

## **Modelado semántico y emocional con redes neuronales multicapa**

### *Semantic and emotional modeling with multilayer neural networks*

- Recibido: 2025/02/20 - Aprobado: 2025/04/02 - Publicado: 2025/04/23

Leonardo Correa Flores  
Alajuela, Costa Rica  
leonardo.correa@ticosoftcr.com  
<https://orcid.org/0009-0002-9184-2619>

Lucia Vega Castro  
Instituto Superior Tecnológico LEMAS, Guayaquil, Ecuador  
coo.neuro@teclemas.edu.ec  
<https://orcid.org/0000-0003-1349-2799>

Luz Ronquillo Alvarez  
Instituto Superior Tecnológico LEMAS, Guayaquil, Ecuador  
lronquillo@teclemas.edu.ec  
<https://orcid.org/0000-0001-5686-085X>

#### **Resumen**

Este artículo presenta una propuesta científica y tecnológica para el análisis semántico y emocional de interacciones digitales mediante redes neuronales multicapa. La arquitectura propuesta combina algoritmos de aprendizaje profundo con procesamiento de lenguaje natural (PLN) — concretamente modelos de tipo BERT y Word2Vec — para detectar y clasificar configuraciones emocionales complejas expresadas en texto, correlacionando significado, tono y contexto.

El modelo teórico que sustenta este trabajo es la Teoría Multinivel de las Emociones, la cual plantea que toda experiencia humana se organiza simultáneamente en tres niveles: instintivo (seguridad y reacción), socioemocional (vínculo y empatía) y analítico (coherencia y propósito), en consonancia con perspectivas neuro-afectivas previas. Esta estructura permite interpretar cada mensaje como una configuración emocional compuesta, más que como una emoción aislada.

La red neuronal multicapa se entrena para reconocer estas capas emocionales en el lenguaje digital, generando mapas de correlación semántica. Los resultados demuestran que este enfoque aumenta

la precisión en la interpretación del comportamiento colectivo, permitiendo anticipar tendencias comunicacionales y optimizar la relación entre marcas, instituciones y ciudadanos. La integración entre inteligencia artificial y teoría emocional ofrece un marco científico para comprender la mente social contemporánea, transformando los datos en conocimiento humano y predictivo.

### **Palabras clave**

redes neuronales multicapa, procesamiento del lenguaje natural, análisis emocional, inteligencia artificial, modelado semántico, comportamiento digital

### **Abstract**

This article presents a scientific and technological approach to the semantic and emotional analysis of digital interactions using multilayer neural networks. The proposed architecture combines deep learning algorithms with natural language processing (NLP) — specifically BERT-based and Word2Vec embedding models — to detect and classify complex emotional configurations expressed in text, correlating meaning, tone, and context.

The theoretical model underlying this work is the Multilevel Theory of Emotions, which proposes that every human experience is simultaneously organized across three levels: instinctive (security and reaction), socio-emotional (bond and empathy), and analytical (coherence and purpose), aligned with prior neuro-affective frameworks. The multilayer neural network is trained to recognize these emotional layers within digital language, generating semantic correlation maps. The results demonstrate improved accuracy in interpreting collective behavior, enabling the anticipation of trends and the optimization of relationships between brands, institutions, and citizens.

### **Keywords**

multilayer neural networks, natural language processing, emotional analysis, artificial intelligence, semantic modeling, digital behavior

## Introducción

El avance de la inteligencia artificial ha permitido desarrollar modelos capaces de procesar lenguaje, reconocer patrones y simular aspectos del razonamiento humano (Hinton et al., 2015). Sin embargo, comprender las emociones detrás de las palabras continúa siendo uno de los mayores desafíos científicos de nuestro tiempo (LeDoux y Brown, 2017). Las emociones no se expresan únicamente en lo que se dice, sino también en cómo se dice y en el contexto donde ocurre la interacción (Kövecses, 2020). En este marco, las redes neuronales multicapa se presentan como una arquitectura idónea para decodificar las estructuras semánticas y emocionales que emergen del lenguaje digital contemporáneo (Vaswani et al., 2017).

