



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: CCUTIME0005271TC

1. Unidad Científico-Tecnológica

FR Mendoza - LABORATORIO DHARMA

2. Denominación del PID

NUEVAS TECNICAS DE OPTIMIZACION PARA EL APRENDIZAJE DE REDES MARKOVIANAS

3. Resumen Técnico del PID

El presente proyecto tiene como objetivo general continuar contribuyendo en el área de aprendizaje de máquinas; en particular, con algoritmos de aprendizaje de modelos probabilísticos gráficos no dirigidos. Estos modelos computacionales están siendo ampliamente utilizados en gran cantidad de dominios. Nuestra propuesta es indagar en la naturaleza exponencial que deben abordar los algoritmos de aprendizaje, para encontrar mecanismos eficientes y teóricamente sólidos que mejoren la calidad del aprendizaje. A partir de la permanente necesidad de mejorar la calidad de los modelos aprendidos desde los datos, nuestra investigación en este área ya ha propuesto diferentes mecanismos para mejorar el aprendizaje de estructuras de modelos gráficos (Schluter et al., 2014a; Schluter et al., 2014b; Schluter et al., 2017). En los modelos gráficos, las estructuras cumplen un rol fundamental de codificación del conocimiento, ya que son su componente cualitativo, mediante el cual se especifica qué variables del dominio estudiado interactúan entre sí. En (Schluter et al., 2014a; Schluter et al., 2017) se proponen diferentes funciones de puntaje de estructuras de redes Markov, las cuales permiten computar aproximadamente la probabilidad a posteriori de una estructura arbitraria dados los datos disponibles $Pr(G|D)$. De este modo, cada posible estructura posee un puntaje más alto o más bajo según qué tan probables en los datos resultan las independencias que codifica. Con este enfoque, para aprender una estructura, simplemente debe utilizarse alguna técnica de optimización con alguna función de puntaje. En esta investigación se pretende generar conocimientos respecto de qué funciones de puntaje y qué algoritmos de optimización resultarían más conveniente, de acuerdo a las características del problema. En los trabajos anteriores, se ha focalizado el desarrollo en el diseño de funciones de puntaje para que tengan propiedades interesantes para resolver el problema, y puedan computarse eficientemente. Respecto a la optimización de las mismas, simplemente se han aplicado mecanismos triviales (i.e., búsquedas locales). Por esta razón, la línea de investigación que proponemos en el presente plan busca el desarrollo de algoritmos novedosos mediante el análisis del comportamiento de las diferentes funciones de puntaje respecto de diferentes condiciones de aprendizaje (disponibilidad de datos, características del problema, etc) y la aplicación de mecanismos de optimización novedosos. Hoy en día, el área de optimización computacional se encuentra en intenso desarrollo, y existe una gran disponibilidad de herramientas que pueden ser útiles de aplicar en el problema de aprendizaje de redes de Markov. Por ejemplo, recientemente se han desarrollado técnicas para análisis del paisaje de la función objetivo (Malan and Engelbrecht, 2013), las cuales permiten extraer información acerca del problema en estudio, teniendo en cuenta: el espacio de posibles soluciones; la función utilizada en la optimización; y un concepto de vecindario o distancia entre soluciones. Por esto, nuestra investigación se centrará en el estudio y análisis las funciones de paisaje, a fin de determinar la aplicabilidad de técnicas novedosas de optimización para el aprendizaje de estructuras.

4. Programa

Electrónica, Computación y Comunicaciones

5. Proyecto

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

Tipo de Actividad: Seleccione..

Campos de Aplicación:

Rubro	Descrip. Actividad	Otra (especificada)
-------	--------------------	---------------------

PROMOCION GENERAL DEL CONOCIMIENTO	Otros - Promocion General Del Conocim. (Especificar)	Vision computacional y analisis de imagenes
PROMOCION GENERAL DEL CONOCIMIENTO	Otras ciencias (Especificar)	Aplicaciones que requieran modelado probabilístico

Disciplinas Científicas:

Rubro	Disciplina Científica	Otras Disciplinas Científicas
MATEMÁTICA	Estadística	-
MATEMÁTICA	Métodos numéricos y computación	-
MATEMÁTICA	Probabilidad	-
CIENCIAS DE LA COMPUTACIÓN E INFORMÁTICA	Inteligencia Artificial	-
CIENCIAS DE LA COMPUTACIÓN E INFORMÁTICA	Estructuras de datos y Algoritmos	-
CIENCIAS DE LA COMPUTACIÓN E INFORMÁTICA	Computación Numérica y Simbólica	-

