

UNIVERSIDAD INTERNACIONAL
DE LA RIOJA

PROGRAMA DE DOCTORADO EN CIENCIAS DE LA
COMPUTACIÓN

TESIS DOCTORAL

Modelo ubicuo de análisis emocional para clases en línea

Memoria presentada por
Susana Alexandra Arias Tapia
para optar al grado de Doctor
por la Universidad Internacional de La Rioja

Dirigida por los Doctores:

Pablo Moreno – Ger
Elena Verdú Perez

Logroño, 2024

Agradecimientos

Agradezco a Dios por ser quien bendice e ilumina mi camino con su amor y bendiciones.

Agradezco de manera especial a mi esposo Héctor por su apoyo incondicional en todo momento; así como a mi hijo Andy, por ser mi inspiración cada día.

Agradezco a mis Directores de tesis Ph.D. Pablo Moreno-Ger y Ph.D. Elena Verdú Perez por su acompañamiento, dirección y conocimiento a lo largo de todo el proyecto de investigación.

Resumen

La gestión emocional es muy importante en las clases presenciales, de hecho, es la base misma del aprendizaje. Sin embargo, todavía no hay una respuesta clara sobre qué sucede en las clases en línea en referencia a las reacciones emocionales. ¿Existen emociones predominantes en las clases en línea? ¿Se pueden crear clusters emocionales en las clases en línea? ¿Es posible obtener tendencias a la acción para el aprendizaje en las clases en línea? En este trabajo presentamos un modelo ubicuo de análisis emocional para clases en línea. La metodología propuesta permite identificar las emociones básicas en el rostro de los estudiantes, determinar emociones predominantes, verificar si las emociones básicas pueden crear clusters emocionales y finalmente usar estos clusters para inferir tendencias a la acción para el aprendizaje mediante una interpretación semántica ontológica durante clases en línea grabadas en video, que sirvan de base para la retroalimentación en el proceso de enseñanza – aprendizaje. La experimentación fue llevada a cabo en una clase en línea real. Para evaluar el modelo, los expertos corroboraron los resultados del modelo ubicuo y se confirma que las tendencias a la acción para el aprendizaje obtenidas por el modelo coinciden con el criterio de los expertos. Inferir las tendencias a la acción es muy importante, ya que el profesor, a diferencia de un modelo presencial, tiene dificultad para observar a todos los estudiantes con el uso de cámaras en clases en línea, dificultando la comprensión del comportamiento de los estudiantes. Este estudio planteó importantes cuestionamientos en sus conclusiones al llevar a cabo una exhaustiva revisión metodológica y teórica de nuevas perspectivas destinadas a comprender las emociones en entornos de aprendizaje en línea. Estas reflexiones abren la puerta a futuras investigaciones, enriqueciendo así la interpretación de los resultados experimentales.

Palabras clave

Clases en línea, clustering, comportamiento emocional, modelo ubicuo, reconocimiento de emociones, ontología de la emoción humana, tendencias a la acción.

Abstract

Emotional management is crucial in face-to-face classes; in fact, it forms the cornerstone of learning itself. However, there is still no clear answer regarding what occurs in online classes concerning emotional reactions. Are there predominant emotions in online classes? Can emotional clusters be created in online classes? Is it possible to get action tendencies for learning in online classes? In this work, we introduce a ubiquitous emotional analysis model for online classes. The proposed methodology enables the identification of basic emotions on students' faces, determination of predominant emotions, verification if basic emotions can form emotional clusters, and finally use these clusters to infer action tendencies for learning through an ontological semantic interpretation during recorded video-based online classes, which serve as a basis for feedback in the teaching-learning process. Experimentation was conducted in a real online class. To evaluate the model, experts corroborated the results of the ubiquitous model, confirming that the action tendencies for learning obtained by the model coincide with experts' criteria. Inferring action tendencies is crucial, as unlike in face-to-face models, teachers have difficulty observing all students using cameras in online classes, making it difficult to understand student behavior. This study posed significant questions in its conclusions by conducting a comprehensive methodological and theoretical review of new perspectives aimed at understanding emotions in online learning environments. These reflections provide opportunities for further research, thereby enriching the interpretation of experimental results.

Keywords

On-line classes, clustering, emotional behavior, ubiquitous model, emotion recognition, human emotion ontology, action tendencies.

TABLA DE CONTENIDO

CAPÍTULO I. INTRODUCCIÓN.....	1
1.1. Problema.....	4
1.2. Descripción de la investigación	5
1.3. Objetivos del trabajo.....	7
1.3.1 Objetivo Principal.....	8
1.3.2 Las emociones predominantes	9
1.3.3 Clusters emocionales.....	10
1.3.4 Tendencias a la acción	10
1.3.5 Hipótesis	11
1.4. Metodología.....	11
1.4.1 Recopilación de datos.....	13
1.4.2 Aporte metodológico	14
1.5. Conclusiones	15
CAPÍTULO II. ESTADO DEL ARTE.....	18
2.1. Influencias principales	19
2.2. Emociones humanas y aprendizaje en línea.....	23
2.2.1 Estudios de las emociones	24
2.2.2 Emociones en el proceso de aprendizaje	26
2.2.3 Emociones en el aprendizaje en línea	28
2.3. Herramientas de análisis	30
2.3.1 Software de Detección de Emociones.....	31
2.3.2 Principio de Pareto	32
2.3.3 Algoritmo KMEANS	33
2.4. Modelado ontológico de emociones y sus influencias: Explorando el dominio emocional.....	36
2.4.1 Ontologías para el análisis de emociones: Un enfoque semántico en el estudio emocional	37
2.4.2 Ontologías y el aprendizaje en línea.....	38
2.4.3 Explorando la estructura de HASIO: Una ontología para el análisis de estados emocionales.....	40

2.5. Conclusiones	44
CAPÍTULO III. METODOLOGÍA.....	48
3.1. Metodología del modelo ubicuo de análisis emocional.....	49
3.1.1 Pasos metodológicos para la selección y agrupamiento de emociones	50
3.1.2 Pasos metodológicos para inferir las Tendencias a la acción en la ontología.....	54
3.2. Metodología para evaluar el modelo ubicuo de análisis emocional	56
3.2.1 Validación del software de reconocimiento de emociones.....	57
3.2.2 Validación semántica.....	57
3.3. Interfaz del modelo ubicuo	59
3.3.1 Opción “Action_Tendency”	59
3.3.2 Opción “Pareto”	60
3.4. Conclusiones	61
CAPÍTULO IV. EXPERIMENTOS.....	63
4.1. Experimento No.1: Software de reconocimiento de emociones	66
4.1.1 Planteamiento del experimento.....	66
4.1.2 Resultados.....	68
4.1.3 Discusión	75
4.1.4 Conclusiones.....	78
4.2. Experimento No.2: Principio de Pareto	79
4.2.1 Planteamiento del experimento.....	79
4.2.2 Resultados.....	79
4.2.3 Discusión	81
4.2.4 Conclusiones.....	83
4.3. Experimento No.3: Algoritmo KMEANS	84
4.3.1 Planteamiento del experimento.....	84
4.3.2 Resultados.....	88
4.3.3 Discusión	89
4.3.4 Conclusiones.....	89
4.4. Experimento No.4: Ontología HASIO.....	90
4.4.1 Planteamiento del experimento.....	91
4.4.2 Resultados.....	92
4.4.3 Discusión	94
4.4.4 Conclusiones.....	96
4.5. Experimento No.5: Validación semántica de la Ontología HASIO	97
4.5.1 Planteamiento del experimento.....	97

4.5.2 Resultados.....	98
4.5.3 Resultados entre Expertos para Kappa	101
4.5.4 Resultados Ontología vs. Expertos.....	102
4.5.5 Discusión	104
4.5.6 Conclusiones.....	105
4.6 Conclusiones del capítulo	106
CAPÍTULO V. CONCLUSIONES	112
5.1. Análisis del cumplimiento de los objetivos.....	114
5.1.1 Identificación de Emociones Predominantes	114
5.1.2 Creación de Clústeres Emocionales.....	115
5.1.3 Inferencia de Tendencias a la Acción.....	116
5.2. Resumen de contribuciones	117
5.3. Trabajos futuros.....	118
BIBLIOGRAFÍA	122

ÍNDICE DE TABLAS

Tabla 1. Investigaciones sobre el manejo emocional y comportamiento humano en entornos educativos en línea.....	19
Tabla 2. Action_Tendency y funciones de algunas emociones (Frijda, 1986)	43
Tabla 3. Extracto del archivo de entrada para graficar Pareto	52
Tabla 4. Resultados del software Emotion Recognition (video del Estudiante 1).....	68
Tabla 5. Resultados del software Emotion Recognition (video del Estudiante 3).....	70
Tabla 6. Expertos vs Resultados del Software Emotion Recognition (video del Estudiante 3).....	71
Tabla 7. Datos de la curva ROC para los 33 estudiantes.....	73
Tabla 8. Archivo de entrada para KMEANS del Estudiante 1.....	85
Tabla 9. Resultados de la clase “Frijda_Action_Tendency”.....	92
Tabla 10. Resultados de los expertos vs. Resultados de la ontología (tabla completa)	99
Tabla 11. Resultados de los expertos vs. Resultados de la ontología (tabla resumida).....	100
Tabla 12. Valoraciones del coeficiente Kappa	104

ÍNDICE DE FIGURAS

Figura 1 Software de reconocimiento de emociones en el rostro	6
Figura 2 Aparataje emocional en el aula.....	29
Figura 3 Relaciones tridimensionales emocionales (Latinjak et al., 2014).....	37
Figura 4 Modelo conceptual de la ontología HASIO que representa las principales entidades y las relaciones entre las entidades (Abaalkhail, 2018)	41
Figura 5 Estructura de las principales clases, subclases y sus propiedades de la ontología HASIO que se relacionan con los estados afectivos (Abaalkhail, 2018)	42
Figura 6 Metodología aplicada para la obtención del comportamiento humano (Tendencias a la acción para el aprendizaje) a partir de los rostros grabados de estudiantes.....	50
Figura 7 Emociones de un estudiante obtenidas por el software de reconocimiento de emociones	51
Figura 8 Inferencia en la clase Frijda_Action_Tendency para el Estudiante 2.....	55
Figura 9 Interfaz del modelo ubicuo de análisis emocional desarrollada en Python	59
Figura 10 Opción “Action_Tendency”	59
Figura 11 Opción “Pareto”	60
Figura 12 Curvas ROC del conjunto de emociones registradas en los rostros de 5 estudiantes	73
Figura 13 Diagrama de Pareto: emociones básicas en una clase en línea	80
Figura 14 Ejecución del método del codo.....	87
Figura 15 Ejecución del algoritmo KMEANS para Estudiante 1	88
Figura 16 Inferencia de la clase “Frijda_Action_Tendency” para el Estudiante 1	94

CAPÍTULO I. INTRODUCCIÓN

Las emociones desempeñan un papel crucial en el ámbito educativo, actuando como elementos fundamentales en el proceso de aprendizaje. La importancia de comprender y manejar las emociones en la educación se refleja en su impacto tanto en el bienestar social y mental de los alumnos como en su capacidad de atención y desarrollo. Las emociones pueden actuar como poderosos aliados o impedimentos en la absorción de conocimientos, y su gestión adecuada contribuye significativamente al ambiente educativo. La inteligencia emocional se destaca como un factor clave, facilitando a los estudiantes herramientas para enfrentar desafíos, gestionar el estrés y cultivar relaciones positivas. La educación se centra cada vez más en el manejo de las emociones, reconociendo su influencia en el desarrollo integral de los individuos y su impacto en el rendimiento académico.

En el contexto de la educación en línea, el análisis emocional se destaca como un campo vital de investigación y desarrollo. Comprender las emociones de los estudiantes en este contexto es esencial para ofrecer un entorno de aprendizaje efectivo y personalizado. Las clases en línea presentan desafíos únicos, ya que la comunicación no verbal y las interacciones en tiempo real se ven limitadas. Por lo tanto, comprender las emociones de los estudiantes durante estas clases es fundamental para brindar un entorno de aprendizaje efectivo y personalizado. Así, para promover la educación en línea, la computación ubicua representa un paradigma emergente, pues mediante ella se puede obtener datos importantes de las emociones en los contextos educativos, información que puede ser utilizada para lograr un aprendizaje significativo (Cárdenas-Robledo et al., 2018) (Villamizar et al., 2023).

La investigación de un modelo ubicuo de análisis emocional para clases en línea no solo mejoraría la calidad de la educación en la clase, sino que también contribuiría al avance del campo del análisis emocional en general. Además, la comprensión más profunda de las emociones en el contexto educativo en línea abriría nuevas oportunidades para investigar, diseñar intervenciones emocionales efectivas y nuevos modelos pedagógicos que mejoren la experiencia de aprendizaje y el bienestar de los estudiantes.

La elaboración de esta tesis se centra en el desarrollo de un modelo ubicuo de análisis emocional que aspira a detectar las emociones de los estudiantes durante las clases en línea y procesar esas emociones para obtener un comportamiento conocido como tendencias a la acción o action tendencies. Al identificar y comprender las tendencias a la acción, se pueden adaptar las estrategias pedagógicas y los recursos de enseñanza para promover un aprendizaje más significativo.

Al estudiar las actitudes y emociones en el aprendizaje en línea, los educadores pueden identificar los factores que influyen en la participación y el compromiso de los estudiantes.

Esto les permite adaptar las estrategias pedagógicas y crear un ambiente de aprendizaje virtual más motivador, interactivo y emocionalmente satisfactorio. Reconociendo y valorando las emociones de los estudiantes, se fomenta la empatía, se establece una relación de confianza entre el profesor y el estudiante, en consecuencia, el cerebro emocional recibe de mejor manera los estímulos externos, lo cual es fundamental para generar un clima propicio para el aprendizaje (Harley et al., 2019).

Para lograr esto, será importante también entender cómo funcionan las respuestas emocionales y como éstas influyen en nuestro comportamiento. Las emociones, consideradas eventos de corto plazo que involucran una experiencia subjetiva de un estado emocional, son desencadenadas en respuesta a estímulos relevantes (Ekman, 1999). Según Goleman (1995), las emociones funcionan como impulsos para la acción, preparando al organismo para diferentes tipos de respuestas. Es común que las emociones vengan acompañadas por una tendencia a la acción, que representa el sentimiento de querer actuar o motivar la acción. Goleman habla de la existencia de un "cerebro emocional" en el sistema límbico, que trabaja en estrecha colaboración con el cerebro racional (corteza prefrontal). Este sistema límbico es responsable de la generación y procesamiento de las emociones, mientras que la corteza prefrontal nos permite regular y manejar nuestras respuestas emocionales.

Goleman resalta la importancia de la regulación emocional, es decir, la capacidad de controlar y dirigir nuestras emociones de manera adecuada. Esto implica la capacidad de gestionar el estrés, manejar la ira, cultivar la empatía y tomar decisiones equilibradas. Por ejemplo, si experimentamos miedo, es posible que evitemos una situación o estímulo que lo provoque. Además, nuestras emociones pueden definir tendencias a la acción al influir en nuestras decisiones y elecciones. Según Lazarus (1991), las emociones no solo son reacciones automáticas, sino que también implican una evaluación cognitiva del estímulo y su significado para el individuo.

En el contexto educativo, por ejemplo, los estudiantes experimentan una tendencia a la acción en su deseo de aprender a colaborar, trabajar en equipo o buscar evadirse, entre otras acciones. Estas tendencias a la acción pueden tener una valencia positiva, negativa o neutra, manifestándose como estados dinámicos de querer-aprender, no-sentir-aprender y no-querer-aprender. Se ha observado que estas tendencias a la acción son altamente predictivas del comportamiento en situaciones donde no existen restricciones sociales u otras limitaciones (Palmer, 2017).

1.1. Problema

Frijda en 1986 sostuvo que la tendencia a la acción es el núcleo de una emoción, mientras que otros autores como Clore y Ortony (1988) consideraron innecesaria la identificación de la tendencia a la acción en algunas emociones.

Las tendencias a la acción se pueden ocultar o simplemente pueden no ser particularmente evidentes (por ejemplo, en el caso de la tristeza o la alegría), o pueden ser limitadas por reglas informales de comportamiento social que consideran inapropiado un comportamiento en una situación determinada (Vallerand y Blanchard, 2000).

Existen muy pocos estudios sistemáticos de las tendencias a la acción en los escenarios educativos presenciales y casi ninguno en escenarios educativos en línea, por ejemplo, Eynde y Turner en el 2006 afirmaron que un estudiante que siente vergüenza tiene tendencia a la acción como querer estar solo en un escenario presencial (Palmer, 2017).

Aún no se ha establecido si las emociones experimentadas por un estudiante durante una clase en línea pueden resultar en tendencias a la acción para el aprendizaje. Los profesores y los estudiantes se enfrentan a diversos desafíos emocionales durante las clases en línea. Para abordar estos desafíos, es fundamental que los profesores trabajen en la creación de un ambiente de apoyo y colaboración en línea. Además, deben proporcionar retroalimentación frecuente y alentadora a los estudiantes, ya que esto puede ayudar a identificar las tendencias a la acción para el aprendizaje y mantener a los estudiantes motivados y comprometidos con el proceso de enseñanza-aprendizaje en línea.

Según Hartnett (2016), uno de los principales desafíos que enfrentan los estudiantes durante las clases en línea es la falta de motivación. Esto puede ocurrir cuando se sienten desconectados, desinteresados en el material que se está presentando o experimentan una limitada retroalimentación inmediata por parte del profesor. La falta de motivación puede tener un impacto negativo en su capacidad para aprender y retener información, tal como señalan Manea et al. (2020) y Code et al. (2022).

En este sentido, Rodríguez-Galván et al. (2022) plantean como línea de investigación futura el empleo de la retroalimentación en diversas modalidades de enseñanza con el objetivo de regular las emociones de los estudiantes. Estos hallazgos permitirán iniciar acciones pedagógico-innovadoras que usen la tecnología para mediar componentes afectivos en procesos de retroalimentación y medir el impacto de las emociones a través de diferentes formatos en contextos de aprendizaje en línea.

Esta tesis se alinea con la investigación propuesta por Rodríguez-Galván et al. (2022), ampliando el enfoque centrado en las tendencias a la acción para el aprendizaje, que serán utilizadas como base para la retroalimentación en el proceso de enseñanza-aprendizaje. Además, en esta tesis se pretende desarrollar un modelo ubicuo basado en la semántica para el ámbito educativo, específicamente para las clases en línea, con el propósito de identificar las tendencias a la acción de los estudiantes. Mediante esta semántica, se buscará comprender y analizar cómo las emociones y las tendencias a la acción influyen en el proceso de aprendizaje, permitiendo así una retroalimentación más personalizada y efectiva para promover el éxito académico.

Dado que las clases en línea presentan desafíos particulares en comparación con las clases presenciales, como la dificultad para observar a todos los estudiantes debido al uso de cámaras, se hace necesario comprender su comportamiento, necesidades de aprendizaje y metodología de enseñanza de manera más efectiva.

Para ello, proponemos un modelo que facilitará la orquestación de las actividades llevadas a cabo por los profesores en las clases en línea y respaldará la toma de decisiones para abordar los problemas que enfrentan los estudiantes. Al finalizar una clase, el profesor se cuestiona cómo fue la experiencia de los estudiantes y cómo se sintieron con respecto al tema tratado. Con la implementación de este modelo, se proporcionará un valioso apoyo para la retroalimentación educativa del profesor, mejorando así la calidad del proceso de enseñanza-aprendizaje en entornos en línea, como se explica en la descripción de la investigación.

1.2. Descripción de la investigación

Según Ekman (1984), existen algunas emociones humanas básicas, como la felicidad, tristeza, ira, miedo, sorpresa, asco y desprecio, que son universales y se acompañan de expresiones faciales comunes en todas las culturas.

En el ámbito de las clases en línea, es fundamental reconocer y abordar los desafíos emocionales que tanto profesores como estudiantes enfrentan. Para lograr un entorno de apoyo y colaboración en línea, así como proporcionar retroalimentación efectiva a los estudiantes, es necesario comprender y analizar las emociones presentes durante el proceso de enseñanza-aprendizaje. Es en este contexto en el que se pretende desarrollar un modelo ubicuo de análisis emocional para las clases en línea.

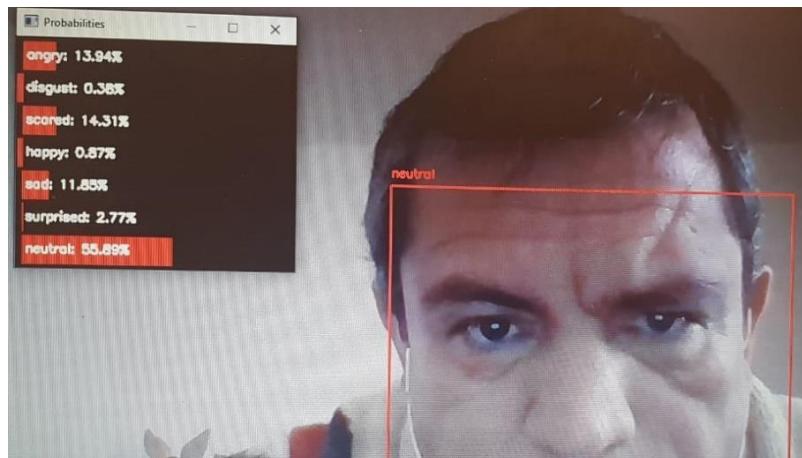


Figura 1 Software de reconocimiento de emociones en el rostro

Para alcanzar este objetivo, en primer lugar, se utiliza el software de reconocimiento de emociones¹ en el rostro para registrar las emociones con su porcentaje de ocurrencia (Figura 1), con una precisión del 66%. Este software demuestra una precisión superior al 60% en el reconocimiento de siete emociones humanas básicas en el rostro utilizando el conjunto de datos "Fer2013"². Este resultado prometedor sugiere la eficacia de las técnicas de deep learning empleadas en el software de reconocimiento de emociones, especialmente en un contexto donde la clasificación emocional es fundamental (Khanzada et al., 2004). Con este enfoque se puede capturar de manera precisa y objetiva las respuestas emocionales de los estudiantes durante las clases en línea.