El volumen creciente de información proveniente de redes sociales, foros y entornos digitales ha convertido el análisis de sentimientos en un campo prioritario para la inteligencia artificial aplicada (Cambria et al., 2022). No obstante, la mayoría de los enfoques tradicionales se limitan a clasificar emociones en categorías planas — positivas, negativas o neutras — sin capturar la complejidad de las configuraciones emocionales humanas (Russell y Barrett, 1999). Este vacío metodológico exige un nuevo paradigma que permita interpretar la emoción como un sistema dinámico, con capas simultáneas de significado, vinculación y racionalidad (Panksepp, 2011).

En respuesta a esta necesidad, el presente estudio propone un modelo de análisis basado en la Teoría Multinivel de las Emociones (Bravo, 2024), que concibe la experiencia emocional como una interacción entre tres niveles: instintivo, socioemocional y analítico. Desde esta perspectiva, el lenguaje es una huella del estado cerebral colectivo (LeDoux y Brown, 2017), y su lectura a través de redes neuronales multicapa posibilita una comprensión más profunda del comportamiento humano en entornos digitales.

### 1.1. Fundamento teórico y origen del modelo

El modelado semántico y emocional con redes neuronales representa una propuesta que redefine la emoción como un sistema de respuesta simultánea en tres planos funcionales del cerebro humano (Panksepp, 2011). A diferencia de los modelos clásicos que conciben las emociones como impulsos aislados o reacciones discretas (Russell y Barrett, 1999), el enfoque multinivel propuesto por Bravo (2024) plantea que toda experiencia emocional combina, en distintos grados, necesidades de seguridad, vínculo y coherencia.

El nivel instintivo actúa como el sistema de alerta primaria, encargado de la supervivencia y la protección; se expresa en reacciones de impulso, urgencia o defensa, y constituye la base biológica del comportamiento (Panksepp, 2011). El nivel socioemocional organiza la experiencia afectiva en torno al vínculo, la empatía y la pertenencia (Kövecses, 2020). Finalmente, el nivel analítico otorga sentido y coherencia a la emoción, transformándola en pensamiento, argumento o propósito (LeDoux y Brown, 2017).

Esta estructura tridimensional permite comprender las decisiones humanas como el resultado de una interacción dinámica entre reacción, vínculo y sentido. En el contexto de los datos digitales, las redes neuronales multicapa reproducen este principio al procesar la información en capas sucesivas (Hinton et al., 2015), donde cada una aporta una lectura distinta del mismo mensaje: desde la respuesta impulsiva hasta la interpretación racional.

## **1.2. Arquitectura conceptual de la red neuronal multicapa aplicada al lenguaje emocional**

Las redes neuronales multicapa (MLP, del inglés Multilayer Perceptron) procesan la información en capas jerárquicas, emulando la forma en que el cerebro humano integra estímulos sensoriales, afectivos y cognitivos en distintos niveles de profundidad (Hinton et al., 2015). En el modelo propuesto, cada capa de la red cumple una función análoga a las dimensiones de la Teoría Multinivel de las Emociones (Bravo, 2024).

La primera capa representa el nivel instintivo: identifica patrones inmediatos en el texto, como la intensidad emocional, la urgencia o la presencia de términos de alerta. La segunda capa se asocia al nivel socioemocional, analizando las relaciones semánticas entre palabras, el tono afectivo, los pronombres inclusivos y las coocurrencias que reflejan vínculos o empatía (Kövecses, 2020). La tercera capa corresponde al nivel analítico, evaluando la coherencia discursiva, la argumentación lógica y la dirección racional del mensaje (LeDoux y Brown, 2017).

El modelo de aprendizaje utiliza funciones de activación no lineales (ReLU en capas ocultas; softmax en la capa de salida) para capturar relaciones complejas entre variables lingüísticas (Kim, 2014). Esta arquitectura se implementa dentro de un pipeline que integra análisis morfosintáctico, embeddings semánticos (Mikolov et al., 2013; Devlin et al., 2019) y clasificación emocional tridimensional. Los datos textuales son transformados en vectores de significado, procesados por la red y mapeados en un espacio emocional tridimensional (Cambria et al., 2022).