Palabras Clave

APRENDIZAJE DE MAQUINAS, REDES DE MARKOV, MODELOS PROBABILISTICOS GRÁFICOS, OPTIMIZACION

6. Fechas de realización

Inicio	Fin	Duración	Fecha de Homologación
01/01/2019	31/12/2020	24 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 :

CCUTIME0005271TC

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	INVESTIGADOR DE APOYO	10	01/01/2019	31/12/2020	-
SCHLUTER, FEDERICO	DIRECTOR	10	01/01/2019	31/12/2020	-
STRAPPA FIGUEROA, YANELA DAIANA	INVESTIGADOR TESISISTA	40	01/01/2019	31/12/2020	-

11. Datos de la investigación**Estado actual de concimiento del tema**

El presente plan de investigacion se enmarca en el aprendizaje de estructuras de redes de Markov. Las redes de Markov son modelos probabilísticos graficos empleados para representar distribuciones de probabilidad y realizar tareas de inferencia sobre dichas distribuciones de manera computacionalmente eficiente [10, 11, 17]. Estos modelos son utilizados en una gran variedad de áreas, tales como biología computacional [26], visión computacional y análisis de imágenes [13, 25], biomedicina [24], recuperacion de información [4], entre muchas otras.

Una red de Markov esta compuesta por una estructura de independencias (por ejemplo, un grafo no dirigido) y un conjunto de parámetros. La estructura especifica qué variables del dominio estudiado interactúan entre sí, mientras que los parámetros cuantifican dichas interacciones. El proceso de aprendizaje de una red de Markov se compone, por tanto, de dos etapas: el aprendizaje de su estructura y el aprendizaje de los parametros.

Actualmente, el aprendizaje de modelos desde datos esta tomando cada vez mayor relevancia, debido a la inviabilidad de construirlos manualmente en dominios cada vez mas complejos e inexplorados. Dada la naturaleza de los modelos probabilísticos, en la práctica, el objetivo del aprendizaje de los mismos puede variar, de acuerdo al problema donde se aplique. Por un lado, las redes de Markov permiten revelar

propiedades interesantes del dominio de estudio, ya que por su naturaleza gráfica es muy sencillo analizar la estructura aprendida desde los datos, a fin de extraer patrones desde los mismos. Este objetivo de aprendizaje se llama en la literatura "descubrimiento de conocimiento" (knowledge discovery, en inglés). Ejemplos del uso del aprendizaje guiados por este objetivo pueden verse en [5, 8, 16, 24]. Otro objetivo del aprendizaje de redes de Markov es utilizar el modelo aprendido para tareas de inferencia, lo que se conoce como "estimación de densidad" (density estimation) [6, 7, 14]. Las tareas de inferencia más utilizadas consisten en el cómputo de probabilidades marginales y el cómputo de la configuración más probable del dominio.

