

Machine learning para evaluación de estrategias de enseñanza-aprendizaje del sistema web de planeaciones didácticas.

Machine Learning for evaluating teaching-learning strategies in the web-based didactic planning system.

Luis Manuel Faustino Rico (1).
Estudiante del Tecnológico Nacional de México-Valle de Bravo.
L202007020@vbravo.tecnm.mx.

Mariana Carolyn Cruz Mendoza* (2). Docente del Tecnológico Nacional de México-Valle de Bravo,
mariana.cm@vbravo.tecnm.mx.

Julio Alejandro López Espinoza (3). Estudiante del Tecnológico Nacional de México-Valle de Bravo,
L202007016@vbravo.tecnm.mx.

Cesar Primero Huerta (4). Docente del Tecnológico Nacional de México-Valle de Bravo,
iscprimerocesar@gmail.com.

*corresponding author.

Artículo recibido en diciembre 12, 2024; aceptado en enero 28, 2025.

Resumen.

En el Tecnológico de Estudios Superiores de Valle de Bravo (TESVB), la evaluación de estrategias pedagógicas es un proceso manual y subjetivo que dificulta el análisis efectivo y la identificación de estrategias alineadas con las competencias académicas. Para resolver esta problemática, se desarrolló un modelo de Machine Learning que automatiza la clasificación de estrategias utilizando BERT, un modelo avanzado de PLN, y el algoritmo K-means para agruparlas en categorías significativas. El modelo mejora la precisión en la evaluación al identificar patrones relevantes y proporcionar una base objetiva para decisiones pedagógicas. Las representaciones semánticas generadas por BERT permiten un análisis profundo del contexto y la efectividad de las estrategias, mientras que K-means organiza las estrategias según sus similitudes pedagógicas. Este enfoque optimiza el proceso de enseñanza-aprendizaje al alinear las estrategias con las competencias esperadas y fomentar su mejora continua, destacando su potencial impacto en la educación.

Palabras claves: Análisis, docencia, enseñanza-aprendizaje, predicción.

Abstract.

At the Tecnológico de Estudios Superiores de Valle de Bravo (TESVB), the evaluation of pedagogical strategies is a manual and subjective process that hinders effective analysis and the identification of strategies aligned with academic competencies. To address this issue, a Machine Learning model was developed to automate the classification of strategies using BERT, an advanced natural language processing model, and the K-means algorithm to group them into meaningful categories. The model enhances evaluation accuracy by identifying relevant patterns and providing an objective foundation for pedagogical decision-making. The semantic representations generated by BERT enable an

in-depth analysis of the context and effectiveness of the strategies, while K-means organizes them based on their pedagogical similarities. This approach optimizes the teaching-learning process by aligning strategies with expected competencies and fostering continuous improvement, highlighting its potential impact on education.

Keywords: Analysis, prediction, teaching, teaching-learning.

1. Introducción.

En el TESVB, la evaluación de estrategias de enseñanza-aprendizaje enfrenta diversos desafíos debido a la ausencia de un sistema automatizado basado en datos. Actualmente, este proceso es manual y subjetivo, lo que dificulta la identificación de estrategias pedagógicas alineadas con las competencias académicas y limita la posibilidad de realizar análisis objetivos que respalden decisiones pedagógicas informadas. Para abordar esta problemática, se propone un enfoque basado en Machine Learning (ML) que automatiza la evaluación y clasificación de estrategias pedagógicas, utilizando técnicas avanzadas de procesamiento de lenguaje natural y aprendizaje automático.

El modelo desarrollado emplea BERT (Bidirectional Encoder Representations from Transformers), un modelo de PLN diseñado para analizar texto y generar representaciones vectoriales que capturan el significado y el contexto completo de las palabras dentro de una oración. Este enfoque es especialmente útil para comprender la semántica de descripciones textuales complejas, como las estrategias pedagógicas analizadas en este proyecto. Estas representaciones vectoriales generadas por BERT fueron utilizadas como base para el agrupamiento de estrategias mediante el algoritmo K-means, que organiza las estrategias en categorías pedagógicas significativas, revelando patrones útiles para su evaluación.

