciones de puntaje que relajen la suposición de independencias de IB-score producirá modelos de mejor calidad estructural.

2. Como se llevarán a cabo los experimentos: Para realizar estos experimentos es necesario codificar en algún lenguaje de propósito general las funciones de puntaje propuestas, y un conjunto de algoritmos de maximización para optimizar dichas funciones, así como también se requiere implementar los algoritmos competidores (el presente equipo prefiere el lenguaje Java por su versatilidad y conocimiento generalizado). Se correrá tanto las soluciones propuestas como los algoritmos competidores sobre conjuntos de datos sintéticos (de los cuales se sabe la estructura subyacente) y también sobre conjuntos de datos benchmark del área. En los conjuntos de datos

generados sintéticamente, se computará y reportará la distancia de Hamming de los modelos aprendidos respecto de la estructura solución subyacente. En los conjuntos de datos de benchmark se medirá la precisión, que es una medida que se puede calcular desde los datos, cuando la solución del problema es desconocida (más detalles en las técnicas que son patrimonio del grupo).

3. Que controles se usarán: Todos los algoritmos resultantes se ejecutarán utilizando el mismo test estadístico (e.g. chi-cuadrado de Pearson). Se realizarán barridos sobre porciones aleatorias de los conjuntos de datos para analizar como evolucionan las respuestas de los tests estadísticos, de acuerdo a la disponibilidad de datos. Las variables de control son: el conjunto de datos utilizado y el algoritmo de aprendizaje de estructuras utilizado. Las variables de salida son: la distancia de Hamming (medida de error en datos sintéticos) y precisión (medida de performance en datos benchmark).

4. Técnicas que son patrimonio del grupo (descriptas o publicadas). Dado que es usual no solo testear la calidad de los modelos aprendidos desde datos sintéticos, sino también desde conjuntos de datos benchmark donde el modelo real subyacente es desconocido, en este caso la distancia de Hamming no puede computarse ya que requiere comparaciones con el modelo real subyacente. En trabajos anteriores del grupo [12, 14, 17] se introdujo una aproximación del cómputo de la precisión que utiliza como verdad subyacente las independencias que se cumplen en el conjunto completo de datos, aprendiendo el modelo desde un subconjunto reducido de datos. Adicionalmente, nos encontramos desarrollando técnicas para evaluar y analizar las características de distintas funciones de puntaje sobre el espacio de búsqueda de todas las estructuras posibles, a fin de diseñar métodos prácticos para comparar las bondades de distintas funciones de puntaje (comparación de características deseadas, como rugosidad, convexidad, consistencia, etc.)

5. Como se interpretarán los datos a la luz de lo que se quiere estudiar y cómo se contrastará con la hipótesis de trabajo: La hipótesis se confirmará si para cada conjunto de datos utilizado en los experimentos se cumple que: (i) los modelos aprendidos tras maximizar las nuevas funciones de puntaje diseñadas tienen mejor calidad que los modelos generados por el algoritmo ILMAP, y se reforzará si además este mejora frente a la calidad de las estructuras producidas por los algoritmos del estado del arte (es decir, presentan mayor precisión y menor distancia de Hamming). Si esto no se cumple para todos los conjuntos de datos, se elaborará un análisis detallando las características de los casos para los cuales la hipótesis sí se cumple, y se estudiarán las razones por las cuales la hipótesis no se cumple en los otros casos.

6. Tratar de evaluar limitaciones y potenciales problemas de la metodología (tratando de proponer alternativas): La principal dificultad que se vislumbra es que los tiempos de ejecución de los experimentos pueden llegar a ser extremadamente costosos computacionalmente. Esto se debe a la inherente naturaleza exponencial de la maximización de funciones de puntaje sobre el espacio de todas las estructuras posibles. Un modo de atacar esta dificultad es mediante el diseño de algoritmos de optimización heurísticos, o muestreando el espacio de búsqueda con algoritmos específicos para tal fin (por ejemplo, métodos basados en Monte Carlo).

---

Hipotesis de trabajo II: un estudio de aprendizaje de estructuras en EDAs contribuirá con ambas áreas.