En el aprendizaje de estructuras de redes de Markov, hay dos principales enfoques: estrategias basadas en tests de independencia (algoritmos basados en independencias o basados en restricciones), y estrategias basadas en búsquedas en espacios de estructuras evaluadas con funciones de puntaje (algoritmos basados en puntaje). En el primer caso el aprendizaje se basa en la evaluación de tests estadísticos de independencias para determinar la presencia o ausencia de independencias entre variables del dominio de acuerdo a los datos. Así, los resultados de los tests funcionan como restricciones que permiten descartar las estructuras que no satisfacen las independencias evaluadas. De esta forma se aprende una estructura de manera eficiente y posteriormente puede realizarse aprendizaje de los parámetros para obtener el modelo completo [1, 3, 19, 22]. Además, estos algoritmos garantizan que la estructura aprendida es la correcta, bajo las suposiciones de que la distribución subyacente puede ser representada por un grafo y de que los tests son correctos. Sin embargo, debido a la dimensionalidad de los problemas en los que se aplica el aprendizaje en la práctica, es muy común obtener resultados erróneos en los tests por escasez de datos; y esto sumado a que se desconoce a ciencia cierta qué clase de distribuciones subyacen a los conjuntos de datos que son de interés en el mundo real, se pierden todas las garantías de correctitud que ofrecen estos algoritmos en teoría. En el segundo caso el aprendizaje se formula como un problema de optimización, aplicando un algoritmo de búsqueda en un espacio de posibles estructuras, donde la búsqueda es dirigida por una función de puntaje. Normalmente, dicha función de puntaje evalúa la verosimilitud de un modelo completo en los datos. Esto se conoce en la literatura como el cómputo del likelihood de la red de Markov. Dichas funciones de puntaje no solo evalúan una estructura, sino también sus parámetros numéricos, por lo que este tipo de algoritmos suele incurrir en una búsqueda doblemente exponencial. Por un lado, el espacio de todos los grafos no dirigidos posibles crece super exponencialmente. Y para computar el puntaje de cada grafo, es necesario aprender sus parámetros, una tarea que resulta NP-hard para redes de Markov [2]. Por ello, estos algoritmos suelen ser realmente eficaces para aprender distribuciones que son adecuadas para hacer inferencia. No obstante, su costo computacional compromete su aplicabilidad incluso para dominios de baja dimensionalidad.

Recientemente, ha ganado interés el uso de algoritmos que utilizan un enfoque híbrido [18, 20, 21]. Estos se basan en el diseño de algoritmos basados en puntaje cuya función objetivo es computada eficientemente a partir de los resultados de tests estadísticos. Llamaremos "algoritmos Bayesianos" a los métodos que siguen este esquema híbrido, debido a que la función objetivo suele utilizar un enfoque Bayesiano que consiste en computar la probabilidad a posteriori de las estructuras de independencia. Estos algoritmos Bayesianos capturan las ventajas de los algoritmos basados en puntaje, ya que también se pueden utilizar diversos métodos de búsqueda existentes, y también son más eficientes computacionalmente, ya que la función no requiere el aprendizaje de parámetros numéricos.

Un punto importante a mejorar respecto de los trabajos recientes que siguen el enfoque Bayesiano es específicamente en los mecanismos de optimización. En dichos trabajos, se ha focalizado el desarrollo en el diseño de las funciones de puntaje, para que tengan propiedades interesantes para resolver el problema, y puedan computarse eficientemente. Respecto a la optimización de las mismas, sólo se han aplicado mecanismos extremadamente simples, como búsquedas locales. Esto da pie a continuar esta investigación con horizontes promisorios, ya que hoy en día el área de optimización computacional se encuentra en intenso desarrollo, existiendo una gran disponibilidad de herramientas que pueden ser útiles de aplicar en el problema de aprendizaje de redes de Markov. Una herramienta que nos resulta de particular interés para investigar respecto del uso del enfoque Bayesiano para aprendizaje de redes de Markov es el "Análisis del paisaje de la función objetivo" (fitness landscape analysis) [15]. Esta técnica permite extraer información acerca del problema en estudio, teniendo en cuenta varios factores de interés: el espacio de posibles soluciones; la función utilizada en la optimización; y un concepto de vecindario o distancia entre soluciones. Por esto, a fin de determinar la aplicabilidad de técnicas novedosas de optimización para el aprendizaje de estructuras, nuestra investigación se centrará en el estudio y análisis las funciones de paisaje determinadas por las funciones de puntaje de redes de Markov existentes en la actualidad, en diferentes condiciones (disponibilidad de datos, complejidad del problema, etc).

