

## MULTI-AGENTES CON APRENDIZAJE AUTOMÁTICO EN EL PROCESO DE MORFOSINTAXIS

Multi-Agents With Machine Learning in the Morphosyntaxis Process

**Rios Miranda, Bhylenia Yhasmyna**

Universidad Mayor de San Andrés - CEPIES-Docente Investigador

bhylenia.rios@gmail.com

La Paz, Bolivia

### Resumen

El artículo aborda el desarrollo de un modelo de sistema multi-agente con aprendizaje automático para optimizar el proceso de enseñanza de la morfosintaxis en los estudiantes de Seminario de Grado I en la Carrera de Economía de la Universidad Mayor de San Andrés. Mediante la integración de técnicas de inteligencia artificial y un enfoque colaborativo entre agentes, se busca mejorar significativamente la comprensión y aplicación de las reglas morfosintácticas. El modelo no solo facilita la personalización del aprendizaje, sino que también promueve la eficiencia en la enseñanza de la gramática, contribuyendo al rendimiento académico de los estudiantes. Los agentes inteligentes, como el agente tutor y el agente evaluador, permiten una adaptación individualizada a las necesidades de los estudiantes, ofreciendo una retroalimentación constante y oportuna. El Deep Learning en la misma arquitectura del sistema multi-agente refuerza el proceso de aprendizaje, lo que permite una interacción más efectiva entre los agentes y los estudiantes. El artículo concluye que el modelo propuesto, basado en la metodología MASE y ofrece resultados significativos que pueden ser adaptados a otros contextos educativos. La evaluación del modelo mediante encuestas indica una mejora notable en el proceso de enseñanza-aprendizaje de la morfosintaxis, con una calificación favorable por parte de los estudiantes. Esta investigación destaca el potencial de los sistemas multi-agente con aprendizaje automático como herramientas clave en la educación superior, particularmente en áreas donde la gramática y la estructura del lenguaje son fundamentales.

**Palabras Claves:** morfosintaxis, aprendizaje, automático.

## abstract

The article addresses the development of a multi-agent system model with machine learning to optimize the teaching process of morphosyntax in Grade I Seminar students in the Economics Program at the Universidad Mayor de San Andrés. By integrating artificial intelligence techniques and a collaborative approach between agents, the aim is to significantly improve the understanding and application of morphosyntactic rules. The model not only facilitates the personalization of learning, but also promotes efficiency in teaching grammar, contributing to students' academic performance. Intelligent agents, such as the tutor agent and the evaluator agent, allow individualized adaptation to the needs of students, offering constant and timely feedback. Deep Learning in the same architecture of the multi-agent system reinforces the learning process, allowing a more effective interaction between agents and students. The article concludes that the proposed model, based on the MASE methodology and offers significant results that can be adapted to other educational contexts. The evaluation of the model through surveys indicates a notable improvement in the teaching-learning process of morphosyntax, with a favorable rating from the students. This research highlights the potential of multi-agent systems with machine learning as key tools in higher education, particularly in areas where grammar and language structure are fundamental.

**Keywords:** morphosyntax, learning, automatic.

## Introducción.

Los estudiantes de la Carrera de Economía de la Universidad Mayor de San Andrés al igual que las otras carreras de la Universidad deben presentar documentos académicos en muchas materias pero un documento muy importante a presentar es el Perfil de Tesis que lo realizan en la asignatura de Seminario de Grado I, donde se puede ver morfosintaxis que aplican en el desarrollo de su Perfil de Tesis que aborda la morfología y la sintaxis. Comprender la morfosintaxis es fundamental para dominar esta parte de la gramática que permite a los hablantes y escritores construir frases coherentes y significativas, de acuerdo con las reglas del idioma (Varela, 2019, p. 15).