Los EDAs son un novedoso método de optimización heurística basado en el uso de aprendizaje y muestreo de distribuciones de probabilidad [22, 6]. Los EDAs pertenecen a la clase de los algoritmos evolutivos, inspirados en la evolución natural, en particular los algoritmos genéticos, pero a diferencia de ellos, sustituyen los métodos de cruzamiento y mutación por el modelado probabilístico de las mejores soluciones. El modelado probabilístico permite obtener mejoras considerables en términos de la eficiencia computacional de los algoritmos de optimización. Los EDAs han sido aplicados de forma creciente en dominios tan diversos como la bioinformática [35], el diseño de componentes mecánicos para automotores [36], y la optimización de la gestión de combustible en reactores nucleares [37], entre otros. Recientemente se ha propuesto una clase particular de EDAs que permite modelar las distribuciones de probabilidad utilizando redes de Markov. Esta clase de EDAs ha demostrado interesantes mejoras en términos de la convergencia a soluciones con alto valor de la función objetivo [23, 38, 24]. Sin embargo, un problema abierto en el área de los EDAs es dilucidar qué relación existe entre la calidad de los modelos aprendidos durante la ejecución de los mismos y la convergencia de estos algoritmos de optimización.

En algunos dominios de aplicación, los modelos que son capaces de incorporar información disponible sobre la estructura del problema pueden producir muy buenos resultados en términos de calidad de las soluciones finales [39, 6]. Sin embargo, para el caso de los EDAs basados en redes de Markov esta cuestión no ha sido investigada en detalle. Por esto, se propone realizar un estudio comparativo de diferentes algoritmos de aprendizaje de redes de Markov, analizando la capacidad de diversos algoritmos para recuperar la estructura correcta (conocida) del problema. Además, se utilizará un conjunto de problemas con diversos patrones de interacciones entre sus variables, y se estudiarán los efectos que la calidad de las estructuras aprendidas tienen en los resultados del EDA. Esta hipótesis de trabajo sostiene que una mejor comprensión de la relación existente entre la precisión de los algoritmos de aprendizaje de redes de Markov y la eficiencia en la optimización de los EDAs, contribuirá con conocimiento útil para proponer recomendaciones relativas al uso de algoritmos de aprendizaje para determinadas clases de problemas de optimización. Igualmente, también es útil para evaluar la capacidad de los algoritmos de aprendizaje de

estructuras, y detectar las falencias de estos algoritmos en una aplicación real, dando pie a la obtención de nuevo conocimiento respecto de nuestro principal tema de investigación.

Detallamos a continuación algunas consideraciones respecto a la metodología de investigación para esta hipótesis, a utilizar a través de ciertos detalles de diseño de nuestros experimentos:

1. Base racional de cada experimento. Para analizar la relación entre calidad del aprendizaje de estructuras y la eficiencia de optimización de algoritmos EDAs se realizarán experimentos para observar como en distintas condiciones la calidad del aprendizaje afecta al rendimiento de la optimización. Estos experimentos se realizarán sobre diferentes problemas estándares que existen para algoritmos evolutivos, utilizando diversos algoritmos de aprendizaje de estructuras del estado del arte, y utilizando diferentes tamaños de población (lo que condiciona la calidad del aprendizaje estructural). Luego se reportará la eficiencia de los algoritmos de aprendizaje de estructura utilizados en los EDAs midiendo la distancia de Hamming de la estructura aprendida (ya que en los problemas benchmark la estructura subyacente es conocida) y se medirá también el rendimiento del algoritmo EDA contabilizando la cantidad de evaluaciones de fitness que fueron necesarias, y el tamaño de población crítico. El tamaño de población crítico se obtiene corriendo el EDA haciendo un barrido sobre distintos tamaños de población, eligiendo aquél que presenta desempeño óptimo para un número determinado de repeticiones aleatorias. Estos experimentos tienen un doble propósito. Por un lado, se pretende obtener información para proponer recomendaciones relativas al uso específico de los diferentes tipos de algoritmos de aprendizaje de estructuras en EDAs, para determinadas clases de problemas de optimización. Por otro lado, se pretende también adquirir nuevo conocimiento que permita en el futuro diseñar nuevos algoritmos de aprendizaje de estructuras más eficientes.

2. Como se llevarán a cabo los experimentos: Se codificará en lenguaje Java tanto los algoritmos de aprendizaje de estructuras requeridos para el estudio, como los algoritmos EDAs, y las funciones benchmark de optimización que se deseen evaluar. Para cada función benchmark tenida en cuenta para el experimento, se medirá la performance del algoritmo EDA con cada algoritmo de aprendizaje de estructuras, reportando la calidad estructural obtenida por cada algoritmo como paso intermedio. Se verificará según las características de cada problema benchmark, la relación existente con la dificultad del aprendizaje de estructuras, y como se ve afectado el rendimiento de optimización del algoritmo EDA.