Referencias

- [1] Aliferis, C., Statnikov, A., Tsamardinos, I., Mani, S., and Koutsoukos, X. (2010). Local Causal and Markov Blanket Induction for Causal Discovery and Feature Selection for Classification Part I: Algorithms and Empirical Evaluation. *JMLR*, 11:171–234.
- [2] Barahona, F. (1982). On the computational complexity of Ising spin glass models. *Journal of Physics A: Mathematical and General*, 15(10):3241–3253.
- [3] Bromberg, F., Margaritis, D., Honavar, V., et al. (2009). Efficient Markov network structure discovery using independence tests. *Journal of Artificial Intelligence Research*, 35(2):449.
- [4] Cai, K.-k., Bu, J.-j., Chen, C., and Qiu, G. (2007). A novel dependency language model for information retrieval. *Journal of Zhejiang University SCIENCE A*, 8(6):871–882.
- [5] Claeskens, G., Pircalabelu, E., and Waldorp, L. (2015). Constructing graphical models via the focused information criterion. In *Modeling and Stochastic Learning for Forecasting in High Dimensions*, pages 55–78. Springer.
- [6] Davis, J. and Domingos, P. (2010). Bottom-up learning of Markov network structure. In *Proceedings of the 27th International Conference on Machine Learning*, pages 271–280.
- [7] Haaren, J. V. and Davis, J. (2012). Markov network structure learning: A randomized feature generation approach. In *Proceedings of the Twenty-Sixth National Conference on Artificial Intelligence*. AAAI Press.
- [8] in Lee, S., Ganapathi, V., and Koller, D. (2006). Efficient structure learning of markov networks using l1regularization. In *In NIPS*.
- [9] Jones, T. and Forrest, S. (1995). Fitness Distance Correlation as a Measure of Problem Difficulty for Genetic Algorithms. *Icga*, 95:184–192.

- [10] Koller, D. and Friedman, N. (2009). *Probabilistic Graphical Models: Principles and Techniques*. MIT Press, Cambridge.
- [11] Lauritzen, S. (1996). *Graphical Models*. Oxford University Press.
- [12] Lehman, J. and Stanley, K. O. (2011). Abandoning objectives: Evolution through the search for novelty alone. *Evolutionary computation*, 19(2):189–223.
- [13] Li, S. Z. (2009). *Markov Random Field Modeling in Image Analysis*. Springer Publishing Company, Incorporated, 3rd edition.
- [14] Lowd, D. and Davis, J. (2014). Improving markov network structure learning using decision trees. *Journal of Machine Learning Research*, 15:501–532.
- [15] Malan, K. M. and Engelbrecht, A. P. (2013). A survey of techniques for characterising fitness landscapes and some possible ways forward. *Information Sciences*, 241:148–163.
- [16] Nyman, H., Pensar, J., Koski, T., and Corander, J. (2014). Context-specific independence in graphical log-linear models. *Computational Statistics*, pages 1–20.
- [17] Pearl, J. (1988). *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann Publishers, Inc.
- [18] Pensar, J., Nyman, H., Niiranen, J., and Corander, J. (In Press). Marginal pseudo-likelihood learning of Markov network structures. *Bayesian analysis*.
- [19] Schluter, F. (2012). A survey on independence-based Markov networks learning. " *Artificial Intelligence Review*, pages 1–25. 10.1007/s10462-012-9346-y.
- [20] Schluter, F., Bromberg, F., and Edera, A. (2014). The I MAP approach for Markov network structure learning. " *Annals of Mathematics and Artificial Intelligence*, pages 1–27.
- [21] Schlüter, F., Strappa, Y., Milone, D. H. , Bromberg, F. "Blankets Joint Posterior score for learning Markov network structures." *International Journal of Approximate Reasoning* 92 (2018): 295-320.
- [22] Spirtes, P., Glymour, C., and Scheines, R. (2000). *Causation, Prediction, and Search*. Adaptive Computation and Machine Learning Series. MIT Press.
- [23] Talbi, E.-G. (2009). *Metaheuristics: from design to implementation*, volume 74. John Wiley & Sons.
- [24] Van Haaren, J., Davis, J., Lappenschaar, M., and Hommersom, A. (2013). Exploring disease interactions using markov networks. *Proceedings of the AAAI-2013 (HIAI-2013)*. Bellevue, Washington, 15.
- [25] Wang, C., Komodakis, N., and Paragios, N. (2013). Markov random field modeling, inference & learning in computer vision & image understanding: A survey. *Comput. Vis. Image Underst.*, 117(11):1610–1627.
- [26] Wei, Z. and Li, H. (2007). A markov random field model for network-based analysis of genomic data. *Bioinformatics*, 23(12):1537–1544.
- [27] Wolpert, D. H. and Macready, W. G. (1995). No free lunch theorems for search. *Technical report*, Technical Report SFI-TR-95-02-010, Santa Fe Institute.
- [28] Wolpert, D. H. and Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE transactions on evolutionary computation*, 1(1):67–82.
- [29] Yuan, C., Malone, B., and Wu, X. (2011). Learning optimal bayesian networks using a* search. In *IJCAI proceedingsinternational joint conference on artificial intelligence*, volume 22, page 2186. Citeseer.