A continuación, se recurre al Principio de Pareto conocido como la regla 80/20, que según Romania (2021) es un modelo matemático ampliamente utilizado, que establece que un pequeño porcentaje de factores tiene un impacto significativo en los resultados. Aplicado al análisis emocional en las clases en línea, el principio de Pareto se utiliza para identificar las emociones predominantes y determinar cuáles tienen mayor influencia en las clases en línea.

La aplicación de la regla 80/20 en este contexto específico sugiere que mejorar la calidad emocional se logra eficientemente al centrarse en un conjunto minoritario de emociones clave. Este enfoque estratégico puede traducirse en mejoras sustanciales en la experiencia emocional de los estudiantes. Se ha comprobado que existen emociones que potencian el aprendizaje como la alegría y la sorpresa y, otras que lo obstaculizan como la tristeza, el miedo, el susto y el enojo (Alzina, 2008).

¹ <https://github.com/omar-aymen/Emotion-recognition>

² https://github.com/oarriaga/face_classification

Por otra parte, para comprender mejor el comportamiento emocional y las tendencias a la acción en el contexto de las clases en línea, se emplea el algoritmo de agrupación KMEANS (Horvat et al., 2021). Este algoritmo permite agrupar las emociones básicas identificadas y crear clústeres emocionales, lo que facilitará posteriormente la interpretación semántica del comportamiento emocional de los estudiantes mediante la inferencia de las tendencias a la acción para el aprendizaje.

Para inferir las tendencias a la acción, se utiliza la ontología "Human Affective States and their Influences" (HASIO) que según Abaalkhail (2018) fue diseñada específicamente para describir y categorizar las experiencias emocionales del individuo. HASIO proporciona una base teórica sólida y una estructura formal para comprender y analizar las tendencias a la acción en el contexto educativo. Al aplicar HASIO a los clústeres emocionales generados, se obtiene una visión más profunda de cómo las emociones influyen en el comportamiento de los estudiantes en las clases en línea.

Finalmente, para validar y evaluar esta propuesta, participaron expertos en psicopedagogía, quienes observan los videos de las clases en línea e identificaron las tendencias a la acción más y menos frecuentes. El objetivo es verificar la correspondencia entre las tendencias identificadas por los expertos y la salida del razonador Pellet aplicado a la ontología HASIO. Esta validación garantiza que el modelo ubicuo de análisis emocional propuesto sea efectivo y confiable para brindar retroalimentación docente y mejorar el proceso de enseñanza-aprendizaje en las clases en línea.

En resumen, el modelo ubicuo semántico propuesto en esta tesis busca alcanzar diversos objetivos para lo cual se utilizará el software de reconocimiento de emociones, el principio de Pareto, el algoritmo de agrupación KMEANS y la ontología HASIO. Estos elementos se desglosan en objetivos que se describen a continuación.

1.3. Objetivos del trabajo

En la era digital, el aprendizaje en línea ha adquirido una relevancia significativa, proporcionando a estudiantes y educadores la oportunidad de participar en clases grabadas en video desde cualquier lugar y en cualquier momento. Sin embargo, la falta de interacción directa y la ausencia de señales no verbales dificultan la comprensión de las emociones y las tendencias a la acción de los estudiantes durante estas clases en línea. Comprender y capturar estas dimensiones emocionales es esencial para mejorar la calidad de la enseñanza y ofrecer retroalimentación efectiva.

De este modo nos acercamos a definir el objetivo principal de esta tesis mediante la identificación de las emociones predominantes, la creación de clústeres emocionales y la inferencia de tendencias a la acción relevantes, que mejoren la didáctica en las clases en línea y proporcionen retroalimentación valiosa. Se pretende crear un modelo que sea una herramienta poderosa tanto para educadores como para estudiantes, permitiéndoles adaptar su enfoque y promover un aprendizaje efectivo, enriqueciendo así la experiencia educativa en las clases en línea. A continuación, se describen los objetivos de esta investigación y se destaca la contribución de cada uno de ellos al desarrollo del modelo y a la retroalimentación educativa.

1.3.1 Objetivo Principal

En el ámbito educativo actual, las clases en línea han experimentado un crecimiento significativo, convirtiéndose en una alternativa viable y accesible para la enseñanza y el aprendizaje. Sin embargo, uno de los desafíos que enfrentan tanto los educadores como los estudiantes es la dificultad para capturar y comprender las interacciones emocionales y las tendencias a la acción que se producen durante estas clases en línea. La capacidad de registrar y comprender las emociones y las tendencias a la acción de los estudiantes puede proporcionar valiosa información para mejorar el proceso de enseñanza-aprendizaje y brindar una retroalimentación más efectiva.

En este contexto, el objetivo principal de este trabajo es desarrollar un ***modelo ubicuo semántico que permita el registro emocional y la inferencia de tendencias a la acción en el aprendizaje durante las clases en línea grabadas en video***. Este modelo tiene como propósito capturar y comprender las emociones presentes en las clases en línea, así como inferir las tendencias a la acción que los estudiantes realizan en respuesta a esas emociones.

El modelo propuesto combinará software de reconocimiento facial, procesamiento de imágenes y análisis de datos para identificar y registrar las emociones predominantes en una clase en línea. Esto permitirá comprender cómo las expresiones faciales de los estudiantes reflejan sus estados emocionales y cómo estas emociones influyen en su comportamiento emocional y acciones durante la clase en línea.

En adición, el modelo propuesto incorporará técnicas avanzadas de análisis de datos y minería de datos para generar clústeres emocionales, lo cual constituye una novedad en la investigación. Estos clústeres permitirán una interpretación semántica del comportamiento emocional de los estudiantes, proporcionando una visión más profunda y estructurada de las emociones expresadas. Por último, el modelo inferirá tendencias a la acción para el

aprendizaje para identificar comportamientos emocionales de los estudiantes durante las clases en línea.

Para alcanzar el objetivo principal, se define un conjunto de objetivos específicos detallados a continuación.

1.3.2 Las emociones predominantes

El primer objetivo específico de esta tesis es determinar las emociones predominantes en una clase en línea mediante la identificación automática de emociones en el rostro de los estudiantes. En las clases en línea, donde no hay una interacción directa y en persona entre el profesor y los estudiantes, es crucial comprender las emociones de los estudiantes para mejorar su experiencia de aprendizaje y brindar una retroalimentación efectiva.

Para lograr este objetivo, se utiliza tanto el software de reconocimiento de emociones en el rostro de los estudiantes como el principio de Pareto (Harvey y Sotardi, 2018). Se aprovecharán los avances en el campo del reconocimiento facial y el procesamiento de imágenes para detectar diferentes expresiones emocionales en los rostros de los estudiantes presentes en el video de la clase en línea.

El principio de Pareto sugiere que un pequeño conjunto de estados emocionales, que abarca aproximadamente el 20%, ejerce una influencia significativa en la mayoría de los resultados que inciden positiva o negativamente en el proceso de aprendizaje. Por ejemplo, estos estados emocionales pueden afectar a la participación del estudiante en clase y su habilidad para adquirir nuevos conocimientos (Alzina, 2008).

Determinar las emociones predominantes en una clase en línea es esencial para comprender cómo se sienten los estudiantes durante la sesión de aprendizaje. Esto permite a los profesores y tutores ajustar su enfoque pedagógico y brindar un apoyo emocional adecuado en función de las necesidades identificadas. Por ejemplo, si se detecta una alta presencia de emociones negativas como la frustración o el aburrimiento, los educadores pueden considerar cambiar el ritmo de la clase, emplear estrategias de participación más interactivas o proporcionar recursos adicionales para mantener el interés y la motivación de los estudiantes (Frijda, 1986).

Además, la identificación de emociones predominantes en una clase en línea puede ayudar a evaluar la efectividad de las estrategias de enseñanza utilizadas. Si se detecta una alta presencia de emociones positivas asociadas con la participación y el entusiasmo, esto puede indicar que las metodologías utilizadas están generando un ambiente de aprendizaje estimulante y atractivo.

1.3.3 Clusters emocionales

El segundo objetivo específico de esta tesis se centra en crear un enfoque que permita una interpretación semántica del comportamiento emocional. Para lograr esto, se llevará a cabo una agrupación de las diferentes emociones identificadas en grupos o clusters que posean un significado y una interpretación semántica específica. De esta manera, se busca proporcionar una estructura clara y comprensible para analizar y comprender las emociones expresadas en el contexto educativo.

El objetivo es crear clusters emocionales significativos que vayan más allá de la simple identificación de emociones individuales. Además, se busca comprender cómo influyen en el comportamiento emocional de los estudiantes.

Crear clusters emocionales que permitan una interpretación semántica del comportamiento emocional tiene varias aplicaciones prácticas. Por ejemplo, en el ámbito educativo, estos clústeres pueden ayudar a los profesores a comprender mejor las respuestas emocionales de los estudiantes y adaptar su enfoque de enseñanza para brindar un apoyo más efectivo. En el campo de la investigación psicológica, estos clústeres pueden proporcionar información valiosa para estudios sobre la salud mental, la calidad de vida y las interacciones sociales.

1.3.4 Tendencias a la acción

El tercer objetivo específico de esta tesis consiste en inferir tendencias a la acción para el aprendizaje, las cuales se obtienen a partir de los clústeres emocionales previamente establecidos. Estas tendencias a la acción son valiosas para proporcionar retroalimentación efectiva en el proceso de enseñanza-aprendizaje. Los educadores pueden utilizar esta información para adaptar su enfoque pedagógico, ofrecer intervenciones personalizadas y proporcionar retroalimentación específica a los estudiantes. Por ejemplo, si se detecta una tendencia de bajo compromiso en un tema en particular, el educador puede brindar recursos adicionales, actividades más interactivas o apoyo individualizado para ayudar al estudiante a superar las dificultades y mejorar su aprendizaje (Frijda, 1986; Rodríguez-Galván et al., 2022)

La inferencia de tendencias a la acción también puede servir como una herramienta de monitoreo del progreso y la efectividad del proceso de enseñanza-aprendizaje. Los educadores pueden evaluar el impacto de sus estrategias y ajustarlas en consecuencia para optimizar los resultados de aprendizaje de los estudiantes.

1.3.5 Hipótesis

Ho: Es posible inferir tendencias a la acción para el aprendizaje de los estudiantes en clases en línea a partir del registro de emociones básicas grabadas en video.

En otras palabras, se sostiene que, al examinar las emociones experimentadas por los estudiantes durante las clases en línea, se puede obtener información valiosa sobre cómo sus emociones influyen en su comportamiento emocional, motivación y participación en el proceso educativo. Esta hipótesis busca establecer una conexión significativa entre el análisis de las emociones y la identificación de tendencias a la acción que afectan el aprendizaje de los estudiantes en clases en línea. Para validar esta hipótesis, se aplica la metodología que se detalla a continuación que permite evaluar la viabilidad y la utilidad de este enfoque en el contexto de la educación en línea.

1.4. Metodología

En este estudio, nos enfocaremos en investigar cómo las emociones experimentadas por los estudiantes durante las clases en línea pueden influir en su comportamiento emocional en el proceso educativo. A través del análisis de las emociones básicas registradas en video, buscamos obtener información valiosa sobre las tendencias a la acción para el aprendizaje de los estudiantes.

Nuestro objetivo es comprender cómo las respuestas emocionales de los estudiantes en las clases en línea pueden ofrecer pistas sobre su nivel de involucramiento con la asignatura que están cursando, su respuesta a los desafíos y su motivación para participar activamente en su proceso de aprendizaje. Además, nos interesa examinar cómo estas emociones influyen en eventos a corto plazo, es decir, en situaciones específicas durante las clases en línea.

Para llevar a cabo este estudio, aplicaremos una metodología experimental que nos permitirá evaluar la viabilidad y utilidad de este enfoque en el contexto de la educación en línea. Analizaremos cuidadosamente las emociones de los estudiantes capturadas en los videos, buscando inferir un comportamiento emocional en situaciones específicas de las clases en línea. Al hacerlo, esperamos que los profesores obtengan una mayor comprensión de los distintos factores que influyen en la experiencia de aprendizaje de los estudiantes en clases en línea.

La metodología utilizada en esta investigación se basa en criterios rigurosos que orientaron la selección de fuentes bibliográficas pertinentes y de alta calidad. Estos criterios abarcaron diversos aspectos, como la relevancia del contenido, la actualidad de las publicaciones, la

reputación de las revistas o conferencias, la experiencia y el prestigio de los autores, así como la metodología empleada en los estudios. Estos criterios permitieron descartar aquellas fuentes que no cumplían con los estándares establecidos, y a su vez, aceptar aquellas que presentaban un respaldo sólido y confiable para el desarrollo de la investigación.

Se llevó a cabo una amplia revisión bibliográfica que incluyó la consulta de artículos científicos, libros y revistas especializadas en el campo. Esta exhaustiva investigación permitió recopilar información clave y actualizada de diversas fuentes, asegurando una sólida fundamentación para el desarrollo de la investigación. Para realizar el estado del arte, se realizó una exhaustiva búsqueda en bases de datos bibliográficas como IEEE Xplore, Scopus, ProQuest. Además, se consultaron específicamente las siguientes fuentes:

- International Journal of Interactive Multimedia and Artificial Intelligence
- Frontiers in psychology
- Computers & Education
- Advances in neural information processing systems
- Image and Vision Computing
- Canadian Journal of Science, Mathematics and Technology Education
- International Journal of Learning Technology
- Computers in Human Behavior
- International and Multidisciplinary Journal of Social Sciences
- European Journal of Psychology of Education
- Journal of the learning sciences
- IEEE Transactions on Learning Technologies
- IEEE Transactions on Industrial Electronics
- IEEE Transactions on Affective Computing
- Journal of Teacher Education
- International Journal of Educational Research
- Journal of the Association for Information Systems
- Journal of Positive Psychology and Wellbeing
- Journal of computational and applied mathematics
- Journal of Adolescent Health
- Journal of Interactive Multimedia and Artificial Intelligence

- Information Technology and People
- Evolution and Human Behavior
- Educational Psychology
- Revista de Psicología
- Revista Iberoamericana de Educación a Distancia
- Revista Complutense de Educación
- SEMERGEN - Medicina de Familia
- Telematics and Informatics
- Inteligencia emocional

Se utilizaron palabras clave relevantes para la temática, tales como “comportamiento emocional en clases en línea”, “tendencias a la acción”, “reconocimiento de emociones”, “clusters emocionales”, “modelo ubicuo”, “ontologías de la emoción humana” entre otras.

1.4.1 Recopilación de datos

La recopilación de datos se llevó a cabo mediante un enfoque que combinó métodos cuantitativos y cualitativos. Para garantizar la transparencia y el consentimiento informado de los participantes, se les proporcionó una descripción detallada del proceso de recolección de datos. Durante las clases en línea, se solicitó a los estudiantes que mantuvieran sus cámaras encendidas y se grabó en video únicamente el rostro de los participantes.

En cuanto a los datos cuantitativos, se recopilaron el número de videos registrados, el porcentaje de emociones capturadas en los rostros de los participantes, el número de emociones básicas identificadas y el número de clusters generados. Estos datos proporcionaron una visión cuantitativa de las emociones experimentadas por los estudiantes y su comportamiento emocional durante las clases en línea.

Para obtener los datos cualitativos, se utilizó un software especializado en la identificación de emociones simples. Este software permitió un análisis objetivo de las expresiones faciales de los estudiantes, lo que facilitó la determinación de las emociones presentes en cada momento, así como la inferencia de tendencias a la acción en la ontología. Además, se complementó con la observación y registro de expertos, quienes aportaron sus perspectivas y observaciones relevantes durante el análisis de los videos.

La combinación de datos cuantitativos y cualitativos en este estudio permitió obtener una visión más completa y enriquecedora de las emociones experimentadas por los estudiantes durante las clases en línea, así como de las tendencias a la acción que se pudieron inferir a partir de ellas.

1.4.2 Aporte metodológico

Se utilizaron herramientas y técnicas de investigación adecuadas para la recopilación y el análisis de los datos, como software de reconocimiento de emociones, curvas ROC, principio de Pareto, algoritmo KMEANS, ontologías, índice de Kappa entre las más importantes.

Primeramente, se informó a los estudiantes sobre la grabación de las clases en línea y el registro de sus emociones faciales. El software de reconocimiento de emociones se utilizó para detectar y registrar las emociones en los rostros de los participantes, generando un archivo con el conjunto de emociones y sus respectivos porcentajes. El experimento se llevó a cabo en la Universidad Técnica de Ambato durante el confinamiento causado por la pandemia del COVID-19. Los estudiantes fueron informados sobre los procedimientos y dieron su consentimiento para grabar sus rostros durante las clases en líneas. El estudio contó con la aprobación del Comité de Ética de la Universidad.

Para evaluar los resultados del sistema de reconocimiento de emociones Emotion Recognition, se utiliza las curvas ROC (Receiver Operating Characteristic) para cada uno de los participantes. Las curvas ROC son una forma útil de evaluar la precisión de las predicciones del software al trazar la sensibilidad frente a la especificidad de una prueba de clasificación (Gneiting y Vogel, 2018).

Posteriormente, se aplicó el principio de Pareto para determinar las emociones predominantes durante las clases en línea. Luego, el algoritmo KMEANS se empleó para agrupar las emociones básicas y crear clusters emocionales. La emoción con mayor porcentaje se asignó como representativa del cluster. Así mismo, si el porcentaje de la emoción supera la mediana de los datos, se la asigna como característica MAYOR, caso contrario como característica MENOR. Esta clasificación fue solicitada por los expertos para facilitar su análisis posterior.

Estos clusters fueron instanciados en la ontología HASIO, utilizando el razonador Pellet para inferir la tendencia a la acción, reflejada en una instancia de la clase Frijda_Action_Tendency de la ontología. Si una emoción clasificada como característica MAYOR produce mediante axiomas un Action_Tendency esta será clasificada como característica MAYOR, o MENOR en caso contrario.

Como se ha hecho en otros estudios (Raes et al., 2020), es necesario contar con dos expertos en psicopedagogía para el análisis. Estos expertos observan los videos de las clases en línea y registraron tendencias a la acción como característica MAYOR o MENOR. Se mide el nivel de acuerdo entre los expertos a través del índice Kappa que sirve para comparar la concordancia entre observadores en un conjunto de datos, respecto a la que podría ocurrir por simple azar (Abraira, 2001).

Para evaluar los resultados semánticos de la ontología, se compara las características emocionales MAYORES y MENORES identificadas por los expertos con el resultado obtenido de la clase Fridja_Action_Tendency de la ontología. Es fundamental evaluar el grado de concordancia entre los expertos. Para este propósito, se recurre al coeficiente de Kappa, el cual ayuda a determinar si existe un acuerdo significativo entre los expertos, así como entre la ontología y los expertos, superando lo que podría atribuirse al azar.

1.5. Conclusiones

Esta investigación propone como objetivo principal el desarrollo de un modelo ubicuo semántico para el registro y análisis de emociones e inferencia de las tendencias a la acción para el aprendizaje en clases en línea grabadas en video. Para lograrlo, se emplea el software Emotion Recognition, evaluando los resultados mediante curvas ROC y contando con la participación de expertos en psicopedagogía. Además, se utiliza el algoritmo KMEANS para la creación de clusters emocionales que se instancian en una ontología (HASIO) para un análisis semántico de las emociones y la inferencia de tendencias a la acción, lo que beneficiará tanto a los educadores como a los estudiantes en su búsqueda de un aprendizaje más significativo y enriquecedor.

Pero, se pretende ir más allá de la mera detección de emociones superficiales, abordando su significado y su influencia en el aprendizaje. Se pretende proporcionar a los profesores y tutores de una comprensión más profunda de las emociones mediante la inferencia de tendencias a la acción para el aprendizaje de los estudiantes, lo que permitirá mejorar la retroalimentación y la experiencia de enseñanza-aprendizaje en clases en línea otorgando a los educadores una herramienta invaluable para adaptar su enfoque pedagógico y proporcionar un apoyo más efectivo a los estudiantes.

El objetivo específico de determinar las emociones predominantes en una clase en línea mediante la identificación de emociones en el rostro de los estudiantes busca obtener información valiosa sobre el estado emocional de los estudiantes durante el proceso de aprendizaje. Esto proporciona una base sólida para adaptar y mejorar las estrategias de

enseñanza, brindar apoyo emocional y promover un entorno de aprendizaje en línea más efectivo y favorable para el desarrollo académico y emocional de los estudiantes.

El objetivo específico de crear clústeres es obtener grupos de comportamientos emocionales que permitan una interpretación semántica del comportamiento emocional. Esta aproximación brinda una visión más completa del comportamiento emocional y sus implicaciones, lo cual a su vez puede contribuir a la mejora de áreas fundamentales como la educación, la salud mental y la investigación psicológica.

Por último, el objetivo específico de inferir tendencias a la acción para el aprendizaje busca analizar y comprender los comportamientos de los estudiantes en clases en línea grabadas en video. Estas tendencias proporcionan información valiosa para mejorar la retroalimentación, adaptar las estrategias de enseñanza y monitorear el progreso del aprendizaje. Al utilizar esta información de manera efectiva, los educadores pueden brindar una educación más personalizada y mejorar la experiencia de aprendizaje de los estudiantes.

En el siguiente apartado, se presentará el estado del arte relacionado con el comportamiento emocional en clases en línea, donde se revisarán investigaciones previas y se resumirán los avances y enfoques relevantes en el campo.

Los próximos capítulos, se enfocarán en la consecución de los objetivos específicos establecidos para desarrollar un modelo ubicuo semántico de registro emocional e inferencia de tendencias a la acción en clases en línea grabadas en video. Se abordará cada objetivo de manera detallada, presentando los métodos, técnicas y resultados de la investigación.

CAPÍTULO II. ESTADO DEL ARTE

En este capítulo, se llevará a cabo una exhaustiva revisión del estado del arte en el campo de investigación relacionado con las técnicas utilizadas en el presente estudio. Este análisis servirá como base para la discusión y fundamentación de la propuesta planteada, que se centra en el desarrollo de un modelo ubicuo para el análisis emocional en clases en línea.