Los estudiantes de Seminario de Grado I enfrentan diversos problemas, que se detallan a continuación con estimaciones de incidencia basada en observaciones y datos disponibles:

- **Organización del Tiempo:** El 60% de los estudiantes tienen dificultades para gestionar eficazmente sus actividades, clases y ayudantías, lo que afecta su rendimiento académico a lo largo del semestre (García, 2021, p. 50). La habilidad para organizar el tiempo es esencial para mantener un rendimiento académico óptimo (Britton y Tesser, 1991, p. 56).



- **Presión Autoimpuesta:** El 55% de los estudiantes sienten una presión autoimpuesta significativa para dedicar horas adicionales de estudio, lo cual puede llevar a agotamiento y estrés (Salmela-Aro et al., 2009, p. 34). La presión académica excesiva puede afectar negativamente la salud mental de los estudiantes (Misra y McKean, 2000, p. 89).
- **Enseñanza Uniforme:** El 65% de los estudiantes experimenta una enseñanza que no considera las diferencias en sus estilos de aprendizaje, lo que puede limitar su comprensión y rendimiento (Tomlinson, 2014, p. 15). La enseñanza diferenciada es crucial para abordar las diversas necesidades y estilos de aprendizaje de los estudiantes (Tomlinson, 2014, p. 19).
- **Uso Incorrecto de Reglas:** El 50% de los estudiantes muestra un uso inadecuado de las reglas morfosintácticas en la escritura y la comunicación oral, lo que afecta la calidad de su expresión escrita y hablada (Chomsky, 1965, p. 43). La competencia en morfosintaxis es esencial para una comunicación efectiva y precisa (Celce-Murcia et al., 1999, p. 45).

La enseñanza del proceso de morfosintaxis, representa un desafío significativo en la educación superior, especialmente en la Carrera de Economía, donde los estudiantes no siempre cuentan con una formación lingüística sólida. La morfosintaxis, que comprende el estudio de la estructura interna de las palabras y la forma en que estas se combinan para formar oraciones,

es fundamental para el desarrollo de competencias comunicativas avanzadas.

Ante este desafío, la inteligencia artificial (IA) y, en particular, los modelos de multi-agentes con aprendizaje automático, emergen como una solución innovadora para transformar el proceso educativo. Los agentes inteligentes son sistemas autónomos que pueden interactuar con el entorno, aprender de estas interacciones y tomar decisiones para cumplir objetivos específicos. En el contexto de la enseñanza de la morfosintaxis, estos agentes pueden diagnosticar los estilos de aprendizaje de los estudiantes, analizar las características morfosintácticas clave y personalizar los recursos educativos, ofreciendo una experiencia de aprendizaje adaptativa y efectiva.

Este artículo explora la aplicación de un Modelo Multi-Agentes con Aprendizaje Automático en el proceso de morfosintaxis, desarrollado para mejorar la enseñanza de la gramática en la Carrera de Economía en la Universidad Mayor de San Andrés. A través de un enfoque basado en agentes inteligentes, se busca no solo optimizar la comprensión y el uso de la morfosintaxis entre los estudiantes, sino también proporcionar un marco flexible y escalable que pueda ser adaptado a otras disciplinas y niveles educativos.

### **Morfosintaxis.**

La morfosintaxis es una rama de la gramática, que une la morfología y la sintaxis, aunque ambas puede trabajar de manera individual pero al trabajar juntas no pueden desligarse una de la otra ya que conforman un todo en el lenguaje, dando sentido a una oración, los elementos que la compone y reglas del lenguaje.

Vicente Nuñez (2020) indica: "El estudio morfosintáctico se encarga de analizar palabra por palabra y el modo en que se combinan para formar una oración para luego establecer una tipología y categorización" (p. 65).

**Aprendizaje Automático (Machine Learning).**

El aprendizaje automático conocido como los algoritmos de Machine Learning (ML) busca que las computadoras aprendan de forma autónoma sin la necesidad de ser programados explícitamente, como ejemplo de esto tenemos: autos de conducción autónoma, sistemas de recomendación, agentes virtuales de atención al cliente y otros. La división de los algoritmos de aprendizaje automático es:

- Aprendizaje Supervisado (Supervised machine learning).
- Aprendizaje no Supervisado (Unsupervised machine learning).
- Aprendizaje por Refuerzo (Reinforcement Learning - RL)
- Aprendizaje Profundo (Deep Learning).

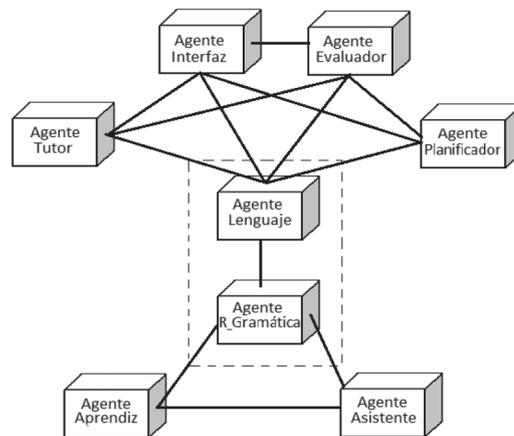
De los aprendizajes mencionados ninguno es mejor que el otro, cada aprendizaje tiene sus ventajas y desventajas dependiendo del problema que se intenta resolver.

**Aprendizaje Profundo (Deep Learning).**

El aprendizaje profundo es parte de la IA que se encarga de emular el aprendizaje de los seres humanos, automatizando el análisis predictivo. "El número de capas de procesamiento a través de las cuales los datos deben pasar es lo que inspiró la etiqueta de profundidad ('deep'). La ventaja del aprendizaje profundo es que el programa construye el conjunto de características por sí mismo sin supervisión. Esto no es sólo más rápido, sino que por lo general es más preciso" (Rouge, 2017, p. 84).

**Metodología MASE.**

MASE viene de iniciales de Multi Agent System Engineering, es una metodología denominada también "Ingeniería de Sistemas Multi-Agente" desarrollada por Scott DeLoach, Mark F. Wood y Clint H. Sparkman, es una metodología de propósito general que permite desarrollar Sistema Multi-Agentes realizando el análisis y diseño (Ceballos, Gómez. y Osorio, 2019, p. 6).



**Figura 1. Diagrama de despliegue MaSE**  
**Fuente: Elaboración propia.**



En el desarrollo del Modelo Multi-Agentes con Aprendizaje Automático para mejorar el proceso de Morfosintaxis (MAAAM) se aplicó la metodología MASE. En la fase final de la metodología se conformó las clases de agentes, su relación, los tipos de agentes y la ubicación de los agentes dentro de un sistema, obteniendo el anterior diagrama.

**Características del modelo.**

El modelo MAAAM presenta las siguientes características, materiales y métodos en los diferentes agentes:

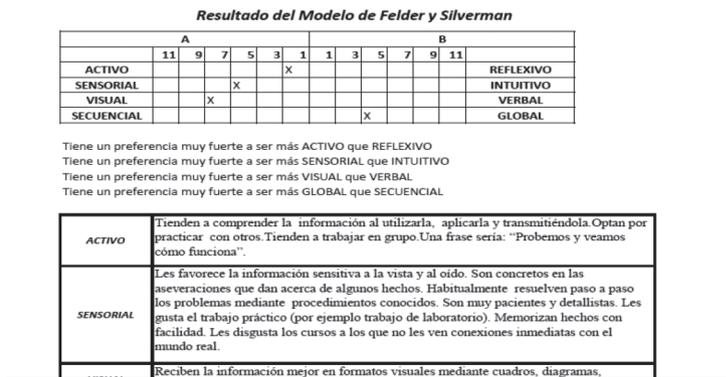
- **Clases de Agentes:** Cada clase de agente (Agente Evaluador, Agente Planificador, Agente Tutor, Agente Aprendiz) hereda de la clase base Agente.
- **Métodos Específicos:** Cada agente tiene métodos específicos que definen sus roles y responsabilidades. Por ejemplo, Agente Evaluador tiene un método para evaluar respuestas, Agente Tutor tiene un método para enseñar un tema, etc.

- **Agente Aprendiz:** Este agente incluye un simple modelo de aprendizaje automático y se pueden usar diferentes algoritmos y técnicas según la necesidad.
- **Modelo Multi-Agentes:** Esta clase principal maneja la interacción entre los diferentes agentes y proporciona un método ejecutar para demostrar cómo podrían trabajar juntos en una ejecución típica.

**Pantallas del modelo MAAAM.**

Se muestran la captura de algunas pantallas que forman parte del modelo MAAAM:

- **Modelo Feldel y Silverman:** Aplicación del Modelo de Felder y Silverman donde se debe responder a todos los ítems que tiene el modelo y al finalizar el Agente Evaluador con el Agente Interfaz mostraran los resultados con su respectiva explicación.



**Figura 2. Resultados del Modelo de Felder y Silverman**  
Fuente: Elaboración propia

- **Actividades:** Son las diferentes actividades que interactúan los Agentes Aprendiz y Asistente.

```

Introduce una oración:
La inteligencia artificial es fascinante
La: DET
inteligencia: NOUN
artificial: ADJ
es: VERB
fascinante: ADJ
    
```

**Figura 3. Ejemplo a) actividad de morfosintaxis**  
Fuente: Elaboración propia



**Figura 4. Ejemplo b) actividad de morfosintaxis**  
Fuente: Elaboración propia

- **Contenido Teórico:** Es el Contenido Teórico que muestra la explicación teórica de los conceptos que utiliza la morfología.

tipo'	}	{'tipopal'	}	{'detalle'
Palabras variables'	}	{'Sustantivo o nombre'	}	{'Clase de palabras con las que nombramos ...
Palabras variables'	}	{'Determinante'	}	{'Clase de palabras que concreta el signif...
Palabras variables'	}	{'Verbo'	}	{'Clase de palabras que expresa acciones, ...
Palabras variables'	}	{'Adjetivo'	}	{'Se refiere directa o indirectamente a un...
Palabras variables'	}	{'Pronombre'	}	{'Clase de palabras que sirve para indicar...
Palabras invariables'	}	{'Adverbio'	}	{'Palabras invariables que complementan o ...
Palabras invariables'	}	{'Preposición'	}	{'Son preposiciones en castellano de, en, ...
Palabras invariables'	}	{'Conjunción'	}	{'Palabras invariables que sirven para uni...
Sintagma'	}	{'El sintagma nominal (SN)'	}	{'Es una categoría sintáctica que puede te...
Sintagma'	}	{'El sintagma verbal (SV)'	}	{'Es la categoría sintáctica que realiza l...
Sintagma'	}	{'El sintagma adjetivo o adjetival (SAdj)'	}	{'Es una categoría sintáctica en la que ap...

**Figura 5. Base Teórica**  
Fuente: Elaboración propia - Captura pantalla de MAAAM



### Proceso Deep Learning.

Deep Learning utiliza redes neuronales profundas para modelar y aprender patrones complejos, entrenar la red neuronal para la clasificación de datos de características mediante Deep Learning, mediante lectura de datos, estadísticas y etiquetas categóricas.

### Red Neuronal Feedforward.

Una red neuronal feedforward tiene una arquitectura básica consta de capas de neuronas dispuestas secuencialmente:

- **Capa de entrada:** recibe el vector de entrada  $x$ .
- **Capas ocultas:** realizan transformaciones no lineales sobre la entrada.
- **Capa de salida:** produce el resultado final.

La representación de una red neuronal feedforward con una capa oculta

- Capa de entrada a capa oculta:
- Capa oculta a capa de salida:

Donde:

- es el vector de entrada.
- son los pesos de las conexiones.
- son los sesgos.
- es el vector de activaciones de la capa oculta.
- es el vector de salida.
- es una función de activación, como la función sigmoide.

### Función de Activación

La función de activación de la red que per-

mita que la red aprenda relaciones complejas es:

- **ReLU (Rectified Linear Unit):**

### Función de Costo

La función de costo mide la discrepancia entre la salida de la red y el valor deseado.

- **Error cuadrático medio (MSE)** para problemas varios:
- **Entropía cruzada** para problemas de clasificación:

Donde:

- es el valor real.
- es el valor predicho por la red.
- $n$  es el número de ejemplos.

### Retropropagación

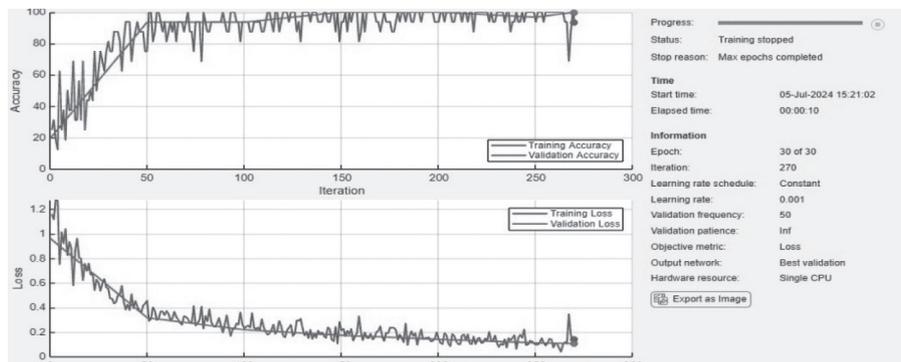
El objetivo es minimizar una función de costo  $J$ , comúnmente el error cuadrático medio para regresión o la entropía cruzada para clasificación. La actualización de los pesos se realiza mediante descenso de gradiente:

- Para los pesos de la capa de salida:
- Para los pesos de la capa oculta:

Donde es la tasa de aprendizaje.

### Proceso Entrenamiento de la Red

Para entrenar la red con la arquitectura definida por layers, utilizando los datos de entrenamiento de Matlab. Concluyendo el entrenamiento se genera una gráfica de progreso del entrenamiento de Deep Learning que muestra la pérdida y la precisión de minilotes.



**Figura 6. Gráfica de progreso del entrenamiento**  
Fuente: Elaboración propia

### Discusiones

La investigación sugiere que los modelos de multi-agentes tienen el potencial de revolucionar la enseñanza de la gramática, en particular en el ámbito de la morfosintaxis. Este tipo de modelo permite que múltiples agentes trabajen en conjunto, representando diferentes roles o enfoques en el proceso de aprendizaje. Cada agente puede estar encargado de un aspecto particular, como la sintaxis, la morfología, o la semántica, facilitando un aprendizaje integral y personalizado para los estudiantes.

Uno de los mayores puntos fuertes de este modelo es su flexibilidad y escalabilidad. A diferencia de los métodos tradicionales, que tienden a ser más rígidos y estandarizados, los modelos de multi-agentes pueden adaptarse no solo a diferentes campos del conocimiento, sino también a diferentes niveles educativos. Por ejemplo, mientras que este modelo se ha aplicado inicialmente en la enseñanza de la morfosintaxis,

se podría expandir para cubrir otros aspectos del lenguaje, como la semántica o el análisis de textos.

Los resultados obtenidos en esta investigación fueron positivos, destacando la efectividad de los modelos de multi-agentes en mejorar el proceso de enseñanza-aprendizaje en la gramática española. Esto sugiere que los modelos pueden evolucionar y mejorar, tanto en términos de personalización del aprendizaje como en la optimización de los algoritmos de IA utilizados.

Un área clave para investigaciones futuras podría ser la integración de modelos más sofisticados de procesamiento del lenguaje natural (NLP), que permitirían a los agentes comprender mejor el contexto de los errores gramaticales y ofrecer retroalimentación más precisa. Además, la creación de modelos híbridos, donde los agentes colaboren con el docente en lugar de reemplazarlo, podría proporcionar un enfoque equilibrado y flexible para mejorar la enseñanza.



## Conclusiones

La implementación de un modelo de multi-agentes ha demostrado ser una herramienta efectiva para mejorar el proceso de enseñanza de la morfosintaxis. A través de la interacción continua entre los agentes y los estudiantes, se pudo observar una mejora significativa en la comprensión y aplicación de las reglas gramaticales. Los estudiantes, al recibir retroalimentación inmediata y personalizada, lograron corregir sus errores con mayor rapidez y consolidar su aprendizaje de manera más profunda en comparación con los métodos tradicionales.

Uno de los puntos más destacados del modelo propuesto es su flexibilidad. Al estar basado en una arquitectura modular y adaptable, este sistema tiene el potencial de ser implementado en diferentes áreas del conocimiento más allá de la gramática española, y en distintos niveles educati-

vos. La escalabilidad del modelo permite que los agentes se configuren para abordar problemas específicos en diversas disciplinas, desde las humanidades hasta las ciencias exactas. Además, la capacidad del sistema para ajustarse a los estilos de aprendizaje de los estudiantes lo convierte en una herramienta versátil y adecuada para múltiples entornos educativos.

El modelo puede ser optimizado mediante la integración de técnicas de aprendizaje automático más sofisticadas, como el aprendizaje por refuerzo y redes neuronales profundas. Estas técnicas permitirían a los agentes adaptarse de manera más efectiva a los patrones de comportamiento de los estudiantes, aprendiendo de sus interacciones y mejorando la calidad de la enseñanza con el tiempo. De esta manera, se podría crear un ciclo de retroalimentación continua que optimice el rendimiento de los agentes y mejore aún más los resultados educativos.

## Referencias Bibliográficas

- Britton, Bruce K., y Tesser, Abraham (1991). Effects of time management practices on college grades. *Journal of Educational Psychology*, 83(3), 405-410.
- Ceballos, Y., Gómez, C. y Osorio, G. (2019). Analysis of the norm “pico y placa” in the Medellín city and its effectiveness in mitigating emissions of pollutants using agent-based simulation. *Prospectiva*, Vol 17, N° 1, 25-32.
- Celce-Murcia, Marianne, Dornyei, Zoltan, y Thurrell, Susan (1999). *Communicative Competence: A Pedagogically Motivated Model with Content Specifications*. *Issues in Applied Linguistics*, 10(2), 1-25.
- Chomsky, Noam (1965). *Aspects of the Theory of Syntax*. MIT Press.
- Felder R. Silverman L. (1988). *Learning Styles And Teaching Styles In Engineering Education*.



- García, Jesús A., y Weiss, Louis (2010). *Factors Affecting College Student Success: A Study of Academic Performance*. *Journal of College Student Development*, 51(4), 408-420.
- Misra, Ranjita, y McKean, Melanie (2000). *College Students' Mental Health and Academic Achievement: A Longitudinal Study*. *Journal of College Student Development*, 41(6), 627-636.
- Nuñez, Vicente. (2020). *Lengua castellana y Literatura*.
- Rouge, M. (2017). Aprendizaje Profundo (Deep Learning).
- Salmela-Aro, Katariina, Kiuru, Niina, Nurmi, Jari-Erik, y Eklund, Kaisa (2009). *Temporal Patterns of Students' Academic Achievement and School Burnout*. *Journal of Educational Psychology*, 101(3), 643-656.
- Tomlinson, Carol Ann (2014). *The Differentiated Classroom: Responding to the Needs of All Learners*. ASCD.
- Varela, J. (2019). *La morfosintaxis en la enseñanza del español: Un enfoque integral*. *Revista de Gramática Aplicada*, 7(1), 15-29.

**Fecha de recepción:** 30 de agosto de 2024

**Fecha de aceptación:** 25 de octubre de 2024