Grado de Avance

Como se desarrolló en el apartado anterior, el problema de investigación de interés en la presente investigación radica específicamente en encontrar nuevos mecanismos de aprendizaje de estructuras de redes de Markov, basados en el enfoque Bayesiano. Para esto, nos centraremos específicamente en el estudio y análisis de las posibles técnicas que pueden aplicarse para hacer un análisis del paisaje de fitness de funciones del estado del arte como así también un estudio de los métodos de optimización potencialmente aplicables. Con esto se pretende obtener algoritmos que aprendan estructuras de independencia de mejor calidad, a un costo computacional similar o mejor que el de los algoritmos Bayesianos actuales.

La optimización de modelos probabilísticos gráficos, al igual que la optimización en general, es con frecuencia compleja. Esto se debe a la diversidad de técnicas de optimización existentes, además de la diversidad en las características de los problemas a resolver. Entre los resultados más importantes a este respecto se encuentran los teoremas de nofreelunch [27, 28], que demuestran que ningún algoritmo de optimización es incondicionalmente superior a otro. Esta complejidad ha llevado al desarrollo de técnicas para extraer información acerca de los problemas, teniendo en cuenta: el espacio de posibles soluciones; las funciones utilizadas en la optimización (llamadas funciones objetivo o funciones de fitness en este ámbito); y un concepto de vecindario o distancia de una solución a otras. De acuerdo a una determinada codificación del problema, una función objetivo y una definición de vecindario/distancia, es posible determinar lo que se conoce como paisaje de la función (conocido comúnmente en la literatura como fitness landscape) [15]. El análisis de paisajes permite determinar características de los mismos, tales como cantidad y distribución de óptimos locales, grado de interdependencia entre variables, rugosidad, neutralidad, evolvability y deception. Este conocimiento luego puede utilizarse para tomar mejores decisiones respecto a que funciones y métodos de optimización son

más adecuados para resolver un problema en particular, como así también para descubrir limitaciones en los métodos existentes e identificar las posibilidades de mejora más prometedoras.

Debido a la complejidad de los dominios de aplicación y las características de las redes de Markov, el diseño de las funciones de puntaje para esta clase de modelos recurre a aproximaciones que introducen máximos locales en el espacio de búsqueda [10, Capítulo 20]. Por esta razón resulta relevante explorar variantes en la optimización de dichas funciones. Para ello, las técnicas de análisis de paisajes de landscape pueden resultar muy útiles para buscar y aprender características previamente desconocidas respecto del problema. Mediante este estudio, creemos que podemos detectar características de interés de las funciones de puntaje que se han diseñado hasta la actualidad, que pueden dar pie al diseño de nuevas funciones, con más bondades. En este respecto, hasta la actualidad hemos avanzado y logrado obtener algunos resultados preliminares que nos permiten inferir que mejorar la optimización es posible, y que dicha mejora tiene potencial para generar algoritmos que mejoren la calidad significativamente.

Nuestros resultados preliminares demuestran que los paisajes de las funciones de puntaje Bayesianas no están exentos del problema de contener óptimos locales. Esta característica hace que las búsquedas locales que buscan optimizar la función, pasando iterativamente de una solución candidata a otra de mayor puntaje, corran el riesgo de alejarse de la solución global a pesar de que el valor de la función aumenta en cada iteración. Por esta razón este tipo de paisajes se describen como engañosos (deceptive) [12, 15].

Objetivos de la investigación

El objetivo general de esta investigación consiste en mejorar la optimización del aprendizaje de estructuras de redes de Markov. Concretamente, en buscar mejoras a través del diseño y adaptación de estrategias de búsqueda para maximización de la probabilidad a posteriori de una estructura dado un conjunto de datos. Específicamente, esto puede llevarse a cabo mediante distintas estrategias de búsqueda, entre las cuales pueden destacarse:

- Búsquedas óptimas: estrategias de búsqueda que garantizan la obtención del máximo global, por ejemplo, el algoritmo A* . Han sido aplicadas exitosamente al aprendizaje de redes de Bayes [29].
- Metaheurísticas: son métodos de optimización aproximados, diseñados específicamente con el propósito de evitar máximos locales en las búsquedas [23]. No proveen garantías teóricas fuertes, pero frecuentemente logran obtener soluciones aceptables en tiempos razonables. La mayoría están inspiradas en fenómenos de la naturaleza, como por ejemplo los algoritmos evolutivos, el recocido simulado, la optimización por enjambre de partículas y la optimización mediante colonia de hormigas.
- Novelty search: un nuevo paradigma que propone atacar problemas engañosos mediante el reemplazo del criterio que guía la búsqueda [12]. En lugar de utilizar una función objetivo, los algoritmos basados en novedad utilizan una medida de la novedad de una solución, guiando la búsqueda hacia las zonas menos exploradas del espacio de hipótesis para una ejecución concreta del algoritmo de búsqueda. Como paso intermedio, para determinar criterios para el diseño de las estrategias previamente descritas, se propone continuar con el análisis de paisaje de funciones de puntaje del estado del arte que permitan evaluar dichos algoritmos y a la vez puedan sugerir potenciales mejoras.

Descripción de la metodología

La metodología a aplicar en el desarrollo de la investigación será iterativa, partiendo de revisiones bibliográficas y exploración teórica para luego formalizar, diseñar, implementar y probar algoritmos que presenten alguna de las mejoras desarrolladas.

Se realizarán experimentos en base a conjuntos de datos sintéticos y también de conjuntos extraídos de bases de datos reales. En el primer caso se construirán redes de Markov de distintas características (tales como dimensionalidad, topología, densidad o regularidad) manualmente y se generarán los conjuntos de datos en base a una o más técnicas de muestreo. En el segundo caso se utilizarán conjuntos de datos disponibles en repositorios públicos que han sido utilizados en la evaluación de algoritmos del estado del arte. También se realizarán experimentos sobre otros algoritmos del estado del arte con fines comparativos, evaluando distintas métricas relacionadas con la calidad y eficiencia de los mismos. Por último, se trabajará en la preparación de publicaciones de las contribuciones alcanzadas.

12. Contribuciones del Proyecto

Contribuciones al avance científico, tecnológico, transferencia al medio

El objetivo del proyecto proyecta contribuciones con 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.

Contribuciones a la formación de Recursos Humanos

El presente proyecto incorpora como 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 inscripta 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 bajo el amparo del presente proyecto.

13. Cronograma de Actividades

Año	Actividad	Inicio	Duración	Fin
1	Revisión bibliográfica del estado del arte de técnicas de análisis de paisaje de función (fitness landscape analysis)	01/01/2019	4 meses	30/04/2019
1	Análisis de adaptabilidad de técnicas de fitness landscape analysis al problema de	01/05/2019	4 meses	31/08/2019

	aprendizaje de Markov networks			
1	Estudio de características de distintas funciones de puntaje de redes de Markov	01/05/2019	4 meses	31/08/2019
1	Diseño de experimentos sintéticos con funciones de puntaje para redes de Markov	01/09/2019	2 meses	31/10/2019
1	Diseño de experimentos benchmark con funciones de puntaje para redes de Markov	01/11/2019	2 meses	31/12/2019
2	Implementación de experimentos con funciones de puntaje para redes de Markov	01/01/2020	4 meses	30/04/2020
2	Corrida de experimentos sistemáticos	01/05/2020	3 meses	31/07/2020
2	Escritura de manuscrito (reporte técnico para publicación)	01/06/2020	6 meses	30/11/2020
2	Análisis de resultados experimentales. Conclusiones. Planificación de trabajo futuro.	01/08/2020	2 meses	30/09/2020