3. Que controles se usará: Todos los algoritmos de aprendizaje se ejecutaran utilizando un mismo test estadístico (e.g. chi-cuadrado de Pearson). Se llevará a cabo un barrido sistemático respecto de todas las posibles maneras de configurar el algoritmo EDA (tamaño de población, porcentaje de selección de individuos, etc.), a fin de encontrar la configuración óptima. Las variables de control y de salida del experimento:

Variables de control: el problema benchmark de optimización, el algoritmo de aprendizaje de estructuras, la configuración del algoritmo EDA (tamaño de población, porcentaje de selección de individuos, etc.). ?

Variables de salida: cantidad de evaluaciones de la función de fitness del EDA, tamaño de población crítica del EDA, y calidad estructural del algoritmo de aprendizaje utilizado.

4. Técnicas que son patrimonio del grupo (descriptas o publicadas): Las técnicas que son patrimonio del grupo son varios de los algoritmos de aprendizaje de estructura a utilizar. Estos experimentos son de aplicación de la tecnología que desarrollamos en nuestro grupo. El resto de las técnicas a utilizar (como los algoritmos EDAs, y las métricas de evaluación) pertenecen en gran parte al Grupo de Sistemas Inteligentes de la universidad del País Vasco, con quienes se colaborará para llevar a cabo esta investigación.

5. Como se interpretarán los datos a la luz de lo que se quiere estudiar y cómo se contrastará con la hipótesis de trabajo: Por tratarse de un experimento de aplicación de tecnologías de aprendizaje de máquinas al área de los algoritmos evolutivos, la hipótesis se confirmará si como resultado del estudio se encuentran patrones de relación entre la calidad estructural de los algoritmos de aprendizaje de estructuras y rendimiento de los EDAs.

6. Tratar de evaluar limitaciones y potenciales problemas de la metodología (tratando de proponer alternativas): La principal dificultad que se vislumbra es la complejidad de parametrización de los EDAs y el hecho de que el aprendizaje de estructuras de independencia es tan solo un paso intermedio de todo el proceso de optimización. Por esto, el experimento intentará aislar el análisis para develar cómo el aprendizaje de estructuras influencia sobre la calidad total de la optimización. Es importante notar que a pesar de que el análisis puede ser complejo, se trata de una aplicación muy desafiante para los algoritmos de aprendizaje de estructuras, ya que durante la ejecución de un EDA, se aprende una estructura de independencias en cada iteración.

## 12. Contribuciones del Proyecto

### Contribuciones al avance científico, tecnológico, transferencia al medio

El objetivo 1 del proyecto presenta un importante impacto en toda disciplina que utilice modelos probabilísticos para el proceso de modelado de las variables en su dominio de estudio. Este puede ser el caso de disciplinas relacionadas a las tomas de decisiones que requerirían estos modelos para utilizar en inferencia estadística, como también a disciplinas científicas que tan solo desean estudiar el modelo probabilístico generado. Cualquiera de estas variantes se beneficiaría enormemente en poder obtener un modelo más cercano al modelo subyacente.

La contribución del objetivo 2 es en la disciplina de optimización, con un impacto en el diseño específico de algoritmos EDAs, e indirectamente en todo desarrollo que requiera de optimización.

### Contribuciones a la formación de Recursos Humanos

El presente proyecto incorpora Dr. Federico Schlüter como investigador, habiéndose formado íntegramente dentro de nuestro laboratorio y bajo el marco de anteriores proyectos tanto PID-UTN como PICTs de la ANPCyT. Además incorpora como principal becario a la Ing. Yanela Strappa incorporada como becaria de grado y postgrado BINID hace ya más de 3 años, poseyendo actualmente una beca doctoral CONICET. Actualmente Yanela ya se encuentra inscrita en su doctorado en Informática de la Universidad Nacional de San Juan, aunque su afiliación es plena en nuestro laboratorio de la Fac. Regional Mendoza, compartiendo espacio de trabajo con todos sus miembros. La beca de Yanela tiene duración hasta Marzo del 2020, quedando prácticamente en un 75% bajo el amparo del presente proyecto.