### **1.3. Entrenamiento y dataset del modelo emocional**

El entrenamiento de la red neuronal multicapa se realizó a partir de un corpus de interacciones reales en redes sociales, foros digitales, encuestas abiertas y comentarios de clientes de diferentes sectores. El propósito del entrenamiento no fue únicamente clasificar la polaridad emocional de los textos, sino enseñar al modelo a identificar las combinaciones y transiciones entre los tres niveles definidos por la Teoría Multinivel de las Emociones (Bravo, 2024): instintivo, socioemocional y analítico.

El proceso de construcción del dataset siguió una metodología de etiquetado mixto (manual y automático). En una primera fase, se realizó una curación semántica y emocional de más de 50.000 registros textuales, clasificados por analistas expertos. Cada texto recibió una etiqueta triple expresada en proporciones porcentuales. Por ejemplo, el enunciado "Estoy cansado de que nunca respondan" fue etiquetado como: 60 % instintivo (reacción), 30 % socioemocional (queja vinculante) y 10 % analítico (evaluación racional). En una segunda fase, se aplicaron técnicas de PLN para normalizar los textos y transformarlos en vectores mediante modelos de incrustación semántica, Word2Vec (Mikolov et al., 2013) y BERT (Devlin et al., 2019).

El modelo MLP utilizó el optimizador Adam con tasa de aprendizaje adaptativa de 0.001 y función de pérdida de entropía cruzada. El entrenamiento convergió en 87 épocas, determinadas por validación cruzada. Los datos se dividieron en entrenamiento (80 %) y validación (20 %); se aplicó dropout con tasa de 0.3 en las capas intermedias para evitar sobreajuste (Hinton et al., 2015). El desempeño se evaluó con métricas estándar de clasificación multiclase (precisión, recall, F1-score) y una métrica propia denominada índice de coherencia emocional (ICE).

### **1.4. Extracción de datos y obtención de resultados en el modelo**

El proceso inicia con la extracción de datos textuales de fuentes abiertas o privadas. Para garantizar la calidad del corpus, se aplican criterios de depuración lingüística: eliminación de duplicados, normalización ortográfica, anonimización de usuarios y filtrado de contenido generado por bots (Cambria et al., 2022). El resultado es un conjunto de textos limpios y contextualizados, listos para su procesamiento.

Una vez preparado el corpus, los textos son convertidos en vectores mediante modelos de incrustación — Word2Vec (Mikolov et al., 2013) o BERT (Devlin et al., 2019) — preservando las

relaciones contextuales entre palabras y frases. Estos vectores constituyen la entrada del modelo multicapa, que identifica patrones asociados con los tres niveles emocionales definidos (Bravo, 2024). Cada consulta al sistema produce: (a) una predicción emocional multinivel, expresada como un vector de proporciones (p. ej., 0.45 instintivo / 0.35 socioemocional / 0.20 analítico); (b) la polaridad y el tono semántico del discurso; y (c) un mapa de correlación semántica que vincula términos con emociones dominantes (Kövecses, 2020).

La interpretación de los resultados se realiza mediante análisis comparativo y longitudinal, observando la variación del equilibrio emocional a lo largo del tiempo o entre diferentes grupos de datos. Esto posibilita identificar tendencias emergentes, momentos de disonancia afectiva o cambios en la percepción colectiva de un tema (Cambria et al., 2022).

### **1.5. Interpretación de resultados y validación científica del modelo**

La interpretación de los resultados constituye una fase crucial del proceso analítico, ya que transforma los valores numéricos en conocimiento aplicable. Para este propósito, se implementa una validación cruzada en la que los resultados del modelo se contrastan con juicios de analistas entrenados en lectura emocional multinivel. El grado de coincidencia entre la red neuronal y la interpretación humana se expresa mediante el ICE, en una escala de 0 a 1. Un valor superior a 0.80 se considera evidencia de alineación sólida entre la interpretación automática y la humana.