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
sinc(i)	Milone	Diego	DIRECTOR	Universidad Nacional de Litoral Santa Fe	Santa Fe	Colaborar en la investigación post-doctoral del Dr. Federico Schlüter	Co-autoría en trabajo publicado recientemente: Schlüter, F., Strappa, Y., Milone, D. H., Bromberg, F. "Blankets Joint Posterior score for learning Markov network structures." International Journal of Approximate Reasoning 92 (2018): 295-320.
Intelligent Systems Group (ISG)	Santana Hermida	Roberto	INVESTIGADOR FORMADO	Universidad del País Vasco	San Sebastián, España	Colaborar en la investigación post-doctoral del Dr. Federico Schlüter (co-director)	Durante 2016 se realizó una visita al ISG a través de la beca para estancias en el exterior de becarios postdoctorales, realizando una estadía de 3 meses en el país Vasco, de la cual Roberto Santana fue director durante la estadía.
Intelligent Systems Group (ISG)	Lozano	José Antonio	INVESTIGADOR FORMADO	UNIVERSIDAD DEL PAIS VASCO	SAN SEBASTIAN, ESPAÑA	Realizar jornadas de intercambio académico entre laboratorios de investigaciones afines	Se realizaron jornadas de visita por universidades de Europa para generar intercambios académicos, a través de fondos de la SPU.
Computational Intelligence Group	Larrañaga	Pedro	INVESTIGADOR FORMADO	Universidad Politecnica de Madrid	Madrid, España	Realizar jornadas de intercambio académico entre laboratorios de investigaciones afines	Se realizaron jornadas de visita por universidades de Europa para generar intercambios académicos, a través de fondos de la SPU.
MLDL and Artificial Intelligence Lab (DTAI).	Davis	Jesse	INVESTIGADOR FORMADO	Dept. of Computer Science-Katholieke Universiteit	Leuven, Belgica	Realizar jornadas de intercambio académico entre laboratorios de investigaciones afines	Se realizaron jornadas de visita por universidades de Europa para generar intercambios académicos, a través de fondos de la SPU.

15. Presupuesto

Total Estimado del Proyecto: \$ 0,00

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	1	\$ 228324,00	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	\$ 77928,00
4.Investigador de apoyo	1	\$ 136032,00
5.Investigador Formado	0	\$ 0,00
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	\$ 228324,00	\$ 213960,00	\$ 442284,00

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	1	\$ 228324,00	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	\$ 77928,00
4.Investigador de apoyo	1	\$ 136032,00
5.Investigador Formado	0	\$ 0,00
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	\$ 228324,00	\$ 213960,00	\$ 442284,00

TOTAL GENERAL	Inciso 5	Inciso 1	Total General
Todo el Proyecto	\$ 456648,00	\$ 427920,00	\$ 884568,00

15.2 Bienes de consumo - Inciso 2

Año del Proyecto	Financiación Anual	Solicitado a
1	\$ 9.900,00	UTN - SCTyP
2	\$ 9.900,00	UTN - SCTyP
Total en Bienes de Consumo		\$ 19.800,00

15.3 Servicios no personales - Inciso 3

Año	Descripción	Monto	Solicitado a
1	Viáticos	\$ 6.600,00	UTN - SCTyP
2	Inscripciones a congresos	\$ 6.600,00	UTN - SCTyP
Total en Servicios no personales			\$ 13.200,00

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	1,00	\$ 18.000,00	UTN - SCTyP
2	Necesario	Compra	Equipos de computo	CPU para computo con procesador i7 5820k	-	1,00	\$ 18.000,00	UTN - SCTyP
Total en Equipos							\$ 36.000,00	

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

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

15.6 Software - Disponible y/o necesario

Año	Disp/Nec	Origen	Descripción	Modelo	Otras Espc.	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	\$442.284,00	\$9.900,00	\$18.000,00	\$6.600,00	\$0,00	\$0,00	\$476.784,00
2	\$442.284,00	\$9.900,00	\$18.000,00	\$6.600,00	\$0,00	\$0,00	\$476.784,00
Total del Proyecto	\$884.568,00	\$19.800,00	\$36.000,00	\$13.200,00	\$0,00	\$0,00	\$953.568,00

Financiamiento de la Universidad

Universidad Tecnológica Nacional - SCyT	\$ 69.000,00
Facultad Regional	\$ 0,00

Financiamiento de Terceros

Organismos públicos nacionales (CONICET, Agencia, INTI, CONEA, etc.)	\$ 884.568,00
Organismos / Empresas Internacionales / Extranjeros	\$ 0,00
Entidades privadas nacionales (Empresas, Fundaciones, etc.)	\$ 0,00
Otros	\$ 0,00
Total	\$ 953.568,00

Avales de aprobación, Financiamiento y Otros

	Orden	Nombre de archivo	Tamaño
Descargar	1	IMG_20180622_112153961_HDR.jpg	1533182

Currículums (Currículums de los integrantes cargados en el sistema)