En particular, se explorará el uso de software de procesamiento de señales de video para el registro de emociones básicas en las clases en línea. Además, se analizará cómo el principio de Pareto puede ser utilizado para identificar las emociones predominantes en este tipo de entornos. Asimismo, se examinará cómo el algoritmo KMEANS ha sido empleado para agrupar las emociones y crear clústeres emocionales que permitan inferir tendencias a la acción con el objetivo de analizar en detalle las respuestas emocionales de los estudiantes. Por último, se investigará el uso de ontologías, en particular la ontología HASIO, para representar y modelar el comportamiento emocional en las clases en línea.

Mediante el análisis de estos trabajos previos, se buscará desarrollar un modelo integral y semántico para el análisis de emociones y comportamientos en el contexto de las clases en línea, aprovechando las técnicas y enfoques exitosos utilizados en investigaciones anteriores.

2.1. Influencias principales

Las investigaciones de los autores mencionados en la Tabla 1 se refieren al manejo emocional y comportamiento humano en entornos educativos en línea y mixtos y que fueron tomados como referencia para plantear la hipótesis de investigación.

Tabla 1. Investigaciones sobre el manejo emocional y comportamiento humano en entornos educativos en línea

Autor	Propuesta
(Palmer, 2017)	Define que una emoción está a menudo acompañada por una tendencia a la acción que es altamente predictiva del comportamiento humano.
(Clore y Ortony, 1988)	Consideraron innecesaria la identificación de la tendencia a la acción en algunas emociones.
(Frijda, 1986)	Sostiene que la tendencia a la acción es la parte central o núcleo de una emoción.

(Petrova et al., 2020)	Predicción del comportamiento humano mediante estados de ánimo globales en análisis unimodales.
(Raes et al., 2020)	Análisis de entornos de aprendizaje y su afectación emocional a los estudiantes en contextos síncronos. Permite comparar las experiencias presenciales y síncronas con el fin de obtener métodos mixtos de mediación. Mide el proceso de motivación en las clases y retroalimenta a los profesores.
(Behnagh, 2020)	Identificación de los constructos y energía emocional, con el objetivo del control de las emociones basado en el registro emocional en videos. El resultado muestra los méritos y efectos de las emociones con el objetivo de ser aplicados en la educación científica.
(Kaviani et al., 2020)	Valoración de las experiencias de aprendizaje y la relación con el método de enseñanza del profesor y el trabajo con elementos motivacionales.
Wang et al. (2020)	Ánalisis de sentimientos basado en agrupamiento de palabras (WCSA) utilizando modelos con diferentes niveles de granularidad.

Palmer (2017) examina la “tendencia a la acción para el aprendizaje” en contextos de enseñanza regulares. La tendencia a la acción para el aprendizaje se refiere a la disposición o inclinación de un estudiante a tomar medidas activas para aprender y mejorar su desempeño académico. Palmer presenta evidencia de que la tendencia a la acción para el aprendizaje es un constructo válido y útil para entender el aprendizaje en la educación. Palmer también discute los antecedentes de la tendencia a la acción para el aprendizaje, que incluyen tanto factores internos (como la autoeficacia, la autoestima y las metas de aprendizaje) como factores externos (como el apoyo social y el ambiente de aprendizaje). En particular, destaca la importancia de los profesores y su capacidad para fomentar y apoyar la tendencia a la acción para el aprendizaje en los estudiantes. **El presente trabajo de investigación propone encontrar tendencias a la acción para el aprendizaje, pero en contextos de enseñanza en línea como constructo válido para este proceso de enseñanza-aprendizaje.**

Clore y Ortony (1988) mencionan que las emociones a veces se expresan facialmente, pero no todas las expresiones faciales indican emociones. Si partimos desde el punto de vista de

Palmer, que dice que una emoción está a menudo acompañada por una tendencia a la acción, y el de Frijda, que manifiesta que la tendencia a la acción es la parte central o núcleo de una emoción, podríamos concluir que según Clore y Ortony algunas expresiones faciales no registran una tendencia a la acción.

Y si a esto le sumamos lo que dice Palmer (2017) acerca de que existen muy pocos estudios sistemáticos de las tendencias a la acción en los escenarios educativos presenciales y casi ninguno en escenarios educativos en línea, esto nos da como resultado el investigar qué sucede en las clases en línea; **¿Se pueden registrar emociones y tendencias a la acción para el aprendizaje en clases en línea? ¿El registro de emociones y tendencias a la acción en el rostro de los estudiantes en clase en línea contribuye a mejorar el proceso de enseñanza-aprendizaje?** El presente trabajo de investigación intenta responder a estas preguntas, y plantea como posible solución el modelo ubicuo.

Frijda (1986), aborda el tema de las emociones desde una perspectiva psicológica. Define las emociones como "respuestas evaluativas a eventos significativos para el individuo". Según él, las emociones son estados internos que se originan a partir de la evaluación que hace una persona de su entorno y de su propia situación. Frijda también distingue entre emociones primarias y secundarias.

Las emociones primarias son las respuestas inmediatas y automáticas que se experimentan ante un evento significativo, como el miedo, la ira o la alegría. Las emociones secundarias son respuestas más complejas y elaboradas que se originan a partir de las emociones primarias y están relacionadas con la percepción de la propia identidad y la evaluación de los valores. El autor también destaca la importancia de la expresión emocional. Según Frijda, la expresión emocional es una parte importante de la regulación social y de la relación interpersonal. **El presente trabajo de investigación está basado en la obra de Nico Frijda ya que se aborda desde lo que es una emoción hasta la tendencia a la acción que se inferirá en una clase en línea.**

Petrova et al. (2020) y otros investigadores proponen un enfoque de reconocimiento de emociones presencial en grupo que es seguro para la privacidad, **pero no hace un tratamiento individual que sí se aborda en la presente propuesta.** El enfoque utiliza la actividad fisiológica de un grupo de personas, como la variabilidad de la frecuencia cardíaca, para inferir la emoción general del grupo. Los autores realizan experimentos utilizando datos de sensores fisiológicos y vídeos de grupos de personas que interactúan en situaciones sociales presenciales, como jugar juegos de mesa y discutir temas de actualidad. Los resultados muestran que el enfoque propuesto puede detectar emociones en grupos con

una precisión significativa, incluso en situaciones en las que los individuos tienen diferentes emociones.

El presente trabajo de investigación utiliza un método innovador no invasivo para reconocer emociones ya sea de manera grupal como individual en un contexto educativo en donde las emociones afloran, pero sobre todo en clases en línea en donde es difícil tener un control emocional de los estudiantes.

Raes et al. (2020) se centran en investigar la implicación de los estudiantes en el aprendizaje y la efectividad de las pruebas en el contexto de un aula en línea híbrida. Aula en línea híbrida comprende un grupo de estudiantes que participa en el curso presencialmente en el campus y, simultáneamente, otros alumnos participan en el curso de forma remota desde una ubicación de su propia elección conectándose a la misma plataforma y clase. Los resultados indican que los estudiantes estaban comprometidos en el aula en línea, pero que la efectividad de las pruebas dependía de la frecuencia y el momento en que se administraban. También señalan que la implementación exitosa de un aula en línea híbrida requiere una planificación cuidadosa y una estrategia pedagógica sólida.

El presente trabajo de investigación plantea un modelo ubicuo de registro y análisis de emociones en cualquier momento de la clase y en cualquier actividad que el profesor haya planificado, e inferir tendencias a la acción para el aprendizaje en clases en línea.

Behnagh (2020) presenta un método de reducción de dimensionalidad para analizar el comportamiento de los estudiantes en cursos en línea masivos y abiertos (MOOCs). El objetivo es predecir el abandono de los cursos. Esto ofrece una herramienta efectiva para analizar el comportamiento de los estudiantes en MOOCs y tomar medidas preventivas para mejorar la retención.

El presente trabajo de investigación puede ser utilizado para prevenir los abandonos y deserción estudiantil en cursos en línea mediante una herramienta de retroalimentación efectiva y personalizada como lo es el modelo ubicuo de análisis de emociones que permite inferir tendencias a la acción emocionales que sirven de base para la retroalimentación del proceso de enseñanza-aprendizaje.

Kaviani et al. (2020) describe el impacto de la pandemia de COVID-19 en la enseñanza y el aprendizaje a nivel mundial. Adoptan un enfoque ecológico para examinar las interacciones entre los diferentes niveles del sistema educativo y cómo se han visto afectadas por la pandemia. Se destaca la rápida adaptación de educadores y estudiantes a nuevas formas de enseñanza y aprendizaje utilizando tecnologías digitales y de comunicación en línea. Kaviani

resalta la importancia de considerar factores sociales, económicos y culturales, y cómo la pandemia ha impactado de manera desigual a estudiantes y comunidades vulnerables. Se aboga por un enfoque integral que aborde estos desafíos educativos durante la pandemia. En resumen, el artículo enfatiza la necesidad de un enfoque integral y ecológico para abordar los desafíos educativos y sus impactos en diferentes niveles y grupos de estudiantes y comunidades.

El presente trabajo de investigación analizará el contexto de educación en línea centrándose en los desafíos emocionales que enfrentan los involucrados ya que las emociones en el rostro de los estudiantes hablan mucho de lo que está viviendo en ese momento el estudiante en el aula de clase en línea, es decir, desde un enfoque emocional analizamos el registro de las emociones que transcurren en la clase en línea e inferimos su comportamiento.

Wang et al. (2020) proponen un enfoque preciso de detección de sentimientos en múltiples niveles que considera la ambivalencia en los textos. Introducen una técnica llamada Análisis de Sentimientos basado en Agrupamiento de Palabras (WCSA), que categoriza las palabras en clústeres y calcula la polaridad de cada clúster en lugar de la polaridad individual de cada palabra. Luego, presentan una técnica de análisis de sentimientos en varios niveles que utiliza modelos diseñados para diferentes niveles de granularidad, desde oraciones completas hasta palabras individuales. Los resultados de cada modelo se combinan para obtener una evaluación general del sentimiento del texto, y se aplica una ponderación de la polaridad para considerar la importancia de las diferentes opiniones. Este enfoque permite detectar sentimientos en textos complejos, teniendo en cuenta la ambivalencia y la complejidad de las emociones y opiniones expresadas.

El presente trabajo de investigación trabajará con imágenes de video en donde se reconocen las emociones en el rostro de los participantes que delatan lo que en realidad está sintiendo el estudiante en un momento determinado de la clase.

2.2. Emociones humanas y aprendizaje en línea

El estudio de las emociones en los seres humanos ha sido tradicionalmente un área de interés en disciplinas como la psicología y la sociología. La interacción social se basa en nuestra capacidad para comunicar y percibir emociones en los demás. La expresión de las emociones es una forma de regular nuestras reacciones afectivas, manifestándose a través de gestos y movimientos. Sin embargo, las emociones tienen una dimensión más amplia y no son meramente subjetivas. Entre las distintas formas de expresar emociones, la expresión facial es especialmente característica. Por ejemplo, cuando preparamos una

conferencia, solemos centrarnos en el discurso y no en los gestos, pero cada gesto revela una emoción (Chen et al., 2019).

El estudio de las emociones humanas en el contexto del aprendizaje en línea ha adquirido una gran relevancia en los últimos años. Comprender cómo las emociones influyen en el proceso educativo es fundamental para mejorar la experiencia de aprendizaje de los estudiantes. Investigaciones recientes han explorado el impacto de las emociones en el rendimiento académico, la motivación y la retención de conocimientos (Evanger et al., 2023). Además, se ha estudiado cómo las emociones pueden afectar la interacción entre estudiantes y profesores, así como la colaboración y participación en entornos virtuales de aprendizaje (Shinwari et al., 2023).

En el aprendizaje en línea, donde la interacción directa entre estudiantes y profesores puede ser limitada, las emociones adquieren una importancia aún mayor. Las emociones positivas, como el interés y la alegría, han demostrado promover un mayor compromiso y una mayor retención de la información. Por otro lado, las emociones negativas, como la frustración y la ansiedad, pueden obstaculizar el proceso de aprendizaje. Es por eso por lo que es crucial desarrollar estrategias y herramientas que puedan detectar y comprender las emociones de los estudiantes en clases en línea (Alzina, 2008).

El uso de ontologías y el análisis semántico se ha identificado como una tendencia prometedora en la detección y comprensión de las emociones en clases en línea. Estas ontologías permiten la representación formal y estructurada de las emociones, lo que facilita su análisis y la toma de decisiones en tiempo real. Además, la tendencia a la acción en clases en línea se enfoca en utilizar la información emocional captada para ofrecer retroalimentación y adaptar las actividades y el contenido del aprendizaje de acuerdo con las necesidades y preferencias de cada estudiante, mejorando así la calidad y la personalización de la educación en línea.

2.2.1 Estudios de las emociones

La comprensión de las emociones en el contexto del aprendizaje es un tema relevante, ya que las emociones pueden manifestarse como estados de ánimo, actitudes o rasgos de personalidad (Castillo y Neff, 2019). Según Ekman (1984), algunas emociones humanas básicas, como la felicidad, tristeza, ira, miedo, sorpresa, asco y desprecio, son innatas y compartidas por todos, y están acompañadas en todas las culturas por expresiones faciales universales. Estas emociones tienen un carácter marcadamente biológico y hereditario. Es especialmente interesante explorar las emociones experimentadas por los estudiantes durante las actividades de aprendizaje, ya que estas pueden reflejar su actitud hacia la tarea

y su bienestar emocional. La interacción y el manejo de las emociones desempeñan un papel importante en la memoria y el aprendizaje, ya que las emociones pueden tener un impacto directo en ellos. Además, se ha observado que la intensidad y la naturaleza de los estímulos emocionales influyen en la activación del aprendizaje, adaptándose al desafío que representa la comprensión de nuevos conocimientos.

Por otro lado, la retroalimentación facial también juega un papel crucial en las interacciones emocionales. La hipótesis de la retroalimentación facial sostiene que las expresiones faciales pueden influir en la experiencia emocional de una persona y en cómo interpreta las emociones de los demás. Por ejemplo, una expresión facial específica puede activar y reforzar estados emocionales correspondientes en una persona, lo que a su vez puede influir en sus comportamientos emocionales e interacciones sociales. La sonrisa, por ejemplo, puede generar sentimientos de felicidad y transmitir amabilidad y accesibilidad a los demás. Por lo tanto, la retroalimentación facial desempeña un papel crucial en el desarrollo y mantenimiento de las emociones y las interacciones emocionales en las relaciones interpersonales (Rebollo Catalán et al., 2014).

Estos conceptos están respaldados por estudios que han demostrado la replicabilidad del efecto de la retroalimentación facial en entornos educativos y están en línea con las teorías de la expresión emocional, donde los estados emocionales internos y los comportamientos emocionales externos son influenciados por otros individuos (Marsh et al., 2019).

En los últimos años, ha habido avances significativos en la investigación sobre el reconocimiento automático de emociones. Inicialmente, se enfocaba en emociones básicas como alegría, sorpresa, ira, tristeza, miedo y desagrado (Castillo y Neff, 2019). Sin embargo, este enfoque se ha ampliado hacia un conjunto más amplio de emociones. Por ejemplo, investigaciones han demostrado que es posible combinar movimientos musculares observados en rostros alegres y sorprendidos para crear una expresión facial que represente una emoción combinada de alegría-sorpresa (Shichuan et al., 2014). Algunas de estas emociones están relacionadas y comparten patrones de reconocimiento facial. La expresión facial, en particular, ha demostrado ser un indicador crucial de los estados emocionales y se ha utilizado como un descriptor importante en el reconocimiento de emociones (Plutchik, 2001).

El reconocimiento de emociones ha ganado atención tanto en comunidades en línea como en organizaciones comerciales. Los expertos en el campo están trabajando en el avance de esta técnica, que utiliza clasificadores de aprendizaje automático, como bosque aleatorio, SVM, regresión logística, Xgboost, clasificador SGD, Naïve Bayesian y KNN, para clasificar el

texto en diferentes emociones, como alegría, miedo, tristeza, vergüenza y culpa. Una vez clasificado, el texto se divide en diferentes categorías emocionales (Zubair et al., 2020).

Aunque los algoritmos computacionales han demostrado una capacidad variable para clasificar las emociones básicas, con una precisión que oscila entre el 60% y el 80%, se requiere una estructura semántica sólida para lograr una identificación más efectiva del estado de ánimo (Cabada et al., 2019; Pal et al., 2020).

2.2.2 Emociones en el proceso de aprendizaje

El aprendizaje emocional ha sido ampliamente estudiado como un elemento fundamental en las clases presenciales (Meyers et al., 2019). Sin embargo, el funcionamiento de este aprendizaje en las clases en línea aún se encuentra en proceso de investigación (Humphry y Hampden-Thompson, 2019).

El factor emocional del profesor, respaldado por el diálogo, influye en los estudiantes al trabajar con sus contribuciones, compromiso metacognitivo y razonamientos, lo que permite verificar el dominio del tema y mejorar las actitudes hacia el aprendizaje (Howe et al., 2019). La relación entre las percepciones de los estudiantes acerca de los demás y la percepción del profesor sobre los estudiantes indica que existen correlaciones significativas que pueden modificar actitudes e incluso el estilo de aprendizaje (Russo y Benson, 2005). Por lo tanto, la estrategia de comunicación que el profesor utiliza en el entorno en línea repercute en la experiencia de aprendizaje de los estudiantes.

La presencia del profesor en el proceso de enseñanza-aprendizaje va más allá de compartir conocimientos y creencias; también implica establecer una conexión emocional con los estudiantes (García-Cabrero et al., 2018). A medida que se desarrollan las relaciones afectivas, basadas en la expresión emocional, la comunicación abierta y la cohesión grupal, se fortalece la conexión entre el profesor y los estudiantes. En entornos virtuales, estas relaciones emocionales se vuelven aún más relevantes, ya que la proximidad afectiva se vuelve más importante que la proximidad física, lo que puede generar un contagio emocional.

Identificar los momentos o temas que provocan cambios o contagios emocionales resulta especialmente interesante, ya que esto permite recomendar la mejor manera de abordar el proceso de enseñanza y cómo el profesor puede transmitir su conocimiento de manera efectiva a los estudiantes (Deldjoo et al., 2020).

Durante el proceso de enseñanza-aprendizaje, es fundamental tener en cuenta los cambios emocionales, ya que el nivel de aprendizaje se basa en ellos (Hokka et al., 2019). Tanto el

aprendizaje asincrónico como el sincrónico deben centrarse en el estudiante, ya que se trata de un aprendizaje atemporal y no espacial. La inclusión de robots en las clases ha demostrado ser una forma efectiva de mejorar el proceso de aprendizaje y promover emociones positivas en los estudiantes. De hecho, se ha observado que el 80% de los participantes experimentan una mejora en su concentración cuando se utilizan robots en el aula. Estos resultados se han obtenido mediante el análisis de los rostros de los participantes, lo que demuestra que el estudio de las expresiones faciales es una herramienta confiable para comprender mejor el proceso emocional de los estudiantes durante el desarrollo de una clase (Gomez et al., 2019).

En este sentido, Datcu y Rothkrantz (2011) propusieron un sistema bimodal de reconocimiento de emociones que combina la lectura de expresiones faciales y el análisis del discurso. Este sistema utiliza modelos ocultos de Markov (HMM) para describir la dinámica temporal de las emociones en los canales visuales y acústicos. El análisis estadístico y el uso de algoritmos de minería de datos permiten identificar cómo se registran las emociones en el proceso de enseñanza-aprendizaje (Azevedo y Gasevic, 2019). Por ejemplo, el uso de tutorías inteligentes facilita la interacción con los procesos cognitivos, lo que se refleja en las emociones experimentadas durante el aprendizaje. Gracias a estas técnicas, es posible obtener una comprensión más profunda de cómo las emociones influyen en el proceso educativo y cómo pueden utilizarse para mejorar el rendimiento de los estudiantes.

Las emociones experimentadas por los estudiantes y sus efectos en las clases en línea son evaluadas por modelos lineales jerárquicos aplicados a diferentes grupos de aprendizaje lo que ayuda a verificar la capacidad de respuesta y el alcance de los profesores durante el proceso de enseñanza-aprendizaje (Hennessey y Humphrey, 2019).

Es así, que las emociones experimentadas por los estudiantes dependen de las estrategias de enseñanza preferidas por los profesores cuando utilizan entornos virtuales de aprendizaje. En base a ello se identifican patrones de agrupamiento entre los estudiantes centrados en la confianza lo que puede tener un impacto emocional positivo en los estudiantes y proporcionar estrategias de enseñanza a los profesores formadores para mejorar la calidad del proceso (Ledger et al., 2019).

Por tanto, para mejorar la experiencia de aprendizaje, es crucial comprender y analizar las emociones que experimentan los estudiantes en el aula. Un estudio realizado por Ruiz et al. (2020) desarrolló un modelo de predicción del comportamiento emocional humano utilizando técnicas como la correlación y el análisis de componentes principales. Los

resultados revelaron que este modelo permitió identificar diferentes tipos de comportamiento emocional en el proceso de enseñanza-aprendizaje. Además, se encontró que el feedback proporcionado por los estudiantes puede ser una valiosa fuente de información para mejorar la experiencia de aprendizaje. Estos hallazgos resaltan la importancia de prestar atención a las emociones de los estudiantes y emplear enfoques innovadores para mejorar la calidad del proceso de enseñanza-aprendizaje.

2.2.3 Emociones en el aprendizaje en línea

En el contexto en línea, las relaciones emocionales adquieren una mayor importancia que la proximidad física, lo que genera un contagio emocional significativo en el proceso de aprendizaje. Sin embargo, en estos contextos en línea es crucial que la estructura tecnológica funcione adecuadamente para poder percibir el afecto emocional. Por ejemplo, cuando los estudiantes encienden la cámara de su computadora, se interpreta como una participación activa, ya que permite reconocer y comprender las emociones (Sánchez y Duarte, 2020).

El cambio de una enseñanza tradicional a una modalidad en línea puede provocar sentimientos de inseguridad, melancolía e incertidumbre, incluso afectando las prácticas profesionales. La inseguridad inherente al proceso en línea puede alejar a los estudiantes del proceso formativo, desmotivando su aprendizaje, especialmente debido a la variabilidad en las metodologías de evaluación. A pesar de estos desafíos, los estudiantes desarrollan estrategias para superar los sentimientos negativos, aunque a menudo acompañados de nostalgia (González-Calvo et al., 2020).