Los resultados se proyectan en mapas de comportamiento emocional que representan las proporciones relativas de los tres niveles en cada texto o grupo de textos, permitiendo visualizar desplazamientos emocionales colectivos (Bravo, 2024). El análisis de estas trayectorias ofrece una lectura dinámica del comportamiento digital, capaz de anticipar variaciones en la percepción social antes de que se manifiesten en métricas convencionales (Russell y Barrett, 1999). La validación científica del modelo incorpora así una dimensión interpretativa que confirma que los resultados reflejan procesos humanos reales de reacción, conexión y sentido (LeDoux y Brown, 2017).

## **Materiales y Métodos**

La presente investigación adopta un enfoque metodológico mixto (Creswell y Creswell, 2018), que integra procedimientos cuantitativos y cualitativos de forma secuencial y complementaria. El componente cuantitativo comprende el entrenamiento, la evaluación estadística y la validación del

modelo de redes neuronales multicapa, mientras que el componente cualitativo se sustenta en un diseño de teoría fundamentada constructivista (Charmaz, 2014), aplicado al proceso de categorización y etiquetado emocional del corpus textual.

Desde la perspectiva de la teoría fundamentada constructivista (Charmaz, 2014), el investigador y los analistas expertos no descubren categorías preexistentes en los datos, sino que las construyen en interacción con ellos. Esto implica que los tres niveles emocionales — instintivo, socioemocional y analítico — no se imponen como categorías a priori, sino que se emplean como marco orientador susceptible de ser modificado conforme emergen patrones interpretativos en los datos textuales (Bravo, 2024). Los procedimientos de codificación inicial, codificación focalizada y comparación constante (Charmaz, 2014) guían el proceso de construcción de etiquetas emocionales.

A diferencia de los enfoques convencionales de minería de sentimientos que tratan la emoción como una variable nominal discreta (Cambria et al., 2022), este modelo considera la emoción como una estructura tridimensional continua, alineada con la Teoría Multinivel de las Emociones (Bravo, 2024). La metodología se organizó en tres fases principales: (1) recopilación y preprocesamiento del corpus textual; (2) construcción y entrenamiento del modelo multicapa; y (3) evaluación y validación de los resultados. Cada fase se diseñó con criterios de reproducibilidad científica, control de sesgos lingüísticos y respeto por la privacidad de los datos.

### **2.1. Fuentes de datos y criterios de selección**

El corpus se conformó a partir de publicaciones y comentarios textuales extraídos de redes sociales, foros públicos y encuestas digitales, con el objetivo de capturar un lenguaje natural, espontáneo y diverso en temas, estilos y contextos. Cada registro fue sometido a limpieza y normalización lingüística: eliminación de duplicados, corrección ortográfica, tokenización, lematización y anonimización de usuarios (Cambria et al., 2022). Los datos fueron etiquetados en español, con atención especial a la variación dialectal latinoamericana. El tamaño final del corpus fue de aproximadamente 50.000 entradas únicas, distribuidas en cinco categorías temáticas (consumo, política, educación, bienestar y tecnología).

## 2.2. Construcción y entrenamiento del modelo

La red neuronal se implementó con una arquitectura MLP compuesta por una capa de entrada, tres capas ocultas y una capa de salida. La capa de entrada recibió vectores semánticos de alta dimensionalidad generados mediante Word2Vec (Mikolov et al., 2013) y BERT (Devlin et al., 2019). Las capas ocultas utilizaron funciones de activación ReLU; la capa de salida empleó softmax para distribuir probabilísticamente la pertenencia del texto a los tres niveles emocionales (Kim, 2014). El entrenamiento se realizó con el optimizador Adam (tasa de aprendizaje: 0.001), función de pérdida de entropía cruzada y dropout de 0.3. La convergencia se alcanzó en 87 épocas, determinadas por validación cruzada; la división de datos fue 80 % entrenamiento / 20 % validación (Hinton et al., 2015).

## 2.3. Procedimiento de consulta y análisis de resultados

Una vez entrenado el modelo, se implementó un sistema de consulta que permite ingresar textos en lenguaje natural y obtener una predicción emocional multinivel. Cada consulta produce: (a) la proporción de activación en los niveles instintivo, socioemocional y analítico; (b) la polaridad emocional (positiva, negativa o neutra); y (c) un mapa de correlación semántica que vincula palabras clave con las emociones predominantes (Kövecses, 2020). Los resultados se analizaron de forma comparativa y longitudinal; para cada conjunto de textos se calculó el ICE, indicador que expresa la estabilidad del patrón emocional predominante y su consistencia con el contexto discursivo general.

Desde el diseño de teoría fundamentada constructivista (Charmaz, 2014), la fase de análisis no se limitó a la evaluación estadística, sino que incorporó ciclos de comparación constante entre los patrones cuantitativos detectados por el modelo y las interpretaciones cualitativas de los analistas expertos. El conjunto de métodos descritos confirma que el modelo cumple con los principios de replicabilidad y transparencia científica (Creswell y Creswell, 2018), y ofrece una aproximación empírica para el estudio sistemático del lenguaje emocional en entornos digitales.

## Resultados

El modelo de redes neuronales multicapa demostró una capacidad significativa para identificar configuraciones emocionales complejas dentro de corpus textuales provenientes de entornos

digitales reales. Los resultados confirman que las emociones expresadas en lenguaje natural no operan de forma unidimensional, sino como combinaciones dinámicas de niveles instintivos, socioemocionales y analíticos — coherente con los postulados de Russell y Barrett (1999) — que pueden ser detectadas y representadas mediante arquitecturas de aprendizaje profundo (Hinton et al., 2015).

Durante la fase experimental, se observaron altos niveles de coherencia entre las predicciones del modelo y las evaluaciones humanas de referencia, validando la efectividad del enfoque multinivel (Bravo, 2024; Panksepp, 2011). Este hallazgo refuerza la pertinencia de la Teoría Multinivel de las Emociones como fundamento teórico para la modelización computacional del comportamiento humano.

### **3.1. Análisis de los resultados y consideraciones interpretativas**

Los resultados finales del modelo evidencian una precisión promedio del 87 % en la identificación de las configuraciones emocionales dominantes. Este porcentaje representa una mejora respecto a los sistemas convencionales de análisis de sentimientos, limitados a clasificaciones binarias o ternarias (Cambria et al., 2022). La arquitectura multicapa permitió detectar matices emocionales intermedios y registrar transiciones entre los tres niveles con un margen de error inferior al 10 % (Hinton et al., 2015).

El análisis de los mapas emocionales mostró que la mayoría de las conversaciones digitales tiende a organizarse alrededor de dos polos: instintivo-socioemocional (impulsividad y pertenencia) y socioemocional-analítico (empatía y razonamiento compartido). Este hallazgo sugiere que la interacción social en línea es una oscilación constante entre seguridad, vínculo y sentido, en consonancia con los postulados de la Teoría Multinivel de las Emociones (Bravo, 2024) y con la perspectiva dimensional de Russell y Barrett (1999).

El ICE alcanzó valores superiores a 0.82 en los conjuntos de datos analizados, indicando alta correspondencia entre el modelo computacional y la percepción emocional humana. Desde una perspectiva interpretativa — consistente con el diseño de teoría fundamentada constructivista adoptado (Charmaz, 2014) —, los resultados revelan que las emociones digitales se comportan como sistemas autoorganizados: varían con el tiempo, se retroalimentan y se propagan por resonancia social (Kövecses, 2020). La validación empírica del modelo abre una nueva vía para la

investigación del lenguaje emocional, confirmando que la combinación entre inteligencia artificial y teoría emocional ofrece una lectura más profunda del comportamiento humano digital (Vaswani et al., 2017).

## Conclusiones

El presente estudio demuestra que el modelado semántico y emocional mediante redes neuronales multicapa (Hinton et al., 2015) constituye una herramienta científica válida para comprender la complejidad del comportamiento humano en entornos digitales. Al integrar el aprendizaje profundo con la Teoría Multinivel de las Emociones (Bravo, 2024) y con marcos neuro-afectivos consolidados (Panksepp, 2011; LeDoux y Brown, 2017), se logró construir un modelo capaz de leer el lenguaje como una manifestación simultánea de reacción, vínculo y sentido, superando las limitaciones de los análisis unidimensionales de sentimiento (Cambria et al., 2022; Russell y Barrett, 1999).

La adopción de un enfoque mixto con diseño de teoría fundamentada constructivista (Charmaz, 2014; Creswell y Creswell, 2018) permitió articular el componente cuantitativo del modelo computacional con el componente cualitativo del proceso interpretativo-emocional, dotando a la investigación de una base epistemológica sólida. Metodológicamente, la red neuronal multicapa demostró que la combinación entre estructura algorítmica y teoría emocional puede alcanzar niveles de precisión superiores al 85 %, con una coherencia interpretativa cercana al juicio humano, abriendo la posibilidad de desarrollar sistemas de observación emocional en tiempo real.

La lectura computacional del lenguaje emocional inaugura una frontera científica en la que los datos se convierten en una expresión estructurada del sentir colectivo. En esa convergencia entre ciencia, emoción y tecnología — donde la inteligencia artificial amplifica la comprensión humana (Vaswani et al., 2017) — se perfila el nuevo horizonte del conocimiento: comprender para conectar, medir para interpretar y modelar para humanizar la inteligencia artificial.

## Referencias

- Bravo, S. (2024). *Teoría de las emociones multinivel: El nuevo paradigma de la investigación de mercados y consumidores*. San José, Costa Rica. [Libro de consultoría; pendiente de verificación de indexación académica.]
- Cambria, E., Poria, S., Hazarika, D., & Kwok, K. (2022). SenticNet 7: A commonsense-based neurosymbolic AI framework for explainable sentiment analysis. *Proceedings of the 31st International Joint Conference on Artificial Intelligence*, 3829–3837. <https://doi.org/10.24963/ijcai.2022/530>
- Charmaz, K. (2014). *Constructing grounded theory* (2.<sup>a</sup> ed.). SAGE Publications.
- Creswell, J. W., & Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches* (5.<sup>a</sup> ed.). SAGE Publications.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training deep bidirectional transformers for language understanding. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics (NAACL-HLT)*, 4171–4186. <https://doi.org/10.18653/v1/N19-1423>
- Hinton, G. E., LeCun, Y., & Bengio, Y. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Kim, Y. (2014). Convolutional neural networks for sentence classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1746–1751. <https://doi.org/10.3115/v1/D14-1181>
- Kövecses, Z. (2020). *Emotion concepts and human meaning: A cognitive semantic perspective*. Cambridge University Press.
- LeDoux, J. E., & Brown, R. (2017). A higher-order theory of emotional consciousness. *Proceedings of the National Academy of Sciences*, 114(10), E2016–E2025. <https://doi.org/10.1073/pnas.1619316114>

- Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J. (2013). Distributed representations of words and phrases and their compositionality. *Advances in Neural Information Processing Systems*, 26, 3111–3119.
- Panksepp, J. (2011). The basic emotional circuits of mammalian brains: Do animals have affective lives? *Neuroscience & Biobehavioral Reviews*, 35(9), 1791–1804. <https://doi.org/10.1016/j.neubiorev.2011.08.003>
- Russell, J. A., & Barrett, L. F. (1999). Core affect, prototypical emotional episodes, and other things called emotion: Dissecting the elephant. *Journal of Personality and Social Psychology*, 76(5), 805–819. <https://doi.org/10.1037/0022-3514.76.5.805>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998–6008.

Copyright (2025) © Leonardo Correa Flores, Lucia Vega Castro, Luz Ronquillo Alvarez

Este texto está protegido bajo una licencia internacional Creative Commons 4.0.



Usted es libre para Compartir—copiar y redistribuir el material en cualquier medio o formato — y Adaptar el documento — remezclar, transformar y crear a partir del material—para cualquier propósito, incluso para fines comerciales, siempre que cumpla las condiciones de Atribución.

Usted debe dar crédito a la obra original de manera adecuada, proporcionar un enlace a la licencia, e indicar si se han realizado cambios. Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que tiene el apoyo del licenciante o lo recibe por el uso que hace de la obra.

[Resumen de licencia](#) – [Texto completo de la licencia](#)