### 13. Cronograma de Actividades

Año	Actividad	Inicio	Duración	Fin
1	Estudio del test estadístico Bayesiano para dilucidar suposiciones de independencia que se realizan	01/01/2017	1 meses	31/01/2017
1	Revisión bibliográfica del estado del arte en algoritmos de aprendizaje basados en puntaje	01/02/2017	3 meses	30/04/2017
1	Diseño de relaciones de dependencia entre aserciones de independencia a partir de axiomas de Pearl.	01/05/2017	1 meses	31/05/2017
1	Diseño de funciones de puntaje de estructuras para redes de Markov que relajen la suposición de independencias	01/06/2017	2 meses	31/07/2017
1	Implementación de la nueva función de puntaje en lenguaje Java.	01/08/2017	2 meses	30/09/2017
1	Análisis teórico de diversas funciones de puntaje a partir de sus características: consistencia y convexidad	01/10/2017	2 meses	30/11/2017
1	Experimentación. Comparación de resultados de la maximización en términos de calidad estructural.	01/12/2017	1 meses	31/12/2017
2	Experimentación. Comparación de resultados de la maximización en términos de calidad estructural.	01/01/2018	2 meses	28/02/2018
2	Escritura de manuscrito (reporte técnico para publicación)	01/03/2018	3 meses	31/05/2018
2	Estudio y selección de algoritmos de aprendizaje de estructuras de redes de Markov	01/06/2018	2 meses	31/07/2018
2	Desarrollo de librería de algoritmos de aprendizaje de redes de Markov para utilizar desde EDAs.	01/08/2018	3 meses	31/10/2018
2	Clasificación de algoritmos de aprendizaje de estructuras según su alcance y limitaciones respecto de EDAs	01/11/2018	2 meses	31/12/2018
3	Selección de problemas de optimización para EDAs con diversos patrones de interacciones entre las variables del problema	01/01/2019	1 meses	31/01/2019
3	Selección e implementación de diversos mecanismos EDA que utilizan redes de Markov	01/02/2019	2 meses	31/03/2019
3	Análisis y clasificación de problemas de optimización según su estructura de independencias.	01/04/2019	2 meses	31/05/2019
3	Estudio experimental de los efectos que genera la calidad de las estructuras aprendidas sobre los resultados	01/06/2019	4 meses	30/09/2019
3	Escritura de manuscrito (reporte técnico para publicación).	01/10/2019	3 meses	31/12/2019
3	Escritura del manuscrito (reporte técnico para publicación).	01/10/2019	3 meses	31/12/2019

### 14. Conexión del grupo de Trabajo con otros grupos de investigación en los últimos cinco años

Grupo Vinc.	Apellido	Nombre	Cargo	Institución	Ciudad	Objetivos	Descripción
ITIC	García	Carlos	DIRECTOR	Universidad Nacional de Cuyo	Mendoza	El proyecto financia una colaboración en otro proyecto de investigación aplicado en predicción localizada de heladas en redes de sensores montadas en	El es director del PICT 2013-2713 del cual yo soy investigador responsable. El proyecto financia una colaboración en otro proyecto de investigación aplicado en predicción localizada de heladas en redes de sensores montadas en viñedos de la provincia de



						viñedos de la provincia de Mendoza	Mendoza
sinc(i)	Milone	Diego	DIRECTOR	Universidad Nacional de Litoral	Santa Fe	Colaborar en la investigación post-doctoral del Dr. Federico Schlüter, miembro del presente proyecto.	La relación comienza desde que Federico le solicitara participar como su director en la presentación a beca post-doctoral CONICET de Federico, allá por el año 2014. En el año 2015 viajamos a Santa Fe a visitar al grupo 3 miembros del presente proyecto: Federico mismo, la Ing. Yanela Strappa y el Dr. Facundo Bromberg. Durante el viaje hicimos un intercambio de las investigaciones de cada grupo y desde ese momento Diego se ha incorporado plenamente en la investigación de Federico, con intercambios periódicos.
Intelligent Systems Group	Santana	Roberto	INVESTIGADOR FORMADO	Universidad del País Vazco	San Sebastián	Colaborar en la investigación post-doctoral del Dr. Federico Schlüter, miembro del presente proyecto. Específicamente en su segundo objetivo principal del estudio del uso de redes de Markov en EDAs	La relación comienza informalmente hace varios años, pero se formaliza con el pedido de Federico de que Roberto sea su co-director en la beca post-doctoral CONICET. Luego obtuvimos (Federico y Facundo) fondos de la SPU (Misiones VI) para lograr una visita durante el 2016. Federico por una estadía de 3 meses en el país Vasco, y Facundo una visita de pocos días.

### 15. Presupuesto

**Total Estimado del Proyecto: \$ 2480000,00**

#### 15.1. Recursos Humanos - Inciso 1 e Inciso 5

##### Primer Año

Becarios Inciso 5	Cantidad	Pesos	Origen del financiamiento
1. Becario Alumno Fac.Reg.	0	\$ 0,00	-
2. Becario Alumno UTN-SAE	0	\$ 0,00	-
3. Becario Alumno UTN-SCTyP	0	\$ 0,00	-
4. Becario BINID	0	\$ 0,00	-
5. Becario Posgrado-Doctoral en el país	6	\$ 331500,00	Organismos públicos nacionales (CONICET, Agencia, INTI, CONEA, etc.)
6. Becario Posgrado Doctoral en el extranjero	0	\$ 0,00	-
7. Becario Posgrado - Especialización	0	\$ 0,00	-
8. Becario Posgrado - Maestría en el país	0	\$ 0,00	-
9. Becario Posgrado - Maestría en el extranjero	0	\$ 0,00	-

Docentes Investigadores y Otros - Inciso 1	Cantidad	Pesos
1.Administrativo	0	\$ 0,00
2.CoDirector	0	\$ 0,00
3.Director	1	\$ 336000,00
4.Investigador de apoyo	0	\$ 0,00

5. Investigador Formado	2	\$ 306000,00
6. Investigador Tesista	0	\$ 0,00
7. Otras	0	\$ 0,00
8. Técnico de Apoyo	0	\$ 0,00

Totales	Inciso 5	Inciso 1	Total
Primer Año	\$ 331500,00	\$ 642000,00	\$ 973500,00

### Segundo Año

Becarios Inciso 5	Cantidad	Pesos	Origen del financiamiento	
1. Becario Alumno Fac.Reg.	0	\$ 0,00	-	-
2. Becario Alumno UTN-SAE	0	\$ 0,00	-	-
3. Becario Alumno UTN-SCTyP	0	\$ 0,00	-	-
4. Becario BINID	0	\$ 0,00	-	-
5. Becario Posgrado-Doctoral en el país	6	\$ 331500,00	Organismos públicos nacionales (CONICET, Agencia, INTI, CONEA, etc.)	UTN-SCTyP
6. Becario Posgrado Doctoral en el extranjero	0	\$ 0,00	-	-
7. Becario Posgrado - Especialización	0	\$ 0,00	-	-
8. Becario Posgrado - Maestría en el país	0	\$ 0,00	-	-
9. Becario Posgrado - Maestría en el extranjero	0	\$ 0,00	-	-

Docentes Investigadores y Otros - Inciso 1	Cantidad	Pesos
1. Administrativo	0	\$ 0,00
2. CoDirector	0	\$ 0,00
3. Director	1	\$ 336000,00
4. Investigador de apoyo	0	\$ 0,00
5. Investigador Formado	2	\$ 306000,00
6. Investigador Tesista	0	\$ 0,00
7. Otras	0	\$ 0,00
8. Técnico de Apoyo	0	\$ 0,00

Totales	Inciso 5	Inciso 1	Total
Segundo Año	\$ 331500,00	\$ 642000,00	\$ 973500,00

### Tercer Año

Becarios Inciso 5	Cantidad	Pesos	Origen del financiamiento	
1. Becario Alumno Fac.Reg.	0	\$ 0,00	-	-
2. Becario Alumno UTN-SAE	0	\$ 0,00	-	-
3. Becario Alumno UTN-SCTyP	0	\$ 0,00	-	-
4. Becario BINID	0	\$ 0,00	-	-
5. Becario Posgrado-Doctoral en el país	6	\$ 331500,00	Organismos públicos nacionales (CONICET, Agencia, INTI, CONEA, etc.)	UTN-SCTyP
6. Becario Posgrado Doctoral en el extranjero	0	\$ 0,00	-	-
7. Becario Posgrado - Especialización	0	\$ 0,00	-	-
8. Becario Posgrado - Maestría en el país	0	\$ 0,00	-	-
9. Becario Posgrado - Maestría en el extranjero	0	\$ 0,00	-	-

Docentes Investigadores y Otros - Inciso 1	Cantidad	Pesos
1. Administrativo	0	\$ 0,00
2. CoDirector	0	\$ 0,00
3. Director	1	\$ 336000,00
4. Investigador de apoyo	0	\$ 0,00
5. Investigador Formado	2	\$ 306000,00
6. Investigador Tesista	0	\$ 0,00

7.Otras	0	\$ 0,00
8.Técnico de Apoyo	0	\$ 0,00

Totales	Inciso 5	Inciso 1	Total
Tercer Año	\$ 331500,00	\$ 642000,00	\$ 973500,00

TOTAL GENERAL	Inciso 5	Inciso 1	Total General
Todo el Proyecto	\$ 994500,00	\$ 1926000,00	\$ 2920500,00

### 15.2 Bienes de consumo - Inciso 2

Año del Proyecto	Financiación Anual	Solicitado a
1	\$ 6.000,00	UTN - SCTyP
2	\$ 6.000,00	UTN - SCTyP
3	\$ 6.000,00	UTN - SCTyP
Total en Bienes de Consumo		\$ 18.000,00

### 15.3 Servicios no personales - Inciso 3

Año	Descripción	Monto	Solicitado a
1	Formación de miembros del proyecto	\$ 6.000,00	UTN - SCTyP
2	Formación de miembros del proyecto	\$ 6.000,00	UTN - SCTyP
3	Formación de miembros del proyecto	\$ 6.000,00	UTN - SCTyP
Total en Servicios no personales		\$ 18.000,00	

### 15.4 Equipos - Inciso 4.3 - Disponible y/o necesario

Año	Disp/Nec	Origen	Descripción	Modelo	Otras Espec.	Cantidad	Monto Unitario	Solicitado a
1	Necesario	Compra	Actualización de memorias y procesadores de equipos de computo	DDR4 y i7 5820k	-	1,00	\$ 16.000,00	UTN - SCTyP
2	Necesario	Compra	Equipos de computo	CPU para computo con procesador i7 5820k	-	1,00	\$ 16.000,00	UTN - SCTyP
3	Necesario	Compra	Equipos de computo	CPU para computo con procesador i7 5820k	-	1,00	\$ 16.000,00	UTN - SCTyP
Total en Equipos						\$ 48.000,00		

### 15.5 Bibliografía de colección - Inciso 4.5 - Disponible y/o necesario

Año	Disp/Nec	Origen	Descripción	Modelo	Otras Espec.	Cantidad	Monto Unitario	Solicitado a
Total en Bibliografía							\$ 0,00	

### 15.6 Software - Disponible y/o necesario

Año	Disp/Nec	Origen	Descripción	Modelo	Otras Espec.	Cantidad	Monto Unitario	Solicitado a
-	-	-	-	-	-	-	-	-
Total en Software							\$ 0,00	

### 16. Co-Financiamiento

Año	RR.HH.	Bienes de Consumo	Equipamiento	Servicios no personales	Bibliografía	Software	Total
1	\$973.500,00	\$6.000,00	\$16.000,00	\$6.000,00	\$0,00	\$0,00	\$1.001.500,00
2	\$973.500,00	\$6.000,00	\$16.000,00	\$6.000,00	\$0,00	\$0,00	\$1.001.500,00
3	\$973.500,00	\$6.000,00	\$16.000,00	\$6.000,00	\$0,00	\$0,00	\$1.001.500,00
Total del Proyecto	\$2.920.500,00	\$18.000,00	\$48.000,00	\$18.000,00	\$0,00	\$0,00	\$3.004.500,00

### Financiamiento de la Universidad

Universidad Tecnológica Nacional - SCyT

\$ 84.000,00

Facultad Regional	\$ 1.008.000,00
<b>Financiamiento de Terceros</b>	
Organismos públicos nacionales (CONICET, Agencia, INTI, CONEA, etc.)	\$ 1.912.500,00
Organismos / Empresas Internacionales / Extranjeros	\$ 0,00
Entidades privadas nacionales (Empresas, Fundaciones, etc.)	\$ 0,00
Otros	\$ 0,00
<b>Total</b>	<b>\$ 3.004.500,00</b>

#### Avales de aprobación, Financiamiento y Otros

	Orden	Nombre de archivo	Tamaño
<a href="#">Descargar</a>	1	AvalProyAprendizajedeRedesdeMarkov.pdf	82792
<a href="#">Descargar</a>	3	ResoluciónNº567-2016CD-avaIPIDsConv2016-17-v2.pdf	455055
<a href="#">Descargar</a>	4	NotaclaratoriapresupuestoProyUTI4481TCBrombergFacundo.pdf	411061

#### Currículums (Currículums de los integrantes cargados en el sistema)