Para hacer frente a estos cambios, resulta fundamental que los profesores utilicen técnicas adecuadas. Además, transmitir emociones espejo, es decir, las emociones propias del profesor que estimulan la comprensión por parte de los estudiantes se vuelve esencial en una clase en línea, ya que las emociones varían según el tema de estudio que se aborde (Kateb y Ali, 2020).

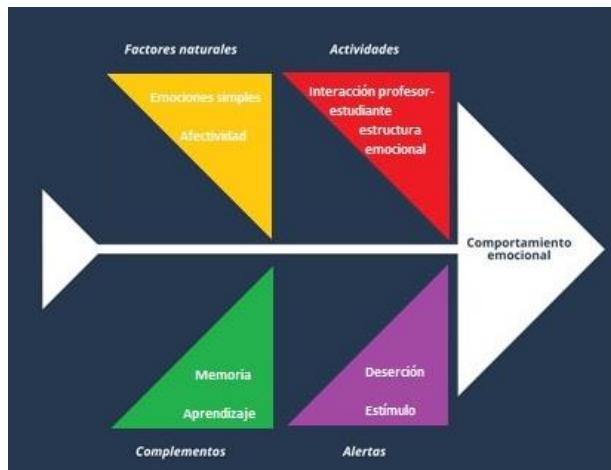


Figura 2 Aparataje emocional en el aula

La Figura 2 representa la línea base del aparataje emocional en el entorno educativo, ya sea en el aula presencial o en línea, y su conclusión es la interpretación semántica del comportamiento emocional. Tanto los estudiantes como los profesores interactúan en este contexto, y esta interacción está estrechamente relacionada con el factor emocional, que comienza con las emociones básicas y evoluciona hacia tendencias a la acción para el aprendizaje. En la actualidad, los procesos de aprendizaje se están llevando a cabo principalmente en entornos en línea, lo que permite incluso una mayor flexibilidad y la implementación de sistemas inteligentes personalizados adaptados al modelo educativo (Cui y Gou, 2019).

En el contexto de las clases en línea, las emociones básicas pueden manifestarse de diversas formas, como expresiones faciales, texto o voz. Es crucial comprender que estas emociones pueden agruparse y tener un impacto en el comportamiento emocional de los participantes. Esta dinámica permite observar si el entorno está afectando positiva o negativamente a los estudiantes y si estos forman parte de la estructura emocional del entorno (Stark et al., 2018).

El cambio de un modelo educativo presencial tradicional a un entorno de aprendizaje en línea requiere de una adecuada gestión emocional que demuestre la viabilidad y mejora de este nuevo entorno. Las críticas sobre la aplicabilidad de la educación en línea evidencian una disposición hacia el cambio tecnológico y la posibilidad de que este pueda facilitar la interacción entre profesores y estudiantes (Liaw et al., 2018).

Surgen preguntas sobre si la atención, las emociones y los métodos de enseñanza son los mismos en las clases en línea en comparación con las clases presenciales, y si las estrategias de aprendizaje tienen el mismo efecto. Por ejemplo, ¿las estrategias del profesor y su estado emocional influyen de la misma manera en las clases en línea que en las presenciales? La

respuesta puede parecer evidente según la teoría, que indica que las emociones son un factor clave en el aprendizaje. Sin embargo, en el entorno de aprendizaje en línea, donde los estudiantes dependen en gran medida del autoaprendizaje, se deben analizar las emociones individuales de los participantes y cómo estas afectan a su experiencia de aprendizaje (Schunk et al., 2021).

En el aprendizaje en línea, donde los estudiantes no reciben una supervisión emocional directa por parte del profesor, las redes neuronales convolucionales han demostrado ser capaces de clasificar las emociones de los estudiantes durante el proceso de aprendizaje. Estas redes pueden determinar si las emociones son negativas y, en base a ello, recomendar al profesor que adapte el contenido de enseñanza para abordar las necesidades emocionales de los estudiantes (Hingu et al., 2019).

2.3. Herramientas de análisis

Esta sección explora las herramientas de análisis utilizadas para identificar emociones en el aprendizaje en línea. Destacan entre estas herramientas el software de procesamiento de señales de video, crucial en campos como la visión computacional, la inteligencia artificial y la transmisión de medios digitales. Además, se abordan el análisis del principio de Pareto y el algoritmo de agrupamiento KMEANS, empleados para analizar y comprender las emociones experimentadas por los estudiantes durante las clases en línea.

A lo largo de los años, ha habido un gran avance en el desarrollo de técnicas para analizar, manipular y comprender contenido visual en forma de video. El reconocimiento de acciones humanas en videos es esencial para aplicaciones como la vigilancia inteligente y la interacción humano-computadora. Se utilizan técnicas de aprendizaje profundo y modelos de espacio-tiempo para reconocer actividades humanas (Simonyan y Zisserman, 2014). Así mismo, la super resolución de video se refiere al proceso de aumentar la resolución espacial de un video. Métodos como el uso de redes neuronales convolucionales profundas han demostrado ser efectivos para mejorar la calidad visual de videos de baja resolución (Tao et al., 2017). A la vez, el análisis de sentimientos en video implica detectar y reconocer expresiones faciales y emociones humanas en secuencias de video. Se utilizan técnicas de procesamiento de imágenes y aprendizaje automático para este propósito (Kossaifi, 2017).

El análisis de Pareto permite identificar y priorizar las emociones más relevantes y frecuentes en un conjunto de datos, brindando una visión general de las experiencias emocionales de los estudiantes. Por su parte, el algoritmo KMEANS facilita la agrupación de las emociones en clusters, lo que permite identificar comportamientos emocionales en los

estudiantes y proporcionar información valiosa para la mejora de los entornos de aprendizaje en línea. A través de esta sección, exploraremos cómo estas herramientas de análisis han contribuido a la comprensión de las emociones en el aprendizaje en línea y cómo su aplicación puede impulsar estrategias pedagógicas más efectivas y personalizadas.

2.3.1 Software de Detección de Emociones

El software de detección de emociones Emotion Recognition, utiliza la biblioteca OpenCV y Keras para realizar el reconocimiento de emociones en el rostro de estudiantes a partir de videos grabados durante clases en línea. Importa las bibliotecas necesarias como OpenCV, Keras, NumPy, etc. y opera de la siguiente manera:

- Configuración de modelos y rutas
 - Define las rutas a los modelos preentrenados para la detección de rostros y el reconocimiento de emociones.
 - Carga el modelo de detección de rostros (haarcascade) y el modelo de reconocimiento de emociones (_mini_XCEPTION).
 - Parámetros y estructuras de datos
 - Define parámetros como las emociones posibles y estructuras de datos para el almacenamiento de resultados.
 - Inicialización de video
 - Inicializa la captura de video, ya sea desde la cámara web o desde un archivo de video pregrabado.
 - Bucle principal
 - Entra en un bucle que captura cada fotograma del video.
 - Realiza detección de rostros en escala de grises.
 - Para cada rostro detectado:
 - a. Se extrae la región de interés (ROI: Rostro región de interés) y la prepara para la clasificación.
 - b. Utiliza el modelo de reconocimiento de emociones para predecir la emoción.
- El modelo de reconocimiento de emociones utilizado en este contexto es un modelo de aprendizaje profundo basado en redes neuronales convolucionales.
- Data Set: 33 videos de estudiantes durante clases en línea.
- Preprocesamiento: Los datos faciales se preprocesan para extraer características relevantes y emociones.

- Clasificación de Emociones: Después del entrenamiento, el modelo es capaz de clasificar nuevas muestras de datos en categorías emocionales como happy, sad, scared, etc.
- c. Calcular un "peso" basado en la emoción.
 - d. Almacena resultados en un archivo CSV y mostrar resultados en tiempo real.
- Visualización de resultados
 - Muestra una ventana con la transmisión de video original y otra ventana con barras de probabilidad para cada emoción.

2.3.2 Principio de Pareto

La distribución de Pareto se caracteriza por una cola larga y pesada. Esto significa que hay muchos eventos o valores pequeños y relativamente pocos eventos o valores grandes. La distribución de Pareto lleva el nombre del economista italiano Vilfredo Pareto (Mandelbrot, 1960).

La regla (fórmula) del 80/20 de Pareto es una ley empírica que establece que el 80% de los efectos proviene del 20% de las causas. En el ámbito del reconocimiento de emociones, esto se traduce en que el 80% de la información emocional se puede extraer del 20% de los datos. A continuación, se expone algunos ejemplos de la utilización del principio de Pareto.

En el ámbito de la investigación científica, se ha observado en algunos estudios que las publicaciones científicas siguen el principio de Pareto en términos de tiempo y citaciones en revistas electrónicas (Jung et al., 2015). Esto es relevante, considerando que el avance científico tiene un impacto directo en el rendimiento estudiantil (Haan et al., 2015). Esta regla del 80/20 puede tener aplicaciones en el proceso de enseñanza-aprendizaje. La idea es que los educadores se enfoquen en las áreas y habilidades más importantes para mejorar el rendimiento de los estudiantes, en lugar de centrarse en tareas menos relevantes (McLeod, 2018).

El rendimiento académico no solo se ve influenciado por los estímulos y la guía del profesor, sino también por la influencia que ejercen los compañeros de clase sobre cada estudiante. El análisis individualizado del rendimiento académico de cada sujeto mediante técnicas estadísticas revela que la distribución de Pareto está relacionada con la agrupación de estudiantes con intereses similares. Esto permite medir la influencia del grupo escolar en el proceso de enseñanza-aprendizaje (Burke y Sass, 2008). En este sentido, cuando un estudiante destacado se encuentra rodeado de otros estudiantes con un rendimiento igual

o superior, el grupo se organiza y se controla mutuamente, lo que genera los mejores resultados académicos que se reflejan en una distribución de Pareto.

En el ámbito de las emociones humanas, el principio de Pareto también encuentra aplicación. Según la teoría de la arquitectura de elección, se establece que el 80% de nuestras emociones proviene del 20% de nuestras experiencias o circunstancias de vida. Esto implica que el diseño de las opciones presentadas a las personas puede afectar a su bienestar emocional (Thaler y Sunstein, 2009).

El principio de Pareto se aplica al estudio de las emociones humanas y proporciona recomendaciones prácticas para mejorar nuestro bienestar emocional (Alzina, 2008). Siguiendo esta idea, la regla del 80/20 de Pareto puede ser utilizada para identificar las emociones más frecuentes que se reflejan en el rostro de los estudiantes durante las clases en línea.

Esto implica identificar el 20% de las emociones que son expresadas en el rostro del estudiante. Una vez identificadas las emociones más comunes (20%), se pueden analizar las causas detrás de estas emociones y desarrollar estrategias para abordar las emociones más comunes expresadas por el estudiante. Esto puede ayudar a los docentes a mejorar la experiencia de aprendizaje de los estudiantes en las clases en línea y fomentar un ambiente de aprendizaje positivo.

2.3.3 Algoritmo KMEANS

Los entornos en línea de aprendizaje utilizados por la mayoría de las instituciones educativas no brindan a los profesores las herramientas necesarias que permitan rastrear y evaluar minuciosamente todas las actividades realizadas por sus estudiantes para evaluar la efectividad del curso y el proceso de aprendizaje. La aplicación de métodos de minería de datos en el sector educativo es un fenómeno interesante. Se establece para descubrir los datos previamente ocultos en información significativa que podría usarse tanto para logros estratégicos como de aprendizaje (Dutt et al., 2015). El algoritmo KMEANS es una técnica de clustering eficiente y ampliamente utilizada para la agrupación de datos (Mcilhany y Wiggins, 2018).

Antes de explicar cómo funciona el algoritmo, es importante definir lo que significa “clustering”. En este contexto, clustering se refiere a la tarea de agrupar un conjunto de observaciones en grupos, de tal manera que las observaciones dentro de cada grupo sean más similares entre sí que con las observaciones de los otros grupos. El objetivo es

identificar patrones en los datos y crear grupos homogéneos. El algoritmo KMEANS es una de las técnicas más populares de clustering (Hastie et al., 2009).

El algoritmo KMEANS es una herramienta eficiente para agrupar emociones en diferentes categorías según sus características. Su rápida ejecución y escalabilidad lo hacen adecuado para manejar conjuntos de datos grandes. Solo requiere especificar el número de clústeres y elegir una medida de distancia, como la distancia Euclídea. Además, es fácilmente interpretable, ya que se pueden identificar claramente los puntos de datos que pertenecen a cada clúster (Ahmed et al., 2020).

Para realizar la agrupación de emociones primeramente KMEANS fija el número de clusters k que tendrá la partición. Existen diferentes técnicas que nos permiten ayudar a estimar el número k , tales como el método del codo según Humaira y Rasyidah (2020); el método de la silueta según Rousseeuw (1987); el método de la validación cruzada según Kaufman y Rousseeuw (2009) entre otros.

El método del codo consiste en calcular la suma intra-cluster para diferentes valores de k . La suma intra-cluster es una medida de la proximidad de los puntos dentro de un clúster. A medida que aumenta el valor de k , la suma intra-cluster disminuye. El valor de k donde la suma intra-cluster disminuye abruptamente se considera el número de k óptimo (Humaira y Rasyidah, 2020).

El método de la silueta es una técnica útil para evaluar la cohesión y la separación de clusters obtenidos mediante el algoritmo KMEANS, lo que ayuda a determinar la idoneidad del número de clusters y la calidad del agrupamiento resultante.

Por otra parte, la validación cruzada es una herramienta importante en el análisis de agrupamiento para evaluar la calidad de los resultados y seleccionar parámetros adecuados, como el número de clusters, lo que ayuda a mejorar la interpretación y la utilidad de los agrupamientos obtenidos.

Una vez que se ha definido el número de clusters k que tendrá la partición, el algoritmo KMEANS inicia seleccionando k centroides aleatorios en el espacio de características de los datos. Luego, asigna cada observación al centroide más cercano. Después de realizar todas las asignaciones, los centroides se desplazan hacia el centroide de la nueva agrupación. Este proceso se repite hasta alcanzar la convergencia, cuando los centroides apenas se mueven y las asignaciones no cambian significativamente. Cada observación pertenece a un clúster determinado por su centroide más cercano.

El objetivo del algoritmo KMEANS es minimizar la suma de las distancias al cuadrado entre cada observación y su centroide asignado. En cada iteración, se calculan las distancias entre los puntos y los centroides, y se actualizan los grupos asignando los puntos al centroide más cercano. Luego, se recalculan los centroides tomando el promedio de los puntos asignados a cada grupo. Este proceso se repite hasta que los centroides converjan y no haya cambios significativos en la asignación de los puntos (Jain y Dubes, 1988; Ahmed et al., 2020).

El proceso mencionado se lleva a cabo siguiendo los pasos que se detallan a continuación:

1. Selecciona aleatoriamente k centroides iniciales, donde cada centroide representa el centro de cada uno de los k grupos.
2. Asigna cada observación de datos al grupo cuyo centroide está más cerca de ella.
3. Recalcula los centroides de cada grupo como la media aritmética de todas las observaciones asignadas a ese grupo.
4. Se repite los pasos 2 y 3 hasta que no haya cambios en la asignación de observaciones a grupos o hasta que se alcance un número máximo de iteraciones definido por el usuario.

En el contexto del aula de clases, KMEANS ha sido utilizado para reconocer emociones al detectar la actividad facial y los patrones de movimiento de los estudiantes. Estudios han demostrado una alta precisión en la detección de emociones como la felicidad, tristeza, enojo y sorpresa (Chen et.al., 2022), (Melgare, 2019). Asimismo, KMEANS se ha aplicado para medir el estado emocional de los estudiantes en el aula mediante la detección de señales fisiológicas como la variabilidad de la frecuencia cardíaca y la temperatura de la piel. Los resultados muestran una alta precisión en la detección de emociones como la felicidad, el aburrimiento y la tensión (Mohanty y Swain, 2010).

Otra aplicación del algoritmo KMEANS en el aula de clases es en el procesamiento de señales de audio para detectar emociones. Un estudio ha demostrado una alta precisión en la detección de emociones como la felicidad, tristeza, ira y miedo (Jeong y Yoo, 2022).

En el presente trabajo se ha aplicado el algoritmo KMEANS para obtener grupos de emociones que sirvan como entrada para la ontología de la cual se habla en el siguiente apartado.

2.4. Modelado ontológico de emociones y sus influencias: Explorando el dominio emocional

La utilización de ontologías en el contexto del aprendizaje y las emociones en clases en línea permite una comprensión más completa y precisa del comportamiento humano. Las ontologías proporcionan una estructura formal para describir y representar los conceptos relevantes en el ámbito académico, como los objetivos de aprendizaje, los recursos educativos y las interacciones emocionales. Al establecer las relaciones entre estos conceptos, las ontologías facilitan la identificación de patrones emocionales, la personalización de la enseñanza y la adaptación de los entornos virtuales de aprendizaje.

En el ámbito de las ontologías que se enfocan en las emociones humanas, existen varias propuestas relevantes. Por ejemplo, la ontología Affective Common Sense (ACS) desarrollada por Strapparava y Mihalcea (2007) se centra en la representación del conocimiento afectivo común. Por otro lado, la ontología EmotionML, desarrollada por el World Wide Web Consortium (W3C), tiene como objetivo la representación y el intercambio de información emocional en aplicaciones web. Estas ontologías, junto con Human Affect Sensing and Influence Ontology (HASIO), son ejemplos de cómo el modelado ontológico puede contribuir al análisis y comprensión de las emociones humanas en diversos contextos.

La utilización de herramientas de análisis como la ontología HASIO resulta fundamental para comprender y optimizar la experiencia de aprendizaje en línea, lo que a su vez permite una educación más efectiva y personalizada (Abaalkhail, 2018). HASIO conceptualiza las tendencias a la acción, brindando así una herramienta invaluable para comprender y mejorar la experiencia de aprendizaje en línea.

En particular, la estructura de HASIO se basa en la definición de conceptos clave relacionados con las emociones en el proceso de aprendizaje en línea. Esto incluye los estados emocionales, los factores desencadenantes, las respuestas emocionales y las influencias contextuales. La ontología establece relaciones entre estos conceptos, lo que permite un análisis más profundo de las emociones y su impacto en el aprendizaje en línea.

Trabajar con la ontología HASIO resulta crucial debido a sus múltiples beneficios. Al utilizar esta ontología, es posible inferir tendencias a la acción en los estudiantes, lo cual proporciona información valiosa para la retroalimentación educativa y la mejora del proceso de enseñanza-aprendizaje en clases en línea. La estructura bien definida de HASIO facilita la captura y organización de datos emocionales, permitiendo un análisis más preciso y exhaustivo de las emociones en el contexto de las clases en línea. Su aplicación en el ámbito

de la educación virtual la convierte en una herramienta especialmente relevante para comprender y mejorar la experiencia educativa en entornos virtuales de aprendizaje.

2.4.1 Ontologías para el análisis de emociones: Un enfoque semántico en el estudio emocional

Un enfoque basado en ontologías semánticas para la detección de emociones en la interacción humano-máquina, mejora significativamente la precisión en comparación con los enfoques tradicionales que se basan en medidas fisiológicas. La revisión exhaustiva de las ontologías existentes para representar emociones y estados afectivos destaca la necesidad de seguir desarrollando y mejorando estas ontologías para aplicaciones futuras en diferentes campos de la vida humana, centradas en emociones básicas y otras en estados afectivos complejos (Pazos-Sanou et al., 2018). En su revisión sistemática sobre el uso de ontologías en la computación afectiva, García Silva et al. (2020) destacan cómo estas herramientas han mejorado la precisión y eficacia en esta área. Las ontologías se han utilizado en áreas como el reconocimiento de emociones, generación de emociones y detección de eventos emocionales. Al proporcionar una base sólida para el análisis y la interpretación de datos emocionales, las ontologías pueden mejorar la precisión de los sistemas de computación afectiva y superar la variabilidad y subjetividad en la interpretación de las emociones humanas, lo que aumenta la fiabilidad de estos sistemas.

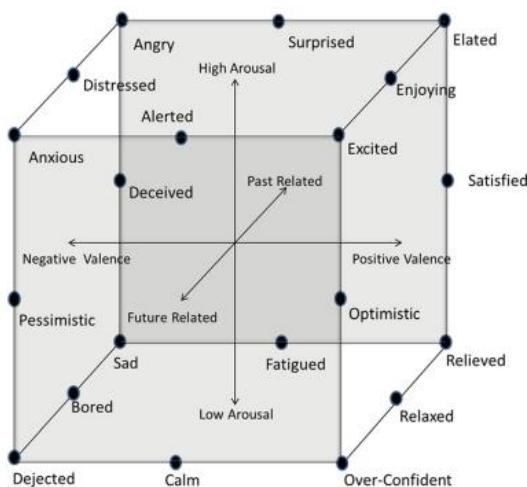


Figura 3 Relaciones tridimensionales emocionales (Latinjak et al., 2014)

La Figura 3 muestra los parámetros emocionales como relaciones que dan la interpretación del afecto. Aquí cada una de las emociones producen valencias positivas o negativas que pueden ser traducidas en porcentaje, en donde; un porcentaje bajo tiene relación directa con una valencia negativa. En ese sentido, la computación afectiva ha adquirido una creciente importancia en áreas como la educación, la salud y el entretenimiento. Para mejorar la precisión de los modelos de reconocimiento de emociones, se ha recurrido al uso

de ontologías y a la integración de múltiples fuentes de datos. Adicionalmente, se ha explorado el potencial de las técnicas de aprendizaje profundo y redes neuronales en la computación afectiva. En conjunto, estos avances en el campo tienen el potencial de transformar diversas áreas de la vida humana (Pazos-Sanou L. et al., 2021). Esto permite incorporar aplicaciones ontológicas basadas en la descripción de las emociones y microexpresiones humanas en sistemas de e-learning para desarrollar la habilidad de los usuarios e identificar y comprender microexpresiones (Cernian y Olteanu, 2015).

2.4.2 Ontologías y el aprendizaje en línea

Las ontologías desempeñan un papel crucial en el análisis y la representación del conocimiento emocional en el aprendizaje en línea. Estas estructuras organizan los conceptos relevantes relacionados con las emociones en entornos virtuales educativos. Al mismo tiempo, las ontologías de aprendizaje describen los elementos clave del proceso educativo, como los objetivos, los recursos y las actividades pedagógicas, estableciendo relaciones y jerarquías entre ellos. Esto permite inferir el comportamiento humano y las respuestas emocionales en el contexto del aprendizaje en línea (Dicheva y Dichev, 2012).

La representación adecuada del estado emocional de los estudiantes en entornos de aprendizaje en línea es esencial para comprender y mejorar su experiencia educativa. Las ontologías proporcionan un marco estructurado y semántico para modelar y organizar el conocimiento emocional, permitiendo el análisis y la inferencia de patrones emocionales relevantes. Para lograr esto, el uso del lenguaje de ontología web (OWL) en el modelado emocional en el aprendizaje en línea resulta especialmente beneficioso. OWL es un lenguaje basado en la lógica computacional que facilita el intercambio y la reutilización del conocimiento (López-Gil et al., 2019).

El modelado emocional en una ontología permite una representación estructurada y coherente de las emociones en el contexto educativo en línea, lo que proporciona una base sólida para la personalización y adaptación de las estrategias pedagógicas. Estas estructuras organizadas facilitan la identificación de patrones emocionales y comportamentales, lo que permite el análisis de tendencias y acciones en el proceso educativo. Los educadores pueden utilizar esta información valiosa para retroalimentar el proceso de enseñanza, ajustando y mejorando continuamente sus métodos pedagógicos con el objetivo de optimizar la experiencia de aprendizaje (Chen, 2016).

Al trabajar con ontologías en el ámbito del aprendizaje en línea, se establece un enfoque sólido para comprender y analizar las emociones y su impacto en el proceso educativo. Estas estructuras semánticas proporcionan una base conceptual para explorar en profundidad los

estados emocionales, las respuestas y los desencadenantes emocionales en las clases en línea. Al comprender mejor las emociones de los estudiantes y su relación con el aprendizaje, los educadores pueden brindar retroalimentación más significativa y oportuna, fomentando así un crecimiento académico sólido y una experiencia educativa enriquecedora en el entorno en línea.

En el contexto de los sistemas de aprendizaje en línea interactivos, se utilizan sistemas de información híbridos que combinan tecnologías como la detección de expresiones faciales y algoritmos basados en clusters y máquinas de soporte vectorial. Estos sistemas ofrecen eficiencia en la detección de estados emocionales y en la retroalimentación al profesor, creando un esquema similar al aprendizaje en el aula tradicional (Ayvaz et al., 2017).

Se propone la implementación de métodos no invasivos para capturar las expresiones faciales de los estudiantes y del profesor sin interrumpir la clase en línea. Esto se logra mediante el uso de elementos multimodales integrados en un sistema inteligente, combinados con estructuras conceptuales, pedagógicas y cognitivas para mejorar el entorno de aprendizaje y los temas tratados (Cabada et al., 2019).

Estas estructuras conceptuales permiten conceptualizar las emociones humanas a través de ontologías, brindando oportunidades para personalizar y adaptar las necesidades del usuario (Storey y Park, 2022). Además, la combinación de información contextual y la fusión de datos mejoran significativamente la precisión en la inferencia de emociones humanas gracias al uso de estructuras semánticas, como se demostró en el trabajo de Mel et al. (2011). Estas estrategias proporcionan una comprensión más profunda de los procesos cognitivos y emocionales, lo que puede tener importantes aplicaciones en el ámbito académico.

Las técnicas de inferencia lógica que utilizan los razonadores ontológicos operan sobre ontologías OWL para realizar razonamientos y obtener conclusiones sobre el conocimiento representado en dicha ontología. Por lo tanto, es fundamental abordar la agrupación de emociones utilizando un razonador ontológico para la interpretación semántica y observar cómo funcionan en las clases en línea. Esto es especialmente relevante en los procesos de retroalimentación educativa, donde a menudo se trasladan las estrategias de enseñanza tradicionales y se pasa por alto la forma particular de aprendizaje de cada estudiante en entornos en línea (Behnagh, 2020; Kaviani et al., 2020; Rowe y Lester, 2020; Anzelin et al., 2020).

2.4.3 Explorando la estructura de HASIO: Una ontología para el análisis de estados emocionales

La aparición de innovaciones tecnológicas, como la Web Semántica y OWL, ha generado una mayor necesidad de que las computadoras comprendan los estados afectivos humanos y sus influencias (Abaalkhail, 2018). La ontología de Estados Afectivos Humanos y sus Influencias (HASIO) es un marco conceptual que describe y organiza los estados afectivos humanos y las influencias que pueden afectarlos. El desarrollo de la ontología HASIO se basó en metodologías de ingeniería del conocimiento, con el objetivo de facilitar el análisis y la integración de datos emocionales en diversas aplicaciones, como la educación, la salud mental, la robótica y la interacción persona-máquina. Esta ontología reconoce la complejidad y multifaceticidad de los estados afectivos humanos, así como la variedad de factores que los influyen.

HASIO describe estos estados afectivos y las influencias que pueden afectarlos utilizando conceptos y relaciones formales. Además, la ontología proporciona un conjunto de reglas y axiomas que permiten la inferencia y la integración de conocimientos. Algunos de los conceptos clave en HASIO incluyen emociones, sentimientos, estados de ánimo, afectos, experiencias subjetivas, eventos externos, factores internos y estados psicológicos. La ontología también considera las influencias sociales, culturales, biológicas y psicológicas que pueden afectar los estados afectivos humanos y sus relaciones semánticas emocionales (Abaalkhail, 2018).

Las relaciones semánticas emocionales se basan en modelos tridimensionales que interpretan el afecto a través de parámetros emocionales. Estos parámetros generan valencias positivas o negativas, que pueden ser expresadas en forma de porcentaje, donde un porcentaje bajo se relaciona directamente con una valencia negativa (Wang, Ho et al., 2020).

Además, HASIO se organiza en tres niveles jerárquicos: el nivel más alto describe el estado afectivo general del individuo (como "felicidad" o "tristeza"); el nivel medio describe los componentes que contribuyen a ese estado afectivo general (como "emoción" o "personalidad"); y el nivel más bajo describe los elementos que componen el nivel medio (como "miedo" o "extroversión"). Además, la ontología incluye relaciones que representan cómo los distintos estados afectivos se influyen entre sí y cómo afectan otros aspectos de la vida de una persona, como su comportamiento, sus relaciones sociales y su salud (García Silva et al., 2020).

Estas relaciones entre los estados afectivos se llevan a cabo gracias a la reutilización ontológica. El enfoque de HASIO consiste en la reutilización y reingeniería de recursos ontológicos y no ontológicos, como la teoría de la psicología, léxicos y tesauros para mejorar la creación y el mantenimiento de ontologías. Dentro de las ontologías reutilizadas, se encuentra FOAF (Friend of a Friend), una ontología legible para máquinas que describe a las personas, sus actividades y relaciones con otros objetos - personas (Brickley y Miller, 2014) y HEO (Human Emotion Ontology), una ontología utilizada para representar y describir las emociones humanas. La ontología HEO se basa en la idea de que las emociones humanas pueden ser descritas por su intensidad, valencia y el objeto o evento que las desencadena (Grassi, 2009). Entre las clases de la ontología HEO, se encuentra Action_Tendency (Abaalkhail, 2018)

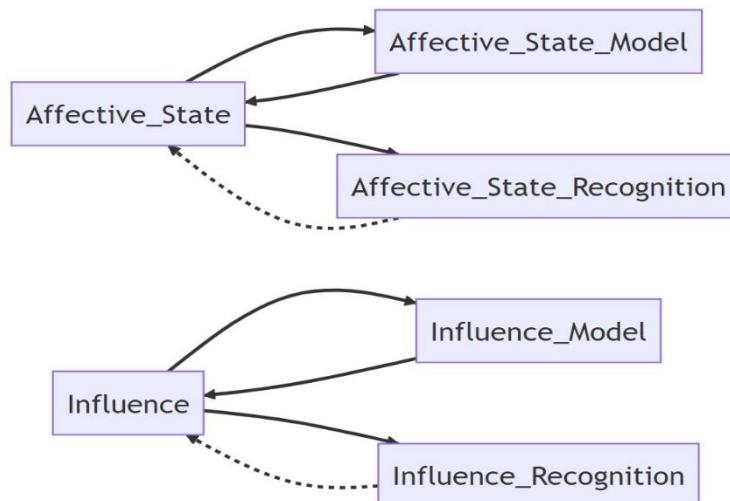


Figura 4 Modelo conceptual de la ontología HASIO que representa las principales entidades y las relaciones entre las entidades (Abaalkhail, 2018)

En la Figura 4 las clases son representadas por formas rectangulares, las flechas indican relaciones entre ellas y las flechas punteadas indican las propiedades de objetos. La clase Affective_State representa estados afectivos humanos.

El Affective_State_Model representa los modelos psicológicos para cada estado afectivo. El Affective_State tiene una relación con la clase Affective_State_Model a través de la relación "hasModel".

Al contrario, el Affective_State_Model se conecta a la clase Affective_State a través de la relación "isModelFor".

El Affective_State_Recognition representa las formas o métodos para detectar cada estado afectivo. Por lo tanto, un Affective_State es detectado por (“isDetectedFrom”) un Affective_State_Recognition. La clase Influence representa la influencia sobre los estados afectivos humanos.

Cada factor puede a su vez ser representado por un Influence_Model, el cual está representado por la clase del mismo nombre, y está expresado a través de la relación “hasModel” que conecta Influence con Influence_Model. La clase Influence_Recognition representa las formas o métodos usados para detectar cada influencia.

Por tanto, Influence conecta con Influence_Recognition a través de la relación “isDetectedFrom”. Como los estados afectivos son factores que influencian sobre las emociones, estados de ánimo y sentimientos, esto es modelado a través de la relación “isInfluencedBy” entre Affective_State e Influence.

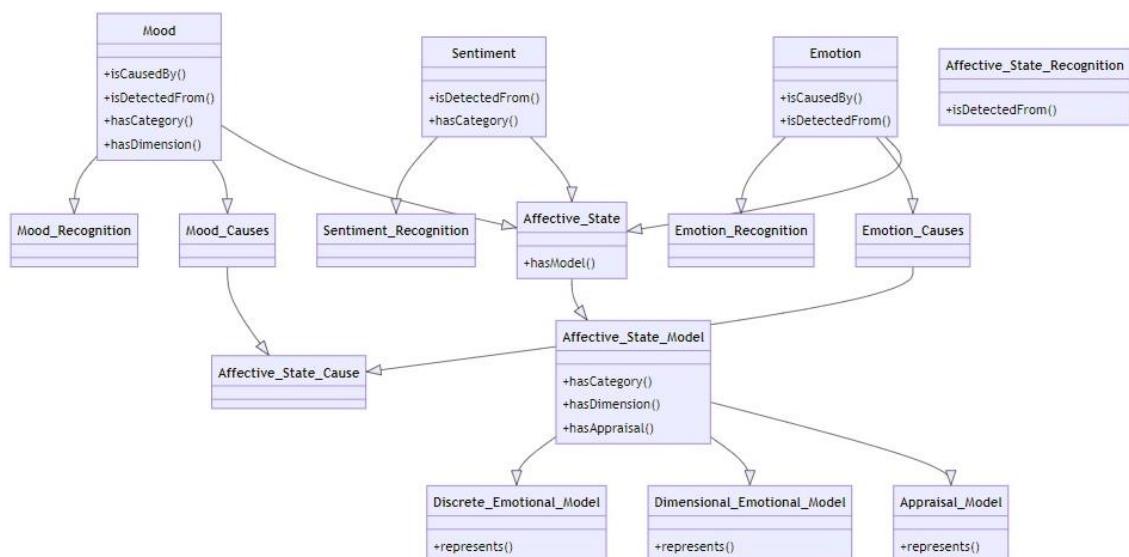


Figura 5 Estructura de las principales clases, subclases y sus propiedades de la ontología HASIO que se relacionan con los estados afectivos (Abaalkhail, 2018)

Se empieza describiendo las clases en la Figura 5 de abajo hacia arriba. Como se mencionó anteriormente, la clase Affective_State_Model expresa las formas de representar los estados afectivos.

Una emoción puede ser definida por varios modelos, uno de ellos está representado en la subclase Appraisal_Model, otro está en la subclase Dimensional_Emotional_Model y otro en la subclase Discrete_Emotional_Model. Una emoción se puede describir de manera discreta usando la propiedad “hasCategory”; de manera dimensional usando la propiedad “hasDimension”; y de manera componencial usando la propiedad “hasAppraisal”.

La clase Affective_State_Cause permite incluir las causas del estado de ánimo y la emoción. La clase Emotion y Mood están conectados a la clase Emotion_Causes y a la clase Mood_Causes respectivamente, a través de la propiedad "isCausedBy".

La clase Affective_State tiene las subclases Emotion, Mood y Sentiment. Las emociones tienen una duración corta por lo general duran segundos, mientras que la duración de los estados de ánimo (Mood) se extiende desde minutos a días. Debido a las similitudes entre el estado de ánimo (Mood) y la emoción (Emotion), el estado de ánimo puede expresarse mediante un modelo discreto o dimensional. Por lo tanto, la clase Mood se conecta con Dimensional_Emotional_Model y Discrete_Emotional_Model a través de las propiedades "hasCategory" y "hasDimension". Además, Sentiment puede representarse mediante un Discrete_Emotional_Model.

La clase Affective_State_Recognition modela las posibles formas de recolectar información para identificar estados afectivos humanos. Además, Emotion, Mood y Sentiment se conectan a Emotion_Recognition, Mood_Recognition y Sentiment_Recognition, respectivamente, a través de la propiedad objeto "isDetectedFrom".

Se sabe que las emociones están ligadas a tendencias a la acción específicas, preparando a la persona para responder rápidamente a las situaciones. Por tanto, una emoción tiene una tendencia a la acción que define el resultado de la acción de la emoción. Se expresa a través de la propiedad "hasActionTendency" (Fridja, 1986).

Por tanto, en la clase Emotion se van a registrar todas las emociones inferidas de cada participante; es decir, todas las emociones que se infieren en la clase Action_Tendency son registradas en la clase Emotion.

Tabla 2. Action_Tendency y funciones de algunas emociones (Frijda, 1986)

Action Tendency	Estado final	Función	Emoción inferida
Approach	Acceso	Situación de producción permitiendo actividad consumatoria	Deseo
Avoidance	Accesibilidad propia	Protección	Miedo
Being With	Contacto, interacción	Permitiendo actividad consumatoria	Disfrute, Confianza

Attending (opening)	Identificación	Orientación	Interés
Rejecting (closing)	Eliminación de objeto	Protección	Asco
NoAttending	Sin información o contacto	Selección	Indiferencia
Agonistic	Eliminación de obstrucción	Recuperando el control	Enojo
Interrupting	Reorientación	Reorientación	Choque, Sorpresa
Dominating	Control retenido	Control generalizado	Arrogancia
Submitting	Placer desviado	Control secundario	Humildad, Resignación

La Tabla 2 muestra las tendencias a la acción con su estado final, función y emoción inferida que obtiene la ontología una vez que se han ejecutado los axiomas según sea el contexto de entrada.

2.5. Conclusiones

En conclusión, el estudio de las emociones en el contexto del aprendizaje ya sea presencial o en línea, desempeña un papel fundamental en la mejora de la experiencia educativa. La comprensión de cómo las emociones influyen en el rendimiento académico, la motivación y la interacción entre estudiantes y profesores permite diseñar estrategias efectivas para optimizar el proceso de enseñanza-aprendizaje.

En el ámbito del aprendizaje en línea, las emociones adquieren una mayor importancia debido a la ausencia de interacción directa, bajo la propuesta de este estudio, se tratará de suplantar con un modelo ubicuo que infiere la tendencia a la acción. Las tecnologías emergentes, como las ontologías y el análisis semántico, brindan herramientas poderosas para detectar y comprender las emociones de los estudiantes, lo que a su vez permite personalizar y adaptar la experiencia educativa de forma individualizada.

La tendencia a la acción en clases en línea, parte fundamental de este trabajo, basada en el uso de la información emocional captada, promueve una retroalimentación oportuna y la adaptación de las actividades y el contenido del aprendizaje, en función de las

necesidades y preferencias de cada estudiante. Esto contribuye a mejorar la calidad de la educación en línea y a fomentar un entorno de aprendizaje más inclusivo y enriquecedor.

Al considerar las emociones en el diseño y desarrollo de entornos de aprendizaje en línea, y al emplear tecnologías innovadoras como las ontologías junto al modelo ubicuo, es posible avanzar hacia una educación más efectiva, personalizada y emocionalmente inteligente. La combinación de la comprensión de las emociones y el uso de herramientas tecnológicas abre nuevas oportunidades para mejorar el proceso de enseñanza-aprendizaje y garantizar una experiencia educativa más satisfactoria para los estudiantes.

Por tanto, el estado del arte presentado en este capítulo destaca las técnicas y enfoques utilizados en investigaciones previas relacionadas con el análisis emocional en el contexto específico de las clases en línea. Se ha puesto énfasis en el uso de software de procesamiento de señales de video para registrar las emociones básicas durante las clases en línea, que representan un método relevante y prometedor para capturar y analizar las expresiones emocionales de los estudiantes en entornos educativos en línea.

Además, se ha explorado cómo el principio de Pareto se puede aplicar para identificar las emociones predominantes en las clases en línea, permitiendo focalizar los esfuerzos en las emociones más relevantes y significativas para mejorar la experiencia de aprendizaje en línea. Asimismo, se ha analizado el empleo del algoritmo KMEANS para agrupar las emociones y crear clústeres emocionales, lo cual resulta de gran utilidad para inferir tendencias en el comportamiento de los estudiantes, proporcionando valiosa información para la toma de decisiones pedagógicas.

Por otra parte, se ha investigado el uso de ontologías, específicamente la ontología HASIO, para representar y modelar los estados afectivos humanos en las clases en línea. Estas ontologías ofrecen una estructura semántica que posibilita una comprensión más profunda y precisa de las emociones, mejorando así la interpretación de los datos emocionales recopilados en las clases en línea.

Basándose en estos estudios previos, se plantea el desarrollo de un modelo integral y semántico que integre las técnicas y enfoques exitosos mencionados anteriormente. Este modelo se enfoca en analizar de manera precisa y significativa las emociones y comportamientos en el contexto específico de las clases en línea, brindando información valiosa para los educadores y facilitando la toma de decisiones informadas para mejorar la experiencia de aprendizaje de los estudiantes en clases en línea.

Así, la combinación de software de procesamiento de señales de video, el uso del principio de Pareto, el algoritmo KMEANS y la utilización de ontologías ofrece un enfoque integral y prometedor para comprender y mejorar el impacto de las emociones en el proceso de aprendizaje en clases en línea. El desarrollo de este modelo podría contribuir significativamente al campo de la educación en línea, proporcionando nuevas herramientas y conocimientos para respaldar el aprendizaje y el bienestar emocional y académico de los estudiantes en clases en línea, lo que da paso al enfoque metodológico que se explica en el siguiente apartado.

CAPÍTULO III. METODOLOGÍA

En este capítulo, se abordarán diversos aspectos relacionados con la **metodología del modelo ubicuo de análisis emocional**. Comenzaremos describiendo detalladamente en la sección 3.1 cómo se aplica esta metodología en el contexto de las clases en línea para registrar y analizar las emociones manifestadas por los estudiantes. Se explicará cómo se utiliza el software de reconocimiento de emociones para capturar las expresiones faciales de los participantes durante las clases, permitiendo así obtener información sobre sus emociones. Posteriormente se explicará cómo determinar cuáles fueron las emociones predominantes experimentadas durante las clases en línea; para luego explicar el uso de una técnica de agrupamiento en minería de datos para generar clusters emocionales individuales para cada estudiante; y finalmente instanciar los clusters emocionales en una ontología con el fin de obtener comportamiento humano asociado a emociones mediante las tendencias a la acción para el aprendizaje.

En la sección 3.2, se presentará una **metodología específica para evaluar el modelo ubicuo**. Esto incluirá la descripción de los criterios y métricas utilizados para medir la eficacia y precisión del sistema de detección de emociones, así como la forma en que se recopilan y procesan los datos para su posterior análisis.

Además, como parte fundamental del análisis emocional se explorará la **validación de los resultados obtenidos**. Esto implica analizar cómo las emociones identificadas y los clusters emocionales se relacionan con el contexto educativo y las tendencias a la acción de los estudiantes. Se explicará cómo se utilizó la ontología HASIO para establecer estas relaciones y obtener una comprensión de las tendencias a la acción en el proceso de enseñanza-aprendizaje.

Por último, en la sección 3.3 se presentará una descripción de la **interfaz del modelo ubicuo de análisis emocional**. Se explicará sus funcionalidades y cómo se integra con el software de reconocimiento facial, el algoritmo de minería de datos y la ontología HASIO para llevar a cabo el análisis emocional durante las clases en línea.

3.1. Metodología del modelo ubicuo de análisis emocional

La metodología del modelo ubicuo de análisis emocional, aplicada en clases en línea, permite registrar y analizar emociones detectadas en los rostros de los estudiantes, así como también inferir y validar las tendencias a la acción para el aprendizaje. A continuación, se explica paso a paso cómo se desarrolló la presente propuesta metodológica.

3.1.1 Pasos metodológicos para la selección y agrupamiento de emociones

La metodología del modelo ubicuo de análisis emocional aplicada en clases en línea permitió una comprensión más profunda de las emociones manifestadas durante el proceso educativo en línea. Al centrarse en el concepto de computación ubicua, este enfoque se concibe como un marco invisible que se desarrolla de manera intrínseca durante la enseñanza-aprendizaje. A través de esta metodología, se pretende mejorar la experiencia y el apoyo emocional de los participantes. Con el objetivo de ilustrar el proceso metodológico, se incluye en la Figura 6 un diagrama que representa visualmente este enfoque.

Metodología del modelo ubicuo de análisis emocional

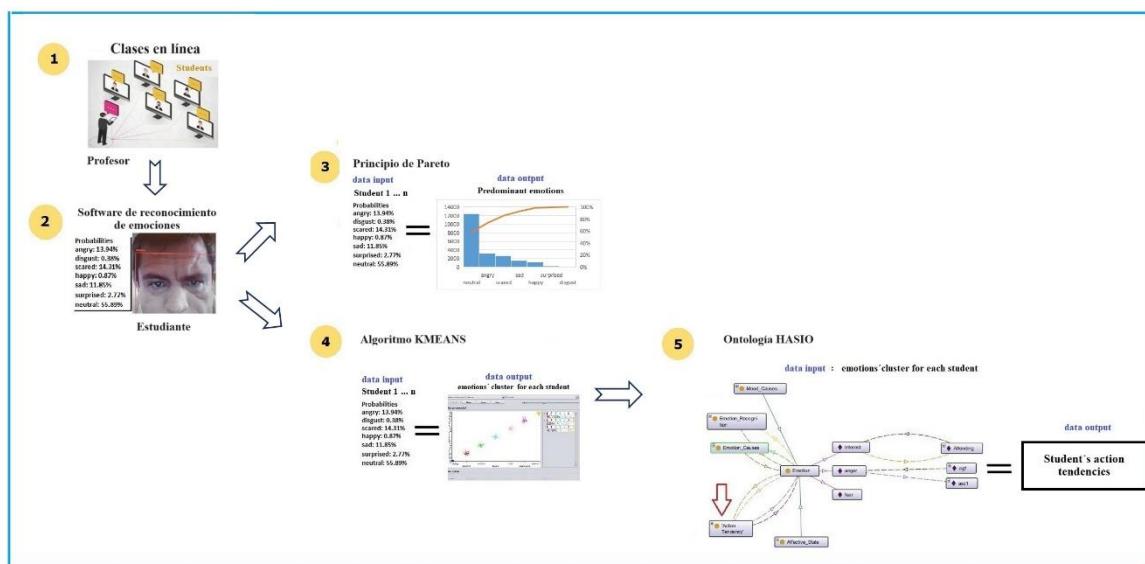


Figura 6 Metodología aplicada para la obtención del comportamiento humano (Tendencias a la acción para el aprendizaje) a partir de los rostros grabados de estudiantes

La Figura 6. muestra la metodología llevada a cabo en la presente investigación, la misma que es explicada a continuación.

1. Se comunica tanto a los estudiantes como a los profesores que la clase en línea será grabada y que sus rostros serán grabados en video mientras transcurre la clase. Para ello, tanto los profesores como los estudiantes mantuvieron activadas sus cámaras. La clase contó con la participación de 33 estudiantes y tuvo una duración total de una hora, siguiendo el enfoque de Vedder-Weiss et al. (2019) y Palmer (2017). Sin embargo, cada uno de los 33 videos resultantes tuvo una duración promedio de una hora. Esto se debe a que el tiempo de cada video está sujeto a las condiciones individuales en las que se encuentre cada estudiante desde el momento en que enciende la cámara, participa en la clase y hasta que finaliza la clase. Es importante destacar que el software de reconocimiento de emociones requiere que el

estudiante esté sentado frente a la cámara web para comenzar a detectar las emociones en su rostro. Por lo tanto, si el estudiante adopta otras posturas, como agacharse, mirar hacia otro lado o taparse la cara, entre otras, el software no podrá detectar ninguna emoción. Esto explica por qué la duración de los videos varía.

Además, es importante considerar que algunos temas podrían ser más interesantes o relevantes para los estudiantes que otros, lo que podría sesgar sus respuestas sobre la motivación. Cuantas más lecciones se incluyan en el proceso, mayor será la posibilidad de que los estudiantes tengan opiniones y emociones divergentes debido a la variabilidad inherente en los contenidos y enfoques de enseñanza.

2. Para registrar las expresiones faciales de los participantes que fueron grabadas en los videos se utilizó el software de reconocimiento de emociones Emotion Recognition explicado en el capítulo I. El software genera un archivo con el conjunto de emociones registradas por cada participante (ejemplo Figura 7), este paso se justifica bajo la propuesta de que las emociones en el rostro son importantes para el proceso de enseñanza-aprendizaje (Cabada et al., 2019).



Figura 7 Emociones de un estudiante obtenidas por el software de reconocimiento de emociones

A través del software de reconocimiento de emociones, se capturaron las expresiones faciales de los participantes durante las clases en línea, lo que permitió recopilar información en tiempo real sobre sus emociones con su porcentaje de ocurrencia asociado.

3. Se aplicó el principio de Pareto para observar qué emociones son las más predominantes en la clase en línea. Para ello se creó un archivo (ver Tabla 3) cuyos datos de entrada son el compilado del registro de las emociones en el rostro de TODOS los estudiantes. Es decir, si por cada estudiante se tiene un fichero csv que contiene sus registros faciales emocionales, cada uno de esos ficheros csv se une un uno solo y se obtiene el csv emocional de todos los estudiantes para este cálculo, tal como propone Ortis et al. (2020).

Tabla 3. Extracto del archivo de entrada para graficar Pareto

Resultados del Software Emotion Recognition para todos los estudiantes de la clase	
Emotions	Percent
angry	2.30
disgust	1.31
scared	4.15
happy	0.66
sad	16.43
surprise	0.05
neutral	75.09
angry	7.22
disgust	0.56
scared	11.54
happy	0.76
...	...

Para realizar el cálculo de Pareto, se trabaja con el porcentaje de cada emoción, luego se ordena los valores de mayor a menor porcentaje, se calcula el porcentaje acumulado y finalmente se identifica que emociones representan el 20% superior.

Este paso permitió determinar cuáles fueron las emociones predominantes experimentadas durante las clases en línea, proporcionando así una visión general del estado emocional de los estudiantes.

4. Se aplicó el algoritmo KMEANS para agrupar las emociones que obtuvo el software de reconocimiento de emociones. El algoritmo KMEANS inicia el proceso de agrupación seleccionando centroides de forma aleatoria según el número k de clústers establecido. Un centroide es un punto representativo dentro de un clúster. Está ubicado en el centro geométrico de un conjunto de datos en un espacio dimensional, y su posición se actualiza iterativamente durante el proceso de agrupamiento. Posteriormente, mediante el cálculo de la distancia euclíadiana, se determinan las emociones más cercanas a cada centroide, facilitando así la creación de clústers emocionales.

Cada archivo de entrada para el algoritmo se organiza en vectores que constan de 7 columnas. Esto implica que para cada ventana de tiempo T_{-i} , los vectores de entrada contienen siete valores numéricos asociados a cada una de las siete emociones. Estos valores representan el estado emocional del estudiante desde el inicio hasta el final de la clase en línea. Por consiguiente, el conjunto completo de vectores en todos los momentos registrados en el video constituye el archivo de entrada para el algoritmo KMEANS de cada estudiante.

Una vez que se ha ejecutado el algoritmo KMEANS, los clústeres resultantes se caracterizan por los centroides obtenidos a partir del vector de emociones asociados a cada clúster. Estos centroides constan de siete valores numéricos, los cuales representan el promedio de cada emoción dentro del vector del clúster respectivo. En consecuencia, se calcula un centroide para cada clúster, donde cada dimensión del centroide corresponde a una emoción. La emoción más destacada en cada centroide se identifica al encontrar la dimensión con el valor máximo en cada vector.

Es importante determinar el número óptimo de clústeres a utilizar; es decir, se debe ajustar el número de clusters (k) y evaluar diferentes configuraciones para obtener resultados más significativos. Para este experimento elegimos el método del codo por ser fácil de entender y usar, es relativamente rápido y eficiente y es relativamente robusto a los datos ruidosos (Humaira y Rasyidah, 2020). Se experimentó el método del codo en un rango de k de 3 a 4. Además, esta tesis se basa en las pruebas realizadas por Melgare (2019) que recomienda un $k = 4$ para los cluster emocionales, pues permite percibir no solo las similitudes entre los miembros del mismo cluster, sino también las diferencias generales entre los miembros que no pertenecen al mismo cluster.

A continuación, se detallan los pasos a seguir para la aplicación del algoritmo KMEANS.

4.1 Lectura y procesamiento inicial del archivo csv:

- Los datos de las emociones en el rostro detectadas por medio del software se almacenan en un fichero csv. Cada fichero csv tiene dos columnas Emotions y Percent.
- Para aplicar KMEANS los datos se organizan en vectores de siete columnas: 'angry', 'disgust', 'scared', 'happy', 'sad', 'surprised', 'neutral'.

Esta disposición se debe a que el software de reconocimiento de emociones reconoce siete emociones básicas en el rostro de los participantes en cada ventana de tiempo T_i . Cada vector de siete columnas representa un estado emocional.

4.2 Análisis de KMEANS y generación de resultados:

- Se aplica KMEANS con $k=4$ clústeres.
- Para asignar las emociones a cada clúster en el análisis de KMEANS, se utilizan los centroides finales de los clústeres. Cada centroide representa un vector en el espacio de características que describe las características promedio de las instancias asignadas a ese clúster. En este caso, las emociones están representadas como características, y cada valor en el vector del centroide corresponde a la prominencia de esa emoción en el clúster.
- Se calcula el centroide para cada clúster, donde cada dimensión del centroide representa una emoción.
- La emoción más prominente en cada centroide se determina encontrando la dimensión con el valor máximo en el vector del centroide.
- Esta emoción se asigna al clúster correspondiente como la emoción representativa del clúster.
- Se etiqueta a la emoción asignada a cada cluster como característica MAYOR o MENOR en función del número de instancias pertenecientes al cluster; es decir, se suman todas las instancias ejecutadas y se obtiene la mediana de ellas. Si el valor de la instancia ejecutada en un cluster es mayor a la mediana se etiqueta como MAYOR, caso contrario se etiqueta como MENOR.

Cada emoción tiene asociada una “tendencia a la acción” según la teoría de Nico Frijda, que se obtiene mediante axiomas ontológicos.

3.1.2 Pasos metodológicos para inferir las Tendencias a la acción en la ontología

En los párrafos anteriores, se describió cómo se obtienen los clusters emocionales, esto proporciona una representación organizada y no redundante de las respuestas emocionales individuales. En esta sección se explica cómo se integran estos clusters en el modelo ubicuo mediante la creación de instancias semánticas.

Para integrar estos clusters emocionales en el modelo ubicuo, se crean instancias de cada cluster de emociones en la clase Frijda_Action_Tendency de la ontología HASIO. Se empleó la ontología HASIO para explorar la relación entre las emociones y las tendencias a la acción para el aprendizaje de los estudiantes. Esta ontología proporcionó un marco conceptual para comprender cómo las emociones influyen en las acciones y comportamientos de los estudiantes durante las clases en línea.

Una vez que los clusters emocionales se han instanciado en la ontología, se utilizó la potencia del razonador Pellet³. Este razonador ejecuta los axiomas y reglas definidos en la ontología, lo que permite obtener las tendencias a la acción en la clase Frijda_Action_Tendency (Frijda, 1986) por cada estudiante. Estas tendencias a la acción inferidas proporcionan información valiosa sobre el comportamiento humano asociado a las emociones identificadas, como el ejemplo que se muestra en la Figura 8.

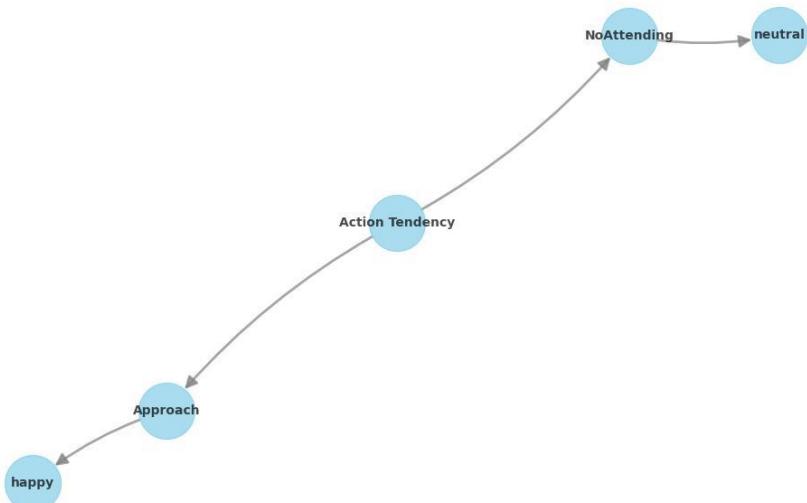


Figura 8 Inferencia en la clase Frijda_Action_Tendency para el Estudiante 2

En la Figura 8, se muestra que en la clase Frijda_Action_Tendency, se instanció Approach y NoAttending, esto quiere decir que, a partir de estados emocionales se puede analizar que tendencias de aprendizaje tiene cada estudiante, lo cual es clave para la retroalimentación del proceso de enseñanza - aprendizaje.

En el siguiente apartado, se abordará la metodología de validación de los resultados. Se llevará a cabo una exhaustiva validación de los resultados obtenidos en cada etapa de la

³ <https://github.com/stardog-union/pellet>

metodología. La validación se realizará para garantizar la precisión y la fiabilidad de los resultados obtenidos a partir del modelo ubicuo de análisis emocional.

3.2. Metodología para evaluar el modelo ubicuo de análisis emocional

En el contexto de la evaluación de emociones en clases en línea, es crucial contar con herramientas confiables y precisas para el reconocimiento emocional. En esta tesis, se emplea el software de reconocimiento de emociones Emotion Recognition como una herramienta fundamental para capturar y analizar las emociones manifestadas en el rostro de los participantes durante el proceso educativo en línea. Además, se utiliza el enfoque de las curvas Receiver Operating Characteristic (ROC) y el Area Under the Curve (AUC) como métrica para evaluar la precisión de las predicciones realizadas por el software.

Para garantizar un análisis riguroso, se requiere la participación de expertos, quienes a partir de las características emocionales MAYORES y MENORES, verificarán si lo inferido por la ontología tiene validez científica. Se considera esencial medir el nivel de acuerdo entre los expertos. Para ello, se utiliza el coeficiente de Kappa, una medida estadística que permite evaluar si la concordancia entre los observadores en un conjunto de datos supera lo que podría esperarse por simple azar. El coeficiente Kappa proporciona una medida objetiva y cuantitativa del acuerdo entre los expertos en la clasificación de las emociones y las tendencias a la acción, lo que ayuda a evaluar la consistencia y confiabilidad de los resultados obtenidos.

El uso del coeficiente Kappa garantiza un análisis riguroso y objetivo de la concordancia entre los expertos. Al comparar las clasificaciones de las características emocionales y las tendencias a la acción, se establece un marco de referencia sólido para evaluar la calidad y coherencia de los resultados obtenidos. Además, El coeficiente Kappa permite determinar si existe un acuerdo significativo entre los expertos y, entre la ontología y los expertos más allá de lo que se podría esperar por azar, lo que aumenta la validez y fiabilidad de los hallazgos.

El nivel de acuerdo medido por el coeficiente Kappa proporciona una evaluación precisa de la consistencia y confiabilidad de los resultados semánticos obtenidos. Si el nivel de acuerdo entre los expertos es alto, indica una coherencia y consistencia en la observación de las emociones y las tendencias a la acción. Por el contrario, un nivel de acuerdo bajo puede indicar discrepancias y diferencias en la interpretación de los resultados. La medición del nivel de acuerdo a través del coeficiente Kappa es esencial para garantizar la calidad y

validez de los resultados obtenidos en el análisis emocional basado en la ontología (Abraira, 2001).

Para facilitar el manejo del modelo ubicuo de análisis emocional aplicado en clases en línea, se desarrolló una interfaz intuitiva que integra todos los pasos mencionados en la metodología. Esta interfaz, implementada en Python, permite a los usuarios cargar los datos obtenidos por el software de reconocimiento de emociones, ejecutar el algoritmo KMEANS y realizar la inferencia de las tendencias a la acción. De esta manera, se brinda una visualización clara y una experiencia de uso fluida del modelo ubicuo.

En los siguientes apartados de esta sección, se explica cómo se realizó la validación de los resultados obtenidos en cada etapa de la metodología.

3.2.1 Validación del software de reconocimiento de emociones

El rendimiento del software de reconocimiento de emociones se evalúa meticulosamente utilizando las curvas ROC para cada participante. Estas curvas son una herramienta invaluable para medir la precisión de las predicciones realizadas por el software al trazar la relación entre la sensibilidad y la especificidad de una prueba de clasificación. Esta evaluación permite determinar cuán efectivo es el software en la identificación y clasificación precisa de las emociones manifestadas (Gneiting y Vogel, 2018).

En línea con investigaciones anteriores, como el estudio realizado por Raes et al. (2020), se requiere la participación de dos expertos para el análisis de los resultados del software de reconocimiento de emociones. Estos expertos especializados en psicopedagogía aportan su conocimiento sobre las emociones en el contexto educativo.

La presencia de estos dos expertos en el análisis del software de reconocimiento de emociones asegura una evaluación integral y multidisciplinaria. La experiencia y conocimientos combinados de ambos profesionales permiten una revisión exhaustiva de las predicciones del software, considerando tanto los aspectos emocionales y pedagógicos. Esta colaboración interdisciplinaria garantiza una evaluación rigurosa y una interpretación precisa de los resultados obtenidos.

3.2.2 Validación semántica

Los expertos desempeñan un papel fundamental en la observación de las características emocionales de los estudiantes, para ello los expertos observan los videos grabados de las clases en línea y asignan una etiqueta de “característica emocional MAYOR” o “característica emocional MENOR” a cada una de las características observadas. Una característica MAYOR

se refiere a la/s características emocionales más frecuentes en los participantes, mientras que una característica MENOR se relaciona con la/s características emocionales menos frecuentes detectadas en el estudio.

La distinción entre características emocionales MAYORES y MENORES permite una organización estructurada y significativa de los resultados del análisis emocional. Al agrupar las emociones en estas categorías, se simplifica y sistematiza la interpretación de los datos, lo que facilita la identificación de las emociones más relevantes y significativas para el proceso de enseñanza-aprendizaje en línea.

Para evaluar los resultados semánticos de la ontología, se lleva a cabo una comparación entre las características emocionales (MAYORES y MENORES) identificadas por los expertos versus los resultados obtenidos por la clase Frijda_Action_Tendency en la ontología HASIO. La clase Frijda_Action_Tendency representa las tendencias a la acción asociadas a las emociones.

La comparación entre las características emocionales y las tendencias a la acción proporciona información valiosa sobre la congruencia y correspondencia entre las emociones detectadas y los posibles comportamientos que pueden desencadenar. Se analiza si las características emocionales identificadas por los expertos están en línea con las tendencias a la acción inferidas por la ontología.

Para medir el nivel de acuerdo tanto entre los expertos como entre la ontología y los expertos en la clasificación de las características emocionales, se utilizó el coeficiente Kappa que tal y como previamente se ha mencionado permite evaluar la concordancia entre observadores en un conjunto de datos, teniendo en cuenta la concordancia que podría ocurrir por simple azar.

Al considerar la concordancia más allá de lo que podría ocurrir por azar, se asegura la fiabilidad y consistencia de los resultados. Esta medida estadística es fundamental para establecer la validez y confiabilidad de los resultados semánticos obtenidos a partir de la ontología y el análisis emocional realizado.

A continuación, en el siguiente apartado, se detalla el desarrollo de la interfaz del modelo ubicuo y se explicará cómo se llevan a cabo cada uno de los pasos mencionados en la metodología.

3.3. Interfaz del modelo ubicuo

Los pasos mencionados en la metodología han sido ubicados dentro de una interfaz o pantalla principal para facilidad del usuario. Para ello se programó en Python una interfaz (Figura 9) que recoge los pasos explicados en la sección 3.1.1 y 3.1.2 de la metodología. Python es un lenguaje de programación de alto nivel y multiparadigma, ya que admite múltiples estilos de programación, incluyendo programación orientada a objetos, programación imperativa y programación funcional (Jalolov, 2023).

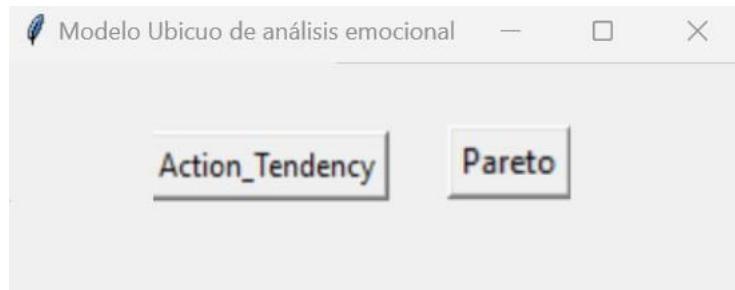


Figura 9 Interfaz del modelo ubicuo de análisis emocional desarrollada en Python

La Figura 9 muestra la interfaz del modelo ubicuo de análisis emocional para clases en línea, la interfaz presenta dos opciones explicadas a continuación.

3.3.1 Opción “Action_Tendency”

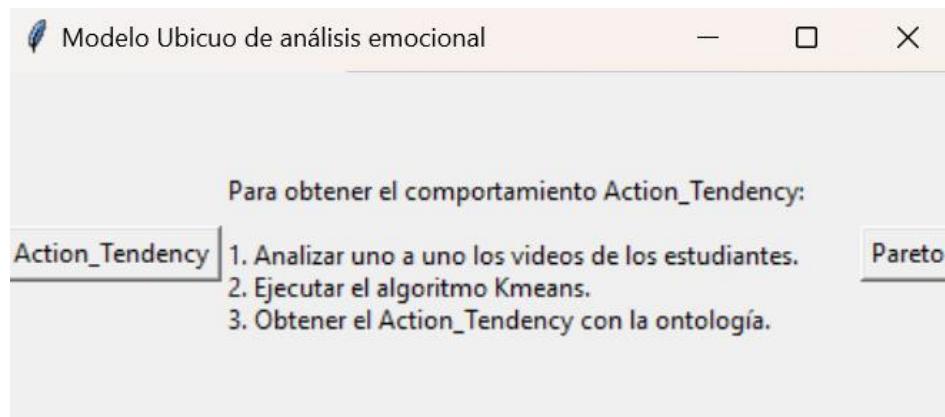


Figura 10 Opción “Action_Tendency”

1. La primera opción llamada “Action_Tendency” (Figura 10) obtiene las tendencias a la acción para cada estudiante; para ello, la interfaz recibe como entrada uno a uno los videos por cada estudiante grabados durante las clases en línea, el video se carga en la interfaz y se llama automáticamente al software de reconocimiento de emociones, el cual va a registrar las emociones detectadas en el rostro con su porcentaje de ocurrencia.

2. Luego se ejecuta el algoritmo KMEANS que recibe como entrada el archivo de las emociones detectadas con su porcentaje de ocurrencia realizado en el paso 1 dispuesto en vectores de siete columnas y crea automáticamente los clusters emocionales para cada estudiante.
3. Finalmente, el modelo automáticamente toma los clusters emocionales que arrojó KMEANS, selecciona la ontología HASIO, instancia las clases, llama al razonador Pellet e infiere las tendencias a la acción de Frijda para cada estudiante.

3.3.2 Opción “Pareto”

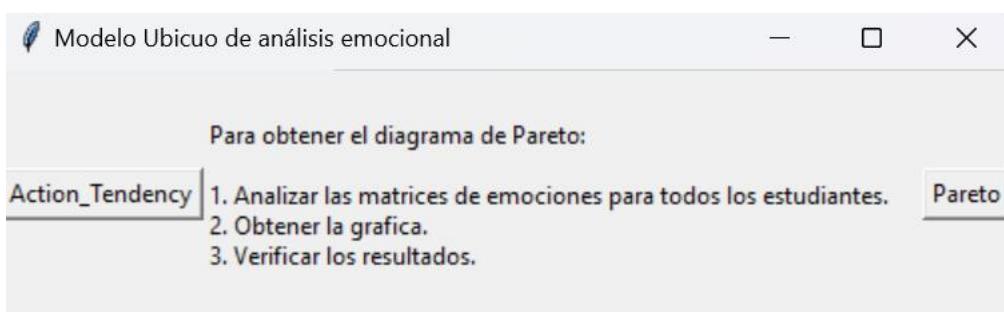


Figura 11 Opción “Pareto”

1. La segunda opción llamada “Pareto” (Figura 11) obtiene las emociones predominantes de los estudiantes en la clase en línea; para ello, la interfaz recibe como entrada todos los archivos individuales de los estudiantes que obtuvo el software de reconocimiento de emociones.
2. Grafica el archivo de entrada mediante columnas ubicadas de mayor a menor mediante el diagrama de Pareto con el fin de medir la frecuencia de cada emoción graficada con su porcentaje acumulado.
3. Por último, se identifica el 20% superior de las emociones. Según el principio de Pareto, un conjunto selecto de factores (20%) tiene un impacto significativo (80%) en los resultados emocionales.

La metodología del modelo ubicuo de análisis emocional aplicada en clases en línea permite registrar y analizar emociones detectadas en los rostros de los estudiantes, así como también inferir y validar las tendencias a la acción para el aprendizaje. Mediante el uso del software de reconocimiento facial, el principio de Pareto y técnicas de agrupamiento se

identifica las **emociones más comunes** experimentadas durante las clases en línea y **genera clusters emocionales**. Esto proporciona una visión general del estado emocional de los estudiantes y un análisis más detallado de las emociones presentes en cada grupo.

Además, al emplear la ontología HASIO, se infiere **tendencias a la acción** partiendo de estados emocionales de los estudiantes, brindando así información valiosa sobre el comportamiento humano asociado a dichas emociones.

3.4. Conclusiones

En este capítulo, se presenta la metodología del modelo ubicuo para el análisis emocional en el contexto de clases en línea. Se abordan diversos aspectos, comenzando por la aplicación de la metodología para registrar y analizar las emociones manifestadas por los estudiantes. Se explica cómo se utiliza el software de reconocimiento de emociones para obtener información en tiempo real sobre sus emociones. Luego, se describe la metodología específica para evaluar el modelo, incluyendo los criterios y métricas utilizados.

La validación del software de reconocimiento de emociones es esencial para garantizar su correcto funcionamiento y precisión en la detección y clasificación de las emociones faciales.

La validación semántica es otro aspecto fundamental del análisis emocional. La comparación entre las características emocionales (MAYORES y MENORES) identificadas por los expertos versus los resultados obtenidos por la clase Frijda_Action_Tendency en la ontología HASIO permite establecer conexiones significativas entre las características emocionales identificadas y las posibles acciones o respuestas asociadas a ellas.

Finalmente, se presenta una descripción detallada de la interfaz desarrollada para implementar el modelo ubicuo de análisis emocional. La interfaz integra los pasos mencionados en la metodología, permitiendo una visualización clara y una experiencia fluida de uso.

En el siguiente apartado, se detalla la experimentación y aplicación de la metodología, incluyendo la selección de emociones, la clasificación de los clusters emocionales, la inferencia de tendencias a la acción y la validación de la ontología HASIO. Una vez obtenidas las tendencias a la acción, estas pueden ser utilizadas para retroalimentar las clases en línea y mejorar el proceso de enseñanza-aprendizaje. La metodología del modelo ubicuo brinda una visión completa y efectiva para comprender las emociones en el contexto educativo y mejorar el apoyo emocional de los estudiantes.

CAPÍTULO IV. EXPERIMENTOS

Este capítulo ofrece una síntesis detallada de los resultados y descubrimientos más significativos derivados de una serie de experimentos relacionados con el modelo ubicuo de análisis emocional en el contexto de las clases en línea. El propósito fundamental de estos experimentos ha sido profundizar en la comprensión de las emociones en el entorno educativo en línea, caracterizado por la ausencia de interacciones presenciales cara a cara entre profesores y estudiantes. Se buscaba, en esencia, obtener información valiosa acerca del estado emocional de los estudiantes y, a partir de ello, inferir las tendencias que influyen en sus acciones de aprendizaje y cómo estas tendencias inciden en su comportamiento emocional.

Estos hallazgos no solo brindan una sólida base de conocimiento, sino que también tienen un propósito práctico fundamental: adaptar y mejorar las estrategias de enseñanza. Además, permiten proporcionar un apoyo emocional más efectivo a los estudiantes y fomentar la creación de un entorno de aprendizaje en línea que sea no solo eficaz desde el punto de vista académico, sino también propicio para el desarrollo emocional de los estudiantes. Esto es particularmente relevante ya que las emociones desencadenan una serie de funciones significativas en el ser humano y ejercen un papel fundamental como motivadores del comportamiento futuro, tal como sostienen Tooby y Cosmides (2008).

En los párrafos siguientes, se presentarán los aspectos clave de cada experimento, así como las implicaciones que se derivan de estos hallazgos, con el objetivo de arrojar luz sobre cómo la comprensión de las emociones puede transformar y enriquecer la experiencia educativa en línea.

El primer experimento se enfoca en el objetivo central de esta tesis, que busca **desarrollar un modelo ubicuo semántico que permita el registro emocional y la inferencia de tendencias a la acción en el aprendizaje durante las clases en línea grabadas en video**. Para lograr este registro emocional, se empleó el software de reconocimiento de emociones conocido como Emotion Recognition, cuyo rendimiento fue evaluado utilizando las curvas Receiver Operating Characteristic (ROC) y el Area Under the Curve (AUC). Estas curvas ROC proporcionan una medida de la habilidad del software para discernir la presencia o ausencia de emociones en los rostros de los estudiantes.

Los resultados obtenidos por el software Emotion Recognition son archivos individuales para cada estudiante, los cuales contienen un registro de las emociones detectadas junto con sus respectivos porcentajes de ocurrencia. Estos archivos individuales se utilizan como datos de entrada tanto para el segundo y tercer experimento, lo que permite una

exploración más profunda de las emociones y sus implicaciones en el entorno educativo de las clases en línea.

El segundo experimento se encuentra estrechamente vinculado al primer objetivo específico, que consiste en **determinar las emociones predominantes en una clase en línea mediante la identificación de emociones en el rostro de los estudiantes**. Para llevar a cabo este proceso, se aplicó el principio de Pareto a los archivos individuales de cada estudiante obtenidos previamente por el software Emotion Recognition en el primer experimento. Los resultados de este experimento son de gran relevancia, ya que permiten comprender el estado emocional predominante de los estudiantes durante las clases en línea, lo que contribuye de manera significativa a nuestra comprensión de su experiencia emocional en este entorno educativo.

El tercer experimento se enfocó en alcanzar el segundo objetivo específico de esta investigación, que se concentra en **crear clusters emocionales que permitan una interpretación semántica del comportamiento emocional**. Para llevar a cabo este proceso, se empleó el algoritmo KMEANS, que agrupa las distintas emociones registradas en los archivos individuales de cada estudiante en clusters emocionales personalizados.

Estos clusters emocionales, que se generaron como resultado, desempeñan un papel fundamental como entrada para el cuarto experimento. El algoritmo KMEANS se constituye como una herramienta esencial para analizar en detalle las respuestas emocionales de los estudiantes.

El cuarto experimento se diseñó para abordar el tercer objetivo específico, que consiste en **inferir tendencias a la acción para el aprendizaje que sirvan de base para la retroalimentación del proceso de enseñanza-aprendizaje**. En este sentido, para inferir las tendencias a la acción se utilizó la ontología HASIO que recibe como entrada los cluster emocionales generados previamente por KMEANS para cada estudiante. El propósito principal de esta etapa fue inferir tendencias a la acción basándose en estados emocionales detectados.

Este enfoque permitió obtener una comprensión más profunda de cómo las emociones básicas influyen en el comportamiento de los estudiantes, así como su relevancia para una educación personalizada en función de las necesidades emocionales y académicas de los estudiantes. Este enriquecimiento del proceso de enseñanza-aprendizaje en línea tiene el potencial de mejorar significativamente la experiencia educativa.

Finalmente, el quinto experimento se llevó a cabo con el ánimo de validar los resultados obtenidos por la ontología HASIO, como parte integral del tercer objetivo de esta tesis. Para ello, se realizó una comparación entre los resultados de la clase Frijda_Action_Tendency de la ontología HASIO y las evaluaciones realizadas por expertos. Para medir el grado de concordancia o acuerdo tanto entre los expertos como entre los expertos y la ontología se empleó la herramienta de evaluación conocida como el Coeficiente Kappa de Cohen.

En conjunto, estos experimentos proporcionan una comprensión sólida de la relevancia de considerar las emociones en el entorno educativo, particularmente en el contexto de las clases en línea. La capacidad para evaluar el desempeño del software de reconocimiento de emociones y discernir las emociones predominantes abre oportunidades significativas para mejorar la retroalimentación educativa y adaptarla a las necesidades emocionales individuales de los estudiantes.

Además, la aplicación del algoritmo KMEANS y la ontología HASIO para inferir tendencias a la acción basadas en estados emocionales introduce nuevas perspectivas para un análisis más pormenorizado y una retroalimentación altamente personalizada. Este modelo tiene el potencial de enriquecer de manera considerable el proceso de enseñanza-aprendizaje en línea al abordar de manera más efectiva las necesidades emocionales de los estudiantes.

En los siguientes apartados, se detallarán minuciosamente cada uno de los experimentos realizados, proporcionando una visión más completa de los procedimientos y resultados obtenidos en esta investigación.

4.1. Experimento No.1: Software de reconocimiento de emociones

El propósito fundamental de este experimento es emplear el software de reconocimiento de emociones Emotion Recognition, con el fin de evaluar su rendimiento en el registro de las emociones de los estudiantes. Este paso es de vital importancia en la construcción del modelo ubicuo de análisis emocional, y marca el punto de partida para todos los experimentos detallados en este capítulo, estableciendo así una conexión directa con el objetivo central de esta tesis.

4.1.1 Planteamiento del experimento

El experimento se caracteriza por los siguientes aspectos:

- Población: 33 videos de estudiantes, matriculados en la Universidad Técnica de Ambato que asistían regularmente a clases en línea.

- Duración promedio de los videos: aproximadamente 1 hora.
- Recursos humanos: 2 expertos en psicopedagogía.
- Software utilizado: Software de reconocimiento de emociones Emotion Recognition que sirve para capturar y analizar las expresiones faciales de los estudiantes durante las clases en línea.
- Herramientas de evaluación: Curva Receiver Operating Characteristic (ROC) y Area Under the Curve (AUC). Para evaluar el rendimiento del software Emotion Recognition, se utilizó las curvas ROC. Estas curvas muestran la relación entre la tasa de verdaderos positivos (Sensibilidad) y la tasa de falsos positivos (1 - Especificidad) a diferentes umbrales de clasificación. Los resultados de las curvas ROC se expresan mediante el Area Under the Curve (AUC), que resume la capacidad del software para distinguir entre clases positivas y negativas.

Este experimento plantea usar y evaluar el rendimiento del software de reconocimiento de emociones Emotion Recognition, para ello se utilizó las curvas ROC, y el juicio de los expertos actuando como *Ground truth*, que es información que se sabe que es real o verdadera, proporcionada por observación y medición directa (es decir, evidencia empírica) en oposición a la información proporcionada por inferencia.

La curva ROC se emplea como una herramienta estadística para medir la habilidad de discriminación de una prueba diagnóstica de naturaleza dicotómica. Esta representación gráfica muestra cómo la sensibilidad varía en relación con la tasa de falsos positivos (que es complementaria a la especificidad) en diferentes umbrales de decisión.

Para entender cómo funcionan las curvas ROC, es necesario comprender algunos conceptos (Ampudia et al., 2017):

1. Sensibilidad (tasa de verdaderos positivos): Es la proporción de casos positivos que fueron correctamente identificados por el modelo. En este contexto, se refiere a la capacidad del software para detectar correctamente las emociones presentes en los rostros de los estudiantes.
2. Especificidad (tasa de verdaderos negativos): Es la proporción de casos negativos que fueron correctamente identificados por el modelo. En este caso, se refiere a la capacidad del software para no detectar erróneamente emociones cuando no están presentes.

3. Falsos positivos: Se refiere a los casos en los que el modelo clasifica erróneamente una muestra negativa como positiva (es decir, detecta una emoción cuando no está presente).

4. Verdaderos positivos: Se refiere a los casos en los que el modelo clasifica correctamente una muestra positiva como positiva (es decir, detecta correctamente una emoción presente).

En una curva ROC, el eje X representa la tasa de falsos positivos (1 - Especificidad), mientras que el eje Y representa la tasa de verdaderos positivos (Sensibilidad). Cada punto en la curva corresponde a un umbral diferente utilizado para clasificar las muestras en positivas o negativas. Al variar el umbral, se obtienen diferentes pares de Sensibilidad y Especificidad, lo que resulta en una curva.

La interpretación de una curva ROC se basa en el área AUC. El AUC es una medida que resume la capacidad del modelo para distinguir entre clases positivas y negativas. Un AUC de 1.0 indica una clasificación perfecta, mientras que un AUC de 0.5 indica una clasificación aleatoria.

4.1.2 Resultados

4.1.2.1 Expertos versus Software de reconocimiento de emociones Emotion Recognition

El software de reconocimiento de emociones Emotion Recognition detecta en el rostro de cada participante varias emociones en una ventana de tiempo de 1 hora en promedio que dura el video de una lección y crea como resultado un archivo .csv para cada estudiante de las emociones con su porcentaje de ocurrencia asociado, tal como se puede ver en la Tabla 4 en donde se muestra un extracto del archivo .csv del Estudiante 1.

Tabla 4. Resultados del software Emotion Recognition (video del Estudiante 1)

	Emotions	Percent
T_1	angry	19,76
	disgust	0,14
	scared	3,80
	happy	4,79
	sad	8,80
	surprised	0,43
	neutral	62,27

T ₋₂	angry	19,28
	disgust	0,48
	scared	5,20
	happy	4,15
	sad	11,85
	surprised	0,91
	neutral	58,13
...
T ₋₃₄₃₇	angry	7,13
	disgust	0,36
	scared	5,02
	happy	10,35
	sad	8,53
	surprised	1,42
	neutral	67,19

En la Tabla 4, se observa los valores de ocurrencia que tiene cada emoción detectada por el software Emotion Recognition en una ventana de tiempo de 1 hora en promedio que es lo que duró la clase en línea. En este caso, para el Estudiante 1, el software obtuvo un archivo .csv que contiene valores de ocurrencia para cada una de las 7 emociones detectadas en el rostro, en cada ventana de tiempo T_{-i}. Por tanto, se genera un archivo que contiene 7 emociones (filas) con distintos valores de ocurrencia asociados a esas emociones, las mismas que se repiten a lo largo de toda la clase en línea, conformándose una matriz de n_x2. Es decir, T₋₁ fue el primer momento de la clase y así sucesivamente hasta el momento T₋₃₄₃₇ que fue el fin de la clase en línea. Este proceso que acabo de explicar es realizado para cada estudiante, puesto que el software Emotion Recognition analiza los 33 videos por separado, obteniendo 33 archivos .csv diferentes dispuestos de esta manera.

Ahora bien, se necesita que los expertos observen los 33 videos para verificar si existe acuerdo o no con lo detectado por el software Emotion Recognition en cada video. Entonces, la Tabla 4 que corresponde al Estudiante 1 es entregada a los expertos con el fin de que puedan verificar si existe acuerdo o no con lo observado. De tal manera que a los expertos se les entrega los 33 videos con los 33 archivos .csv.

Es necesario aclarar que algunos videos duran unos minutos más de una hora y otros menos, por eso la matriz que se genera para cada video tiene n filas en dependencia del tiempo que dura el video.

Durante la revisión de los videos, los expertos asignan un valor de 1 si están de acuerdo con las emociones detectadas por el software, y un valor de 0 en caso contrario, estableciendo así una dicotomía en la evaluación.

A continuación, en la Tabla 5 se muestra los resultados del software Emotion Recognition para el Estudiante 3, y los resultados del software para el resto de los estudiantes se adjuntan en el repositorio GitHub ⁴ creado para esta tesis.

Tabla 5. Resultados del software Emotion Recognition (video del Estudiante 3)

	Emotions	Percent
T_1	angry	21,49
	disgust	0,19
	scared	38,97
	happy	14,92
	Sad	3,95
	surprised	4,74
	neutral	15,74
T_2	angry	17,04
	disgust	0,03
	scared	26,24
	happy	16,25
	Sad	3,3
	surprised	6,38
	neutral	30,76
...
T_559	angry	11,81
	disgust	0,01
	scared	9,05
	happy	15,51
	Sad	4,53

⁴ https://github.com/SusiAT/IEEE_AUbiquitousModelofEmotionalTrackinginVirtualClasses7896

surprised	7,1
neutral	52

En la Tabla 6, se puede apreciar el proceso de construcción específico de la validación del software por los expertos para el video del Estudiante 3. Los resultados de la validación por expertos para el resto de los videos se adjuntan en el repositorio GitHub creado para esta tesis.

Para tener exactitud en los cálculos los expertos decidieron utilizar la metodología de ir observando cada emoción por cada T_{-i} y asignaron el acuerdo o desacuerdo correspondiente. En este contexto, las emociones identificadas por el software se presentan en forma numérica; es decir se asignó un número a cada una de las siete emociones de la siguiente manera: angry = 1; disgust = 2; scared = 3; happy = 4; sad = 5; surprised = 6; neutral = 7. Es relevante señalar que hay momentos en los que los expertos están de acuerdo con el software en ciertos intervalos de tiempo, mientras que, en otros, discrepan entre sí en relación con la evaluación realizada por el software.

Tabla 6. Expertos vs Resultados del Software Emotion Recognition (video del Estudiante 3)

Expertos	Software Emotion Recognition video Estudiante 3
T ₋₁	0
	1
	0
	1
	1
	1
	1
T ₋₂	0
	1
	0
	1
	1
	1
	1

	0	1
	1	2
	0	3
T_{-3}	1	4
	1	5
	1	6
	1	7
...
	0	1
	1	2
	0	3
T_{-559}	1	4
	1	5
	1	6
	1	7

En la Tabla 6, se observan los resultados del experimento para el Estudiante 3, la columna “Expertos” indica la opinión del experto (1 si está de acuerdo, 0 si no lo está) y, la columna “Software Emotion Recognition” muestra la codificación numérica de las emociones de 1 a 7 para el Estudiante 3. Además, en la columna “Expertos” se muestran los resultados de los dos expertos. Los expertos discutieron sobre sus opiniones hasta llegar a un acuerdo común en el análisis experimental.

4.1.2.2 Curva ROC

Para graficar la curva ROC del Estudiante 3 se usa la Tabla 6. Se codificó el software en Python para graficar las curvas ROC. En el repositorio GitHub se adjuntan las curvas ROC para cada uno de los 33 estudiantes.

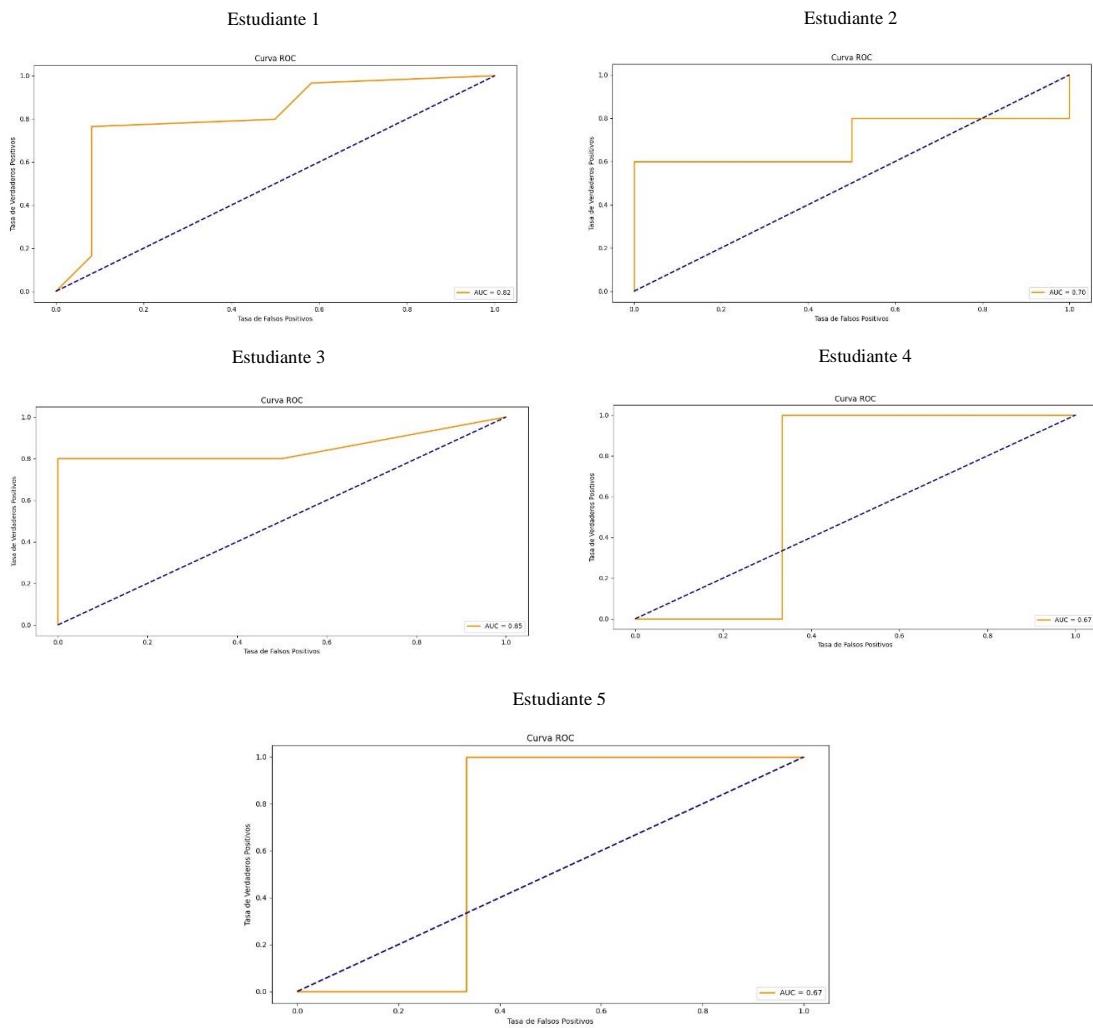


Figura 12 Curvas ROC del conjunto de emociones registradas en los rostros de 5 estudiantes

En la Figura 12, se presentan las curvas ROC para 5 de los 33 casos analizados, donde cada curva representa la capacidad del software para distinguir las emociones registradas en los rostros de los estudiantes.

Tabla 7. Datos de la curva ROC para los 33 estudiantes

No. Estudiantes	AUC
1	0,88
2	0,7
3	0,85
4	0,67
5	0,67

6	0,67
7	0,5
8	0,67
9	0,83
10	0,7
11	0,7
12	0,8
13	0,6
14	0,5
15	0,9
16	0,51
17	0,51
18	0,67
19	0,67
20	0,5
21	0,66
22	0,89
23	0,66
24	0,66
25	0,64
26	0,62
27	0,47
28	0,52
29	0,5
30	0,82
31	0,8
32	0,75
33	0,73

En la Tabla 7, los valores del AUC oscilan entre 0.47 y 0.9. Un AUC superior a 0.5 indica que el modelo tiene un rendimiento mejor que el azar, mientras que un AUC cercano a 1.0 indica un mejor rendimiento de clasificación.

4.1.3 Discusión

La discusión del texto se centra en la evaluación del rendimiento del software de reconocimiento de emociones Emotion Recognition utilizando curvas ROC y el juicio de expertos como “Ground truth”. En la Figura 12 se presentan las curvas ROC para 5 de los 33 casos analizados, lo que representa la capacidad del software para diferenciar emociones registradas en los rostros de los estudiantes.

Los resultados de la Tabla 6 contribuyen a realizar los siguientes análisis:

Acuerdo Mayoritario: En la mayoría de las situaciones (filas), los expertos están de acuerdo con las emociones detectadas por el Software Emotion Recognition. Esto se refleja en la alta cantidad de unos (1) en la columna “Expertos”. Esto sugiere que los expertos y el software están en sintonía en la mayoría de los casos.

Desacuerdo Ocasional: Aunque hay una concordancia mayoritaria, también existen algunas instancias en las que los expertos no están de acuerdo con el software. Estos son los casos en los que se registra un 0 en la columna “Expertos”. Es importante investigar estas discrepancias para comprender por qué ocurrieron y si hay patrones específicos.

En general, la Tabla 6 sugiere que los expertos y el software tienden a estar de acuerdo en la mayoría de las situaciones, lo que indica una cierta confiabilidad en el software de reconocimiento de emociones. Sin embargo, es importante prestar atención a los casos en los que no hay concordancia y analizarlos más a fondo para identificar las razones detrás de los desacuerdos.

En la Tabla 7, los valores de AUC presentados oscilan entre 0.47 y 0.9. Esto sugiere que el software de reconocimiento de emociones tiene una capacidad aceptable de acuerdo con Ampudia et al. (2017) para diferenciar entre emociones presentes y ausentes en los rostros de los estudiantes.

En el contexto de la evaluación de modelos de clasificación, el área AUC es una métrica que se utiliza para medir el rendimiento del modelo en términos de su capacidad para distinguir entre clases positivas y negativas. El valor del AUC varía entre 0 y 1, donde:

- Un AUC de 0.5 indica un rendimiento aleatorio o equivalente al azar. Esto significa que el modelo no es mejor que adivinar al azar.
- Un AUC por encima de 0.5 indica un rendimiento mejor que el azar, es decir, que el modelo tiene cierta capacidad para discriminar entre las clases, siendo 1 el valor máximo que indica una capacidad perfecta de discriminación.

Por lo tanto, en general:

- Valores de AUC cercanos a 1 (por ejemplo, 0.85, 0.88, 0.89, 0.9) indican que el modelo tiene un excelente rendimiento en la clasificación y es capaz de separar de manera efectiva las clases positivas de las negativas.
- Valores de AUC cercanos a 0.5 sugieren que el modelo tiene un rendimiento mediocre y es similar a una elección al azar.
- Valores de AUC por debajo de 0.5 indican que el modelo está clasificando incorrectamente y es peor que una elección al azar.

Por lo tanto, los AUC más elevados, tales como 0.85, 0.88, 0.89 y 0.9, señalan un desempeño superior en la tarea de clasificación, al tiempo que los AUC más bajos, como 0.47, sugieren que el modelo tiene dificultades o inconsistencias en su capacidad de clasificación. Un valor alto de AUC generalmente se relaciona con un modelo de clasificación sólido. No obstante, es esencial tener en mente que la elección de la métrica apropiada también depende del contexto específico de la aplicación y de los objetivos particulares de la clasificación.

Los resultados de la Tabla 7 contribuyen a realizar los siguientes análisis:

Varianza en los Valores de AUC: Los valores de AUC varían ampliamente en esta lista, desde tan bajos como 0.47 hasta tan altos como 0.9. Esto sugiere una variación significativa en el rendimiento del software.

Destacados Rendimientos: Para algunos estudiantes (por ejemplo, Estudiante1, Estudiante3, Estudiante9, Estudiante12, Estudiante15, Estudiante22 y Estudiante30) el software obtuvo valores de AUC notables cercanos a 0.9, lo que sugiere un rendimiento sólido del software.

Rendimientos Inferiores: Para el estudiante Estudiante27 el software obtuvo valores de AUC notoriamente bajos, lo que podría

indicar, por una parte, desafíos en la comprensión o aplicación de conceptos relacionados con la evaluación del software y por otra, fallos del software al momento de detectar las emociones.

La variabilidad en los valores de AUC puede deberse a la complejidad del problema, en el caso del análisis de emociones. Los valores más bajos de AUC pueden ser una oportunidad para la mejora del software. Los valores más altos de AUC indican una comprensión sólida del software.

A continuación, se explica en detalle la comparación del AUC con el azar y se destaca los rendimientos notables.

Comparación con el Azar (0.5): Para comprender plenamente el significado de los valores de AUC, es crucial compararlos con un valor de referencia. En este caso, el valor de referencia es 0.5, que representa una clasificación aleatoria, donde el modelo es tan bueno como lanzar una moneda al aire para tomar decisiones.

En la Tabla 7, podemos observar que:

- Estudiante 13 (AUC: 0.6): Este estudiante supera claramente el valor de referencia de 0.5. Esto sugiere que el software y los expertos están de acuerdo en sus evaluaciones a un nivel significativo. Aunque no es un rendimiento sobresaliente, es mejor que una elección al azar.
- Estudiante 28 (AUC: 0.52): Aquí vemos que el AUC es apenas superior a 0.5, lo que indica un rendimiento que apenas supera el azar. Esto podría significar que hay margen de mejora en la evaluación de este estudiante o en el modelo de detección de emociones.
- Estudiante 2,10,11 (AUC: 0.72): Estos estudiantes obtienen un AUC considerablemente alto, lo que sugiere un rendimiento sólido. Está claramente por encima de la clasificación aleatoria y puede considerarse un rendimiento destacado.
- Estudiante 3 (AUC: 0.85): El AUC de 0.85 indica un rendimiento muy fuerte en la tarea de detección de emociones. Con este estudiante se ha logrado una excelente concordancia entre el software y la evaluación de expertos.
- Estudiante 27 (AUC: 0.47): Contrariamente a los estudiantes mencionados anteriormente, este estudiante tiene un AUC notablemente bajo, incluso por debajo de 0.5. Esto indica un rendimiento deficiente y puede requerir un análisis más profundo para entender las causas.

Es importante destacar que un AUC no se interpreta solo en términos de su relación con 0.5. El contexto es esencial, y un AUC que sea “suficientemente bueno” depende del propósito de la evaluación y de las expectativas en ese contexto específico.

El análisis de los valores de AUC revela la variabilidad del modelo de clasificación en el rendimiento a la hora de detectar emociones. Los valores superiores a 0.5 indican que, en su mayoría, el software y los expertos están de acuerdo en sus evaluaciones, lo que sugiere un rendimiento mejor que el azar.

La comparación con el azar ayuda a contextualizar los valores de AUC y a identificar cuán significativos son en términos de la evaluación de emociones en el contexto de una clase en línea. Cuando AUC supera el azar pueden considerarse como aquellos casos que aportan un valor real en la clasificación, mientras que aquellos que están cerca de 0.5 pueden requerir una mejora en la clasificación del sistema o en la evaluación por parte de los expertos.

4.1.4 Conclusiones

Las curvas ROC proporcionan una representación visual de cómo el software de reconocimiento de emociones se desempeña en términos de sensibilidad (tasa de verdaderos positivos) y especificidad (tasa de verdaderos negativos) en diferentes umbrales de clasificación. La forma y la posición de estas curvas indican la sensibilidad y la especificidad del software en la detección de emociones.

El análisis de las curvas ROC y los valores de AUC proporciona una visión clara del rendimiento del software de reconocimiento de emociones Emotion Recognition en términos de su capacidad para identificar correctamente las emociones en los rostros de los estudiantes.

El análisis de las curvas ROC y el valor AUC también puede ayudar a identificar las fortalezas y debilidades del software en la detección de emociones específicas.

El software de reconocimiento de emociones tiene una capacidad aceptable de acuerdo con Ampudia et al. (2017) para diferenciar entre emociones presentes y ausentes en los rostros de los estudiantes, debido a que los valores de AUC presentados oscilan entre 0.47 y 0.9.

El valor del Área Bajo la Curva (AUC) es una métrica cuantitativa. Cuanto mayor sea el AUC, mayor será la capacidad del software para realizar una clasificación precisa de las emociones. Un AUC cercano a 1 indica un rendimiento sobresaliente en la detección de emociones.

La capacidad del software para detectar emociones de manera precisa y eficiente es crucial en aplicaciones prácticas, como la educación en línea. Un rendimiento sólido en las métricas de evaluación respalda la utilidad práctica del software en contextos educativos.

4.2. Experimento No.2: Principio de Pareto

El propósito de este experimento consiste en aplicar el principio de Pareto para determinar cuáles son las emociones predominantes experimentadas en las clases en línea, lo que constituye un paso crucial hacia la consecución del primer objetivo específico establecido en esta tesis.

4.2.1 Planteamiento del experimento

El experimento se caracteriza por los siguientes aspectos:

- Población: 33 estudiantes, matriculados en la Universidad Técnica de Ambato que asistían regularmente a clases en línea.
- Técnica aplicada: Principio de Pareto y diagrama de Pareto aplicado al conjunto de emociones obtenidas por el software de reconocimiento de emociones Emotion Recognition. Esto permitió identificar las emociones más relevantes, para priorizar su análisis y comprensión.

Este experimento plantea el uso del diagrama de Pareto que se apoya en el principio de Pareto y recibe como entrada todos los archivos individuales .csv de los estudiantes que obtuvo el software de reconocimiento de emociones para graficarlos en Python mediante columnas ubicadas de mayor a menor mediante el diagrama de Pareto con el fin de medir la frecuencia de cada emoción graficada con su porcentaje acumulado.

4.2.2 Resultados

En la Figura 13 se presenta el diagrama de Pareto que ilustra la distribución de las emociones básicas registradas por el software de reconocimiento de emociones para todos los estudiantes durante el tiempo que dura la clase en línea. En el eje X, se representan las diferentes emociones, y en el eje Y, se muestran los porcentajes correspondientes a cada emoción. Las emociones se presentan en orden descendente, de izquierda a derecha, según su frecuencia. Las barras de color azul representan el porcentaje de contribución de cada emoción a la dinámica de la clase en línea. La barra de color rojo que se superpone al gráfico representa el porcentaje acumulado de la frecuencia total.

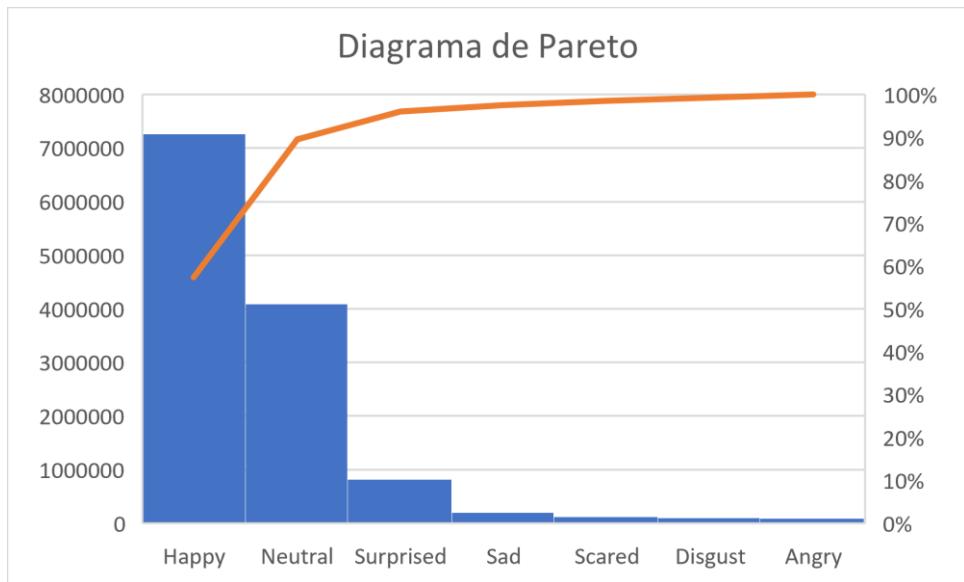


Figura 13 Diagrama de Pareto: emociones básicas en una clase en línea

En este trabajo, para el diagrama de Pareto el archivo de entrada es el compilado del registro de las emociones en rostro de los 33 estudiantes. Es decir, si por cada estudiante se tiene un fichero .csv que contiene sus registros faciales emocionales, cada uno de esos ficheros .csv se une en uno solo y se obtiene un fichero .csv de los 33 estudiantes. En el repositorio GitHub se adjuntan los ficheros de cada uno de los 33 estudiantes, el fichero final con los datos de los 33 estudiantes y los cálculos del análisis de emociones.

El proceso para obtener la Figura 13 trabaja con el porcentaje total de cada emoción (el porcentaje total se calcula como la suma de porcentajes obtenidos en todos los tiempos, por ejemplo, desde T_{-1} hasta T_{-3437} para el estudiante 1), luego se ordena de mayor a menor porcentaje, y se calcula el porcentaje acumulado, por último, se identifica el 20% superior.

En la Figura 13 se observa que las emociones happy y neutral se corresponden al 20 % superior.

Aquí está la conexión con el principio de Pareto:

1. Concentración en lo significativo:

El análisis destaca happy, neutral y surprised como las emociones más relevantes, representando el 61,04%. Este enfoque se alinea con la idea de la regla 80/20, donde un pequeño conjunto (20%) de las emociones predominantes tiene un impacto significativo (80%) en los efectos.

2. Priorización de recursos:

Identificar el 20% superior (happy y neutral) permite concentrar esfuerzos en áreas emocionales clave. En el contexto del análisis de emociones, esto implica que un

grupo selecto de estados emocionales puede tener un impacto sustancial en la respuesta del estudiante a la clase y en su proceso de aprendizaje.

En este punto, cabe definir lo que es estado emocional vs. emoción. Un estado emocional es una experiencia emocional más amplia y prolongada que puede involucrar múltiples emociones; es decir, una experiencia emocional abarca las diversas emociones que un individuo experimenta en un contexto particular. En contraste, una emoción es una respuesta emocional específica a un estímulo particular (Frijda, 1986).

Las emociones happy y neutral son identificadas como el 20% superior en base al principio de Pareto o la regla 80/20. Según este principio, el 80% de los resultados provienen del 20% de las causas. En el contexto del análisis de emociones, concentrarse en happy y neutral, refleja la aplicación de esta regla. Este enfoque se alinea con la idea de que un conjunto selecto de factores (20%) tiene un impacto significativo (80%) en los resultados emocionales.

Esto sugiere que unos pocos estados emocionales, que representan el 20%, son responsables de la mayoría de los resultados que benefician o dificultan el proceso de aprendizaje, como por ejemplo la participación del estudiante en la clase y su capacidad para aprender (Alzina, 2008). Comprender cómo estos estados emocionales influyen en el proceso educativo puede ayudar a los educadores a diseñar entornos de aprendizaje más efectivos y a fomentar un compromiso más profundo por parte de los estudiantes.

4.2.3 Discusión

La interpretación de los resultados de la Figura 13, ofrece una perspectiva valiosa sobre la distribución de las emociones en un entorno de clase en línea. En el contexto de las emociones en una clase en línea, este principio se traduce en que un conjunto selecto de emociones ejerce una influencia desproporcionadamente mayor en la respuesta emocional de los estudiantes en la clase.

El análisis de la Figura 13 destaca que las emociones happy y neutral representan el 20% del total de las emociones observadas. En otras palabras, la mayoría de las respuestas emocionales de los estudiantes en este contexto están centradas en estas dos emociones.

Estos hallazgos son significativos porque sugieren que la respuesta emocional predominante de los estudiantes en esta clase en línea está relacionada principalmente con las emociones happy y neutral de acuerdo con el principio de Pareto. Esto puede tener

varias implicaciones importantes para la comprensión del estado emocional de los estudiantes durante el proceso de enseñanza-aprendizaje en entornos en línea que están descritas a continuación.

Foco en emociones clave:

Si las emociones de happy y neutral son las más representativas, los educadores y diseñadores de cursos en línea pueden centrar sus esfuerzos en comprender y abordar estas emociones en particular. Esto podría llevar a estrategias más efectivas para gestionar y mejorar la experiencia emocional de los estudiantes.

Intervenciones específicas:

Identificar las emociones predominantes puede ayudar a diseñar intervenciones específicas para abordar las necesidades emocionales de los estudiantes. Por ejemplo, se podrían desarrollar recursos para ayudar a los estudiantes a lidiar con sentimientos de irritación, frustración, enojo y hostilidad (emociones asociadas al enfado) (Parkinson, 2019).

Mejora de la retención y el compromiso: Comprender las emociones predominantes puede ayudar a mejorar la retención de estudiantes y su compromiso en el proceso de aprendizaje en línea. Si los estudiantes se sienten más satisfechos emocionalmente, es más probable que continúen participando activamente en el curso (Hartnett, 2016).

Este hallazgo tiene importantes implicaciones para comprender la dinámica emocional en el entorno de enseñanza-aprendizaje en línea. La predominancia de las emociones happy y neutral podría ser indicativa de varios aspectos. En primer lugar, la neutralidad puede reflejar una actitud neutral o falta de reacción emocional hacia el contenido presentado, lo que podría deberse a diversos factores. Por otro lado, el obtener como resultado la emoción happy puede representar la aceptación de desafíos específicos que los estudiantes enfrentan en el entorno en línea, y la comprensión de los materiales presentados.

Estos resultados subrayan la importancia de considerar la dimensión emocional en la educación en línea. La identificación de emociones predominantes puede permitir a los educadores y diseñadores de cursos tomar medidas específicas para abordar las necesidades emocionales de los estudiantes. Estrategias para fomentar una mayor interacción social, mejorar la claridad de los materiales o crear un ambiente en línea más atractivo podrían ayudar a mitigar la prevalencia del “enfado” y fomentar emociones más positivas, enriqueciendo así la experiencia educativa en línea.

Ciertamente, el enfoque basado en el principio de Pareto descrito anteriormente ha sido aplicado para identificar aquellas emociones que más predominan en una clase en línea. Sin embargo, en el trabajo propuesto por Neoh et al. (2015) se utiliza el principio de Pareto para crear un sistema de reconocimiento de emociones faciales con un modelo de optimización en cascada de codificación por capas, el cual se centra en optimizar características que mejor representan cada categoría de emociones y al mismo tiempo proporcionan la mayor cantidad de distinciones con respecto a otras emociones utilizando un algoritmo de optimización de características basado en Pareto con el ánimo de incorporar funciones más discriminantes.

4.2.4 Conclusiones

La aplicación del principio de Pareto resulta beneficiosa para detectar las emociones que destacan con mayor frecuencia en un conjunto de datos, brindando así valiosa información sobre cuáles emociones son las más comunes en el ámbito de las clases en línea.

El principio de Pareto se ha mostrado efectivo para identificar las emociones que prevalecen en un entorno de clases en línea. Esto permite a los investigadores y educadores comprender mejor el panorama emocional de los estudiantes.

Al conocer las emociones predominantes, las instituciones educativas pueden priorizar intervenciones específicas para abordar las necesidades emocionales de los estudiantes.

La identificación de las emociones predominantes también puede contribuir a mejