

Autoescalado basado en Aprendizaje Profundo por Refuerzo de Workflows Científicos en la Nube

Elina Pacini^{1,2}, Carlos Catania¹, Yisel Garí¹ and Luciano Robino¹

¹ Facultad de Ingeniería, UNCuyo

² CONICET

elina.pacini@ingenieria.uncuyo.edu.ar, harpo@ingenieria.uncuyo.edu.ar, yisलगari@gmail.com,
luciano.ivan.robino@gmail.com

RESUMEN

Los workflows científicos representan una importante abstracción para el modelado y la ejecución de experimentos de gran envergadura en múltiples disciplinas. El paradigma de computación Cloud facilita el acceso elástico a la infraestructura computacional requerida para la ejecución de este tipo de aplicaciones. Las estrategias de autoescalado buscan explotar la elasticidad de Cloud para lograr ejecuciones eficientes de los workflow. El autoescalado es un problema de toma de decisiones en el cual es necesario establecer cuándo y cómo incrementar o reducir los recursos computacionales, y cómo ajustarlos a la carga de trabajo actual considerando algún criterio de optimización como pueden ser el tiempo y el costo económico asociado. El aprendizaje por Refuerzo (AR) aparece como un enfoque promisorio para el autoescalado en Cloud ya que permite aprender políticas adecuadas para el manejo de recursos que a su vez son transparentes (sin intervención humana), dinámicas (sin planes computados estáticamente) y adaptables (constantemente actualizadas). Luego, el Aprendizaje Profundo por Refuerzo (APR) permite además el manejo de espacios de estados y acciones de grandes dimensiones, una importante limitante en los enfoques más clásicos del AR.

CONTEXTO

El presente proyecto se desarrolla en el marco de la Facultad de Ingeniería dentro Laboratorio de sistemas inteligentes (LABSIN). El presente trabajo forma parte del proyecto de investigación B038-T1 que dio inicio en el mes de mayo de 2022 en el marco de los proyectos bienales de secretaria de Investigación, Internacionales y Posgrados (SIIP) de la Universidad Nacional de Cuyo.

1 INTRODUCCIÓN

Los workflows científicos [1] se han establecido como una importante abstracción para el procesamiento de datos y la ejecución de grandes y complejos experimentos científicos. A partir del modelado de los pasos de procesamiento y sus dependencias, los workflows permiten contar con una panorámica más clara para el análisis de las aplicaciones. Los workflows científicos usualmente se componen por cientos o miles de tareas de diferentes duraciones que pueden ir desde horas o días hasta semanas. Además, dichas tareas presentan diferentes requerimientos de recursos computacionales (CPU, RAM, ancho de banda). Por otro lado, las estructuras de dependencias entre las tareas de un workflow determinan una carga de trabajo variable durante la ejecución, con momentos donde muchas tareas pueden ser ejecutadas en

paralelo y momentos con largas ejecuciones secuenciales de tareas. Tal variabilidad determina momentos donde se requiere una infraestructura con mayor o menor capacidad computacional.

En este contexto, el modelo de computación Cloud, aparece como una alternativa ideal para la ejecución de workflows científicos, ya que facilita el acceso elástico a la infraestructura computacional requerida por este tipo de aplicaciones [2]. Particularmente, el modelo de servicios IaaS en Cloud permite a los usuarios crear y destruir instancias de Máquinas Virtuales (MV) de diferentes prestaciones bajo un esquema de pago por uso.

Luego, debido a la elasticidad provista por los modelos de computación Cloud, es posible ajustar dinámicamente la infraestructura ante las variaciones en la demanda que se presentan durante la ejecución de los workflows. Esta flexibilidad junto a la necesidad de lograr ejecuciones eficientes de los workflows, alienta el estudio y el desarrollo de estrategias para el autoescalado de workflows y otros tipos de aplicaciones científicas en Cloud [3,4].

Específicamente, las estrategias de autoescalado [5,6,7] resuelven periódicamente dos problemas de optimización interrelacionados, el escalado y la planificación. El escalado consiste en ajustar la capacidad computacional de infraestructura virtualizada en función de la demanda de la aplicación. La planificación consiste en asignar la ejecución de cada tarea a alguna de las instancias de MVs disponibles. Ambos subproblemas (escalado y planificación) son NP-duros por lo que suelen ser abordados con heurísticas o metaheurísticas.

Es importante considerar que existen varios elementos de incertidumbre en la ejecución de las aplicaciones que son inherentes al modelo de computación Cloud. Entre ellos se encuentran, la variabilidad en el

rendimiento de la infraestructura virtualizada, las fluctuaciones en los precios de algunos tipos de instancias y sus posibles fallos. Todo esto hace que sea más complejo poder determinar de antemano las mejores decisiones para lograr una ejecución eficiente.

El Aprendizaje por Refuerzo (AR) [19] constituye uno de los paradigmas del aprendizaje automático, como lo son también el aprendizaje supervisado y no supervisado. En el caso del AR se trata de un enfoque computacional que permite a un agente aprender, mediante la interacción con el entorno, un comportamiento adecuado para el logro de un determinado objetivo. Cuando es posible modelar la dinámica del entorno, el agente puede aprender en modo offline utilizando técnicas específicas para ello. Otra variante consiste en que el agente interactúe directamente con el entorno real aprendiendo en modo online. Esta última variante suele ser más utilizada ya que en muchos problemas no es posible contar con un modelo preciso de la dinámica del entorno o la misma puede cambiar en el tiempo.

Las estrategias basadas en AR están siendo ampliamente utilizadas y con muy buenos resultados en áreas como la teoría de juegos, lo que ha motivado su estudio y aplicación en otras áreas como es el caso del autoescalado en Cloud.

Varias investigaciones recientes proponen soluciones basadas en AR para resolver alguno de los subproblemas involucrados, el escalado [4,9,10] o la planificación [11,12]. El AR ofrece un marco de trabajo de propósito general para la toma de decisiones que ha demostrado un gran potencial en entornos estocásticos complejos. El AR propone un modo de aprendizaje basado en la interacción con el entorno y dirigido por objetivos. La idea consiste en que un agente puede observar el estado del entorno y tomar acciones que

influyen en las observaciones futuras. La retroalimentación de las acciones elegidas llega al agente como señales escalares denominadas recompensas, y el objetivo principal del agente es maximizar la recompensa total a largo plazo. El agente observa el entorno, actúa sobre él y evalúa el impacto de sus acciones. De esta manera puede aprender un comportamiento casi óptimo por prueba y error. Los elementos mencionados - estados, acciones y recompensas - son los componentes clave en la formulación de cualquier problema de AR, y el marco utilizado para definirlos se denomina Proceso de Decisión de Markov (PDM).

Este problema (conocido en inglés como *the curse of dimensionality*) es una importante limitante en los enfoques más clásicos del AR, en algunos casos afectando el tiempo de aprendizaje y en los casos más críticos volviéndose imposible de manejar. De esta manera, ante entornos complejos, el Aprendizaje Profundo por Refuerzo (APR) [13] ofrece un marco de trabajo más potente que el ofrecido por las estrategias clásicas del AR, ya que combina la potencialidad de dos ramas importantes del aprendizaje automático, esto es las Redes Neuronales Profundas (RNP) y el AR, para la resolución automática de problemas de toma de decisiones en entornos estocásticos altamente complejos.

Es importante destacar que la directora del proyecto cuenta con aproximadamente 10 años de experiencia en la implementación de técnicas metaheurísticas para la optimización de aplicaciones científicas en entornos Cloud. [1,14,15]. Además, en cuanto a la implementación de técnicas metaheurísticas para autoescalado en Cloud se pueden mencionar los siguientes trabajos [5,6,7]. Finalmente, cabe mencionar que el problema de autoescalado en Cloud basado en AR se ha avanzado hasta el momento en un exhaustivo estudio del estado del arte [16] y se ha trabajado en la implementación

de un autoescaler [4,17,18] que se tomará como base para extender el trabajo propuesto en el presente proyecto.

2 LÍNEAS DE INVESTIGACIÓN Y DESARROLLO

El AR ha demostrado un gran potencial para la resolución automática de problemas de toma de decisiones en entornos complejos y con incertidumbre, particularmente debido a su capacidad para considerar las consecuencias a largo plazo de las acciones disponibles. A partir del análisis del estado del arte [16] y de las limitaciones de los estudios previos realizados, se hace evidente que existe actualmente una larga lista de problemas abiertos, lo que a su vez significa que existe un amplio espectro de oportunidades de investigación con respecto a las técnicas de AR en el área de autoescalado en Cloud.

A continuación, se analizan 5 líneas de interés que guiarán luego a los objetivos y a las actividades específicas del presente plan de trabajo y que surgen de las limitaciones fundamentales encontradas en los trabajos del área [16].

a) Escalado y Planificación con APR. Es importante diseñar y desarrollar estrategias de autoescalado de workflows en Cloud que combinen un escalador y un planificador, ambos basados en APR, debido al impacto conjunto que tienen tanto las decisiones de escalado como las de planificación en la eficiencia de las ejecuciones de los workflows. Una solución integral permitiría expandir las ventajas (esto es, transparencia, dinamismo y adaptabilidad) de este enfoque de aprendizaje a todo el proceso de autoescalado. La política de escalado determinará cómo ajustar la infraestructura de forma dinámica según la demanda variable de la aplicación, mientras que la política de planificación determinará el recurso más adecuado para la ejecución de cada tarea, considerando información de las tareas y de la infraestructura disponible. Ambas

políticas serían aprendidas observando los efectos conjuntos de las acciones de escalado y planificación en la ejecución del workflow en una infraestructura Cloud.

b) *Elementos de los Entornos Cloud*. Es muy importante ampliar los estudios actuales para representar más elementos de los entornos Cloud reales (por ejemplo, más tipos de MVs y modelos de precios). Este tipo de extensión podría generar problemas de escalabilidad relacionados con la dimensión del espacio de estados y/o de acciones. En este sentido, se propone utilizar técnicas del APR que combinan las potencialidades del AR y de las RNP para resolver este tipo de problemáticas. En el área del autoescalado en Cloud, la mayoría de los enfoques aún utilizan las variantes más simples de los métodos de AR. Por lo tanto, todavía hay espacio para investigar más a fondo la sinergia de diferentes variantes de las estrategias básicas de AR y otros métodos de aprendizaje automático.

c) *Rendimiento Inicial y Convergencia*. Consiste en evaluar y proponer soluciones que garanticen un rendimiento inicial adecuado de las estrategias de autoescalado, así como implementar mecanismos para la aceleración de la velocidad de convergencia en el aprendizaje de las políticas. Ambos factores son de especial interés en el contexto de la ejecución de workflows en Cloud, ya que la reducción del tiempo de ejecución y del costo económico son objetivos primordiales que se ven afectados directamente cada vez que la estrategia de autoescalado no es capaz de tomar decisiones adecuadas de escalado y/o de planificación.

d) *Representación de Estados y Acciones*. La representación de los estados y las acciones es un elemento determinante en el aprendizaje y el desempeño de las estrategias. En AR, como en otras áreas del Aprendizaje Automático, estas opciones de representación, puede decirse que son más arte que ciencia. En el área del autoescalado en Cloud, es fundamental estudiar las implicaciones específicas de tales elecciones de representación (estados y acciones) y cómo impactan en el rendimiento

de las estrategias de autoescalado. Por ejemplo, preguntas interesantes para responder en este contexto son: (1) ¿Qué información de un entorno real Cloud es relevante para aprender adecuadamente una política? (2) ¿Cuál podría ser una representación adecuada de esta información para acelerar el proceso de aprendizaje?

3 RESULTADOS ESPERADOS

Al término de los dos años de duración del plan de trabajo se pretende que se haya logrado:

1) Contar con un análisis del estado del arte actualizado en el marco del tema desarrollado. Este análisis proveerá una además una guía para las futuras líneas de investigación fortaleciendo así el área.

2) Disponer de con una extensión del autoescalador que incorpore técnicas más promisorias basadas en APR para la resolución del problema estudiado.

4 FORMACIÓN DE RECURSOS HUMANOS

Se espera además impactar fuertemente en la formación de recursos humanos mediante la codirección de doctorado del Lic. Luciano Robino (integrante de este proyecto) y de la beca postdoc de Yisel Garí (Doctora en Ciencias de la Computación).

5 AGRADECIMIENTOS

Agradecemos el soporte financiero obtenido a través de los proyectos SIIP-UNCuyo B038-T1 y 06/B040-T1.

6 BIBLIOGRAFIA

- [1] E. Deelman, T. Peterka, I. Altintas et al.: The future of scientific workflows. The International Journal of High-Performance Computing Applications. 2018;32(1):159-175.
- [2] M.A.S. Netto, R.N. Calheiros, E.R. Rodrigues, R.L. F. Cunha, and R. Buyya: Hpc cloud for scientific and business applications:

- Taxonomy, vision, and research challenges. *ACM Computing Surveys*, 51(1):1–29, 2018.
- [3] D.A. Monge, Y. Garí, C. Mateos, and C. García Garino. Autoscaling scientific workflows on the cloud by combining on-demand and spot instances. *International Journal of Computer Systems Science and Engineering*, 32(4 Special Issue on Elastic Data Management in Cloud Systems), Jul 2017.
- [4] Y. Garí, D.A. Monge, C. Mateos, and C. García Garino. Learning budget assignment policies for autoscaling scientific workflows in the cloud. *Cluster Computing*, 23:87–105, 2020.
- [5] D.A. Monge, E. Pacini, C. Mateos, E. Alba and C. García Garino: CMI: An online multi-objective genetic autoscaler for scientific and engineering workflows in cloud infrastructures with unreliable virtual machines. *Journal of Network and Computer Applications* 149, (2020).
- [6] D.A. Monge, E. Pacini, C. Mateos and C. García Garino, C.: Meta-heuristic based autoscaling of cloud-based parameter sweep experiments with unreliable virtual machines instances. *Computers & Electrical Engineering* 69, 364–377 (2018).
- [7] V. Yannibelli, E. Pacini, D. Monge, C. Mateos and G. Rodriguez: A Comparative Analysis of NSGA-II and NSGA-III for Autoscaling Parameter Sweep Experiments in the Cloud. *Scientific Programming* 2020, Article ID 653204, 1-17 (2020).
- [8] R.S. Sutton and A.G. Barto. *Reinforcement Learning: An Introduction*. A Bradford Book, USA, 2018.
- [9] X. Dutreilh and S. Kirgizov. Using reinforcement learning for autonomic resource allocation in clouds: towards a fully automated workflow. In *7th International Conference on Autonomic and Autonomous Systems*, pages 67–74, 2011.
- [10] E. Barrett, E. Howley, and J. Duggan. Applying reinforcement learning towards automating resource allocation and application scalability in the cloud. *Concurrency Computation Practice and Experience*, 2012.
- [11] E. Barrett, E. Howley and J. Duggan. A learning architecture for scheduling workflow applications in the cloud. *Proceedings – 9th IEEE European Conference on Web Services, ECOWS 2011*, pages 83–90, 2011.
- [12] Z. Peng, D. Cui, J. Zuo, Q. Li, B. Xu, and W. Lin. Random task scheduling scheme based on reinforcement learning in cloud computing. *Cluster Computing*, 18(4):1595–1607, 2015.
- [13] F. Palau, C. Catania, J. Guerra, S. Garcia and M. Rigaki. Detecting DNS Threats: A Deep Learning Model to Rule Them All. *ASAI, Simposio Argentino de Inteligencia Artificial*, pages 90-101, 2019.
- [14] E. Pacini, C. Mateos, and Carlos García Garino. A three-level scheduler to execute scientific experiments on federated clouds. *IEEE Latin America Transactions*, 13(10):3359–3369, 2015.
- [15] E. Pacini, C. Mateos, C. García Garino, C. Careglio, and A. Mirasso. A bioinspired scheduler for minimizing makespan and flowtime of computational mechanics applications on federated clouds. *Journal of Intelligent & Fuzzy Systems*, 31(3):1731–1743, 2016. IOS Press.
- [16] Y. Garí, D.A. Monge, E. Pacini, C. Mateos, C. García Garino: “Reinforcement Learning based Autoscaling of Workflows in the Cloud: A Survey”. *Engineering Applications of Artificial Intelligence*, Vol. 102, 2021.
- [17] Y. Garí, D.A. Monge, C. Mateos, C. García Garino. Markov Decision Process to Dynamically Adapt Spots Instances Ratio on the Autoscaling of Scientific Workflows in the Cloud. *Latin American High-Performance Computing Conference*, pages 353-369, 2019.
- [18] Y. Garí, D.A. Monge, C. Mateos. A Q-learning approach for the autoscaling of scientific workflows in the Cloud. *Future Generation Computer Systems* 127: 168-180, 2021.