Además, se implementaron redes neuronales artificiales para modelar las relaciones entre las características textuales y numéricas del conjunto de datos, como relevancia, tasa de éxito y motivación estudiantil. Este enfoque permitió predecir la efectividad de las estrategias de manera precisa y estructurada. El modelo fue evaluado mediante métricas estándar como precisión, recall y F1-score, demostrando un desempeño robusto y ofreciendo una base objetiva para mejorar las prácticas pedagógicas.

Se muestra una descripción general de las metodologías utilizadas, que incluyen la recolección y evaluación de datos provenientes de planeaciones didácticas, el preprocesamiento de texto con BERT, el agrupamiento mediante K-means y la predicción con redes neuronales. Finalmente, se muestran los resultados y su impacto en la mejora del proceso de enseñanza-aprendizaje, destacando la alineación de las estrategias con las competencias esperadas y la contribución del modelo a la toma de decisiones educativas.

2. Métodos.

La recopilación y análisis de documentos didácticos permitió la recolección de datos, en particular planeaciones de clases. Estos documentos permitieron identificar y generar las variables necesarias para construir el conjunto de datos utilizado en el entrenamiento de nuestro modelo de Machine Learning (ML). El objetivo principal del modelo fue predecir la pertinencia de las estrategias de enseñanza-aprendizaje en función del cumplimiento de las competencias señaladas en las materias.

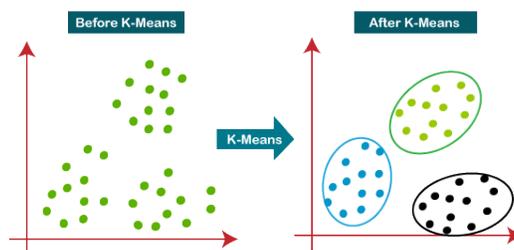


(Udemy, 2022)

Figura 1. Dataset.

El trabajo de Chakrapani y Praveena (2023) destacó la importancia de utilizar algoritmos de clasificación para identificar atributos clave y seleccionar el modelo de ML más eficiente para predecir el rendimiento académico. Este enfoque es crucial para garantizar que las predicciones sean relevantes y contribuyan al proceso educativo. En este estudio, se empleó una técnica avanzada de análisis de texto mediante el modelo BERT, ampliamente reconocido por su capacidad para captar el contexto completo de las palabras en el texto. BERT transformó las descripciones de las estrategias pedagógicas en representaciones vectoriales semánticamente ricas, lo que facilitó su análisis posterior. Estas representaciones se procesaron posteriormente con el algoritmo de clustering K-means, permitiendo agrupar las estrategias en clusters de acuerdo con sus semejanzas textuales y pedagógicas. (Praveena, Academic Performance Prediction Using Machine Learning: A Comprehensive & Systematic Review, 2022)

La utilización de K-Means como algoritmo de identificación de patrones naturales en los datos y generar agrupamientos homogéneos. Esto permitió una clasificación estructurada de las estrategias, revelando semejanzas y tendencias relevantes para su evaluación. Tal como afirman Yang y Cheng (2023), K-means es una herramienta ampliamente utilizada en ML para dividir los datos en grupos similares, lo que resulta particularmente útil para analizar grandes volúmenes de información. (Yang & Cheng, 2023)



(JavatPoint, 2020)

Figura 2. Fórmula K-Means Clustering.

Además, se emplearon redes neuronales para evaluar la efectividad de las estrategias, utilizando como entrada los datos transformados por BERT y los agrupamientos generados por K-means. Las redes neuronales permitieron modelar relaciones complejas entre las características de las estrategias y realizar predicciones más precisas gracias a su capacidad de aprendizaje. La evaluación del modelo se realizó mediante métricas de rendimiento como precisión, recall y F1-score, siendo esta última seleccionada por su capacidad de combinar precisión y recall en una única métrica. Estas herramientas facilitaron la valoración de la dependencia de los atributos y la efectividad del modelo. Los resultados obtenidos se visualizaron mediante gráficos de clustering y métricas, lo que permitió interpretaciones claras y comprensibles.

3. Desarrollo.

El primer paso consistió en recopilar y analizar planeaciones didácticas relacionadas con estrategias de enseñanza-aprendizaje. Este material permitió construir un conjunto de datos estructurado, incluyendo variables como relevancia, tasa de éxito y motivación estudiantil, además de descripciones textuales de las estrategias, pudiéndose observar en la

figura 3.

Estrategia	Relevancia	Tasa_de_Exit	Motivacion_Estudiante	Viabilidad
Método "Círculos de Análisis". Su objetivo es promover un ap	1	70.89730159	1	0
Método "Mesa Debate". Su objetivo es fomentar el sentido cri	4	98.37902758	1	1
Método "Actividad Focal Introdutoria". Su objetivo es atraer	5	77.39859416	1	1
Método "Discusión Guiada". Su objetivo es que las y los estu	1	71.17354712	5	0
Método "Planteamiento de Objetivos". Su objetivo es concrec	2	78.42601419	3	1
Método "Preguntas Intercaladas". Su objetivo es la conceptu	2	78.79622876	1	1
Método "Organizadores Gráficos". Su objetivo es la concrec	1	86.58238776	3	0
Método "Analogía". Su objetivo se basa en la comparaciÃ³n d	2	56.38448647	4	0
Método "Clase Expositiva". Su objetivo es que el docente mue	1	62.50082246	2	0
Método "Aprendizaje basado en Proyectos". Su objetivo es pa	5	79.02720062	4	1
Método "De Procedimientos". Su objetivo es centrarse en el p	5	93.35583036	4	0
Método "Aprendizaje basado en Problemas". Su objetivo es r	1	78.09333461	5	0
Dinámica "Globos". Colocar una pregunta en cada globo inf	5	61.92984299	2	0
Dinámica "AsociaciÃ³n de Letras". Se le da una letra de Foan	5	83.992239	4	0
Dinámica "Flashback". Preguntarle al alumno quÃ© recuerd	5	86.99543802	4	0
Dinámica "Abateleguas". Se escribe el nombre del alumno v	3	61.91180762	2	0
Dinámica "Cadena de Asociaciones". Por filas los alumnos v	4	68.88644431	2	1
Dinámica "Lluvia de Ideas". Donde el alumno participa	2	76.71637368	4	1

Figura 3. Dataset Estrategias.

Para analizar las descripciones textuales, se utilizó el modelo BERT, que generó representaciones vectoriales profundas. Cada texto fue tokenizado y transformado en un vector usando el token [CLS], que captura el contexto global de la estrategia pedagógica, pudiendo observar esta parte del código en la figura 4.

```
# Inicializar BERT
tokenizer = BertTokenizer.from_pretrained('bert-base-uncased')
bert_model = BertModel.from_pretrained('bert-base-uncased')

# Función para generar embeddings
def obtener_embeddings(texto):
    tokens = tokenizer(texto, return_tensors='pt', truncation=True, padding=True, max_length=512)
    with torch.no_grad():
        output = bert_model(**tokens)
    return output.last_hidden_state[:, 0, :].squeeze().numpy() # Usar el token [CLS] como representación

# Aplicar BERT a Los textos
df['Embeddings'] = df['Estrategia_Texto'].apply(obtener_embeddings)
```

Figura 4. Preprocesamiento y representación de datos.

Las representaciones vectoriales de BERT fueron agrupadas utilizando el algoritmo K-means, que identificó patrones naturales entre las estrategias. Se generaron tres clusters principales, que representaban categorías pedagógicas como trabajo colaborativo, competencias comunicativas y resolución de problemas, como se muestra en la figura 5.

```
# Aplicar K-means
kmeans = KMeans(n_clusters=3, random_state=42)
df['Cluster'] = kmeans.fit_predict(embeddings)

# Visualización de clusters
sns.scatterplot(x=embeddings[:, 0], y=embeddings[:, 1], hue=df['Cluster'], palette='viridis')
plt.title("Clusters de estrategias pedagógicas")
plt.show()
```

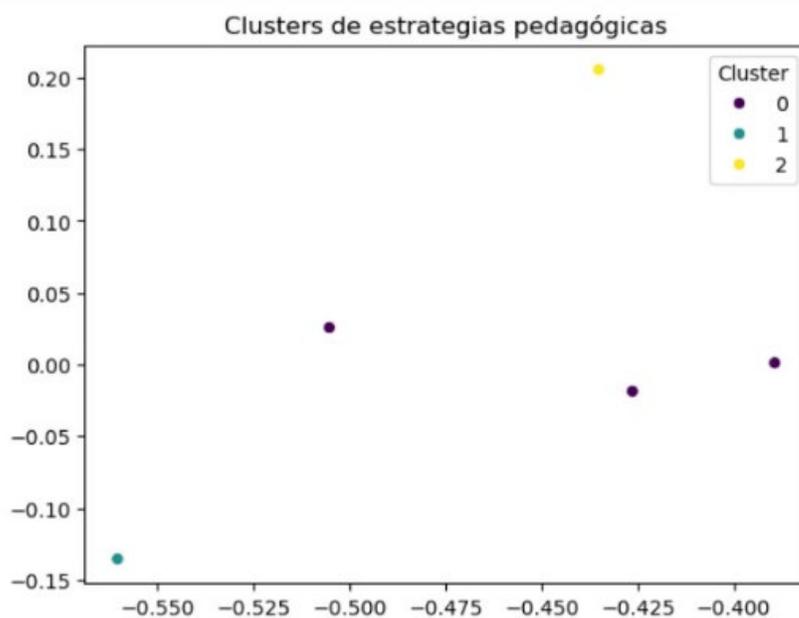


Figura 5. Aplicación K-Means a Estrategias.

Se entrenó un modelo de red neuronal artificial que combinó las representaciones vectoriales de BERT con variables numéricas del conjunto de datos. La arquitectura del modelo incluyó capas densas con funciones de activación ReLU y una capa de salida con activación sigmoide. Mediante el entrenamiento, se optimizaron los hiperparámetros para minimizar la pérdida y mejorar el rendimiento, esto se muestra en la figura 6.

```

# Dividir en entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Inicialización de Los parámetros (pesos y sesgos)
input_size = X_train.shape[1] # Número de características
hidden_size = 128 # Tamaño de la capa oculta
output_size = 1 # Para clasificación binaria (0 o 1)

# Pesos y sesgos de Las capas
np.random.seed(42)
W1 = np.random.randn(input_size, hidden_size) # Pesos de La capa 1
b1 = np.zeros((1, hidden_size)) # Sesgo de La capa 1
W2 = np.random.randn(hidden_size, output_size) # Pesos de La capa 2
b2 = np.zeros((1, output_size)) # Sesgo de La capa 2

# Funciones de activación
def sigmoid(x):
    return 1 / (1 + np.exp(-x))

def sigmoid_derivative(x):
    return x * (1 - x)

def relu(x):
    return np.maximum(0, x)

def relu_derivative(x):
    return np.where(x > 0, 1, 0)

# Propagación hacia adelante
def forward_propagation(X):
    Z1 = np.dot(X, W1) + b1 # Cálculo de la capa oculta
    A1 = relu(Z1) # Aplicar ReLU
    Z2 = np.dot(A1, W2) + b2 # Cálculo de la capa de salida
    A2 = sigmoid(Z2) # Aplicar Sigmoid
    return A1, A2 # Retornar la salida y la capa oculta

```

Figura 6. Entrenamiento de red neuronal.

Se entrenó un modelo de Machine Learning utilizando una combinación de técnicas avanzadas como representaciones semánticas generadas por BERT, agrupamiento mediante K-means, y redes neuronales para clasificar las estrategias pedagógicas. El análisis del modelo se realizó mediante métricas estándar (precisión, recall y F1-score). Los resultados demostraron un desempeño robusto, con un F1-score promedio de 1.0, lo que indica un equilibrio adecuado entre precisión y sensibilidad, mostrando el reporte de clasificación en la figura 7. La matriz de confusión mostrada en la figura 8 muestra una alta tasa de aciertos en la clasificación de estrategias viables y no viables, validando la capacidad del modelo para identificar patrones complejos en los datos.

F1-Score (weighted): 1.00

Reporte de Clasificación:

	precision	recall	f1-score	support
0	1.00	1.00	1.00	18
1	1.00	1.00	1.00	2
accuracy			1.00	20
macro avg	1.00	1.00	1.00	20
weighted avg	1.00	1.00	1.00	20

Figura 7. Reporte de clasificación.

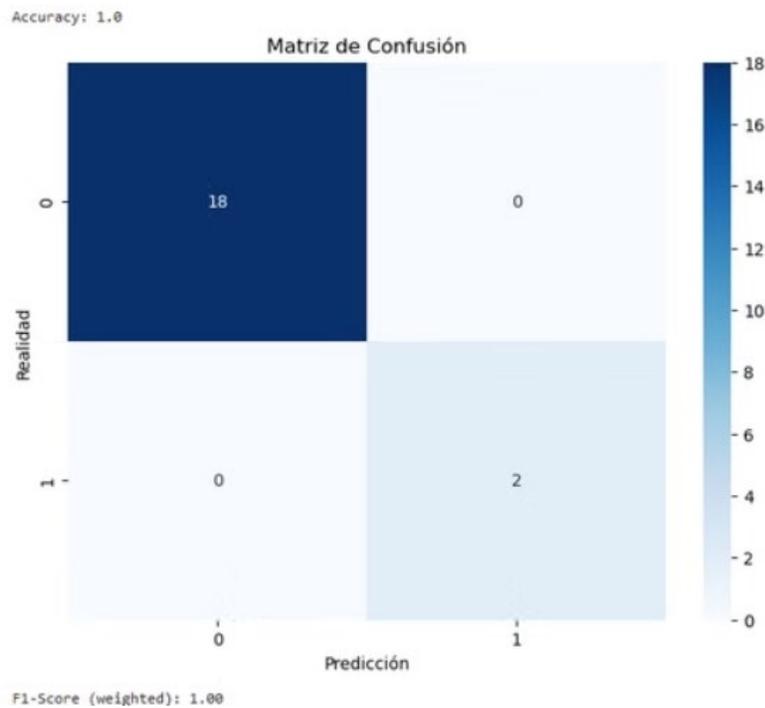


Figura 8. Matriz de confusión.

El análisis mediante el algoritmo K-means permitió identificar tres clusters principales que agrupan las estrategias pedagógicas según sus similitudes textuales y pedagógicas. Estos clusters reflejan categorías pedagógicas significativas: estrategias orientadas a la solución de problemas, actividades colaborativas y estrategias enfocadas en comunicación. Este agrupamiento estructurado reveló patrones importantes en las estrategias de enseñanza-aprendizaje, facilitando su evaluación y comparación.

Finalmente, se demostró la predicción correcta de una nueva estrategia la cual fue la solución de problemas, en conjunto con el producto esperado “Tareas (investigación en Word)”. El modelo evaluó características como relevancia, tasa de éxito, motivación del estudiante y recursos disponibles para realizar la predicción, observando este resultado en la figura 9.

```
[18]: nueva_estrategia = {
      'Estrategia_Cod': label_encoder_estrategia.transform(['Solución de problemas'])[0],
      'Producto_Cod': label_encoder_producto.transform(['Tareas (investigación en Word)'])[0],
      'Relevancia': 5,
      'Nivel_de_Complejidad': 4,
      'Tasa_de_Exito': 85,
      'Motivacion_Estudiante': 5,
      'Interaccion_Docente_Estudiante': 4,
      'Horas_Estudio': 15,
      'Participacion_Estudiante': 5,
      'Recursos_Cod': label_encoder_recursos.transform(['Tutorías'])[0]
    }

[19]: nueva_estrategia_df = pd.DataFrame([nueva_estrategia])

# Normalizar los datos de la nueva estrategia
nueva_estrategia_scaled = scaler.transform(nueva_estrategia_df)

# Hacer predicción
prediccion = clf.predict(nueva_estrategia_scaled)
print("¿Es viable la nueva estrategia?", "Sí" if prediccion[0] == 1 else "No")

¿Es viable la nueva estrategia? Sí
```

Figura 9. Predicción Nueva Estrategia.

Conclusiones.

El modelo propuesto demostró ser eficaz para clasificar estrategias pedagógicas y revelar patrones significativos que contribuyen al cumplimiento de las competencias educativas. La integración de técnicas avanzadas como BERT, K-means y redes neuronales permitió capturar relaciones complejas entre variables textuales y numéricas, logrando un alto rendimiento evaluado mediante métricas como el F1-score.

Los resultados destacan la importancia de factores como la relevancia, la motivación estudiantil y la tasa de éxito en la viabilidad de las estrategias, ofreciendo una herramienta práctica para mejorar las prácticas pedagógicas. Este enfoque puede ser expandido a diferentes contextos educativos, reforzando el conocimiento en el uso de ML en la optimización del proceso de enseñanza-aprendizaje.

Referencias bibliográficas.

- JavatPoint. (2020).** JavatPoint. Obtenido de <https://www.tpointtech.com/k-means-clustering-algorithm-in-machine-learning>.
- Praveena, C. (23 de ABRIL de 2022).** Academic Performance Prediction Using Machine Learning: A Comprehensive & Systematic Review. IEEEEXPLORE, 335-340.
- Praveena, C., & D, C. (22 de Abril de 2022).** Simulation of Machine Learning Techniques to Predict Academic Performance. IEEE XPLORE, 329-334.
- Udemy. (2022).** Udemy. Obtenido de https://www.udemy.com/course/power-bi-analisis-y-visualizacion-de-datos-basico/?utm_source=bing&utm_medium=udemyads&utm_campaign=BG-Search_DSA_Alpha_Prof_la.ES_cc.MX&campaigntype=Search&portfolio=Bing-Mexico&language=ES&product=Course&test=&audience=DSA&t.

Yang, Y., & Cheng, C. (2023). Construction of accurate group portrait of student funding based on Kmeans algorithm. IEE XPLORE, 154-158.

Información de los autores.



Luis Manuel Faustino Rico, Estudiante del programa de Ingeniería en Sistemas Computacionales del Tecnológico Nacional de México/Valle de Bravo.



Mariana Carolyn Cruz Mendoza, es Maestra en Ingeniería en Sistemas Computacionales por el Tecnológico de Estudios Superiores de Ecatepec e Ingeniero en Sistemas Computaciones por el Tecnológico de Estudios Superiores de Valle de Bravo. Cuenta con el reconocimiento de perfil deseable por PRODEP, es cofundador y miembro del cuerpo académico Procesamiento de datos con industria 4.0. Sus intereses en investigación son el aprendizaje automático y la ciencia de datos. Pertenece a la red nacional de Investigación Aplicación de las Tecnologías de la Industria 4.0 reconocida por el TECNM. Actualmente es docente en la carrera de Ingeniería en Sistemas Computacionales del Tecnológico Nacional de México - Valle de Bravo.



Julio Alejandro Lopez Espinoza, Estudiante del programa de Ingeniería en Sistemas Computacionales del Tecnológico Nacional de México/Valle de Bravo.



Cesar Primero Huerta, es Maestro en Ingeniería en Sistemas Computacionales por el Tecnológico de Estudios Superiores de Ecatepec e Ingeniero en Sistemas Computaciones por el Tecnológico de Estudios Superiores de Valle de Bravo. Cuenta con el

reconocimiento de perfil deseable por PRODEP, es cofundador y miembro del cuerpo académico: Procesamiento de datos con industria 4.0 y miembro activo del colectivo Ambiente Cielo Rojo. Sus intereses en investigación son el aprendizaje automático y la ciencia de datos, Actualmente es docente en la carrera de Ingeniería en Sistemas Computacionales del Tecnológico Nacional de México- Valle de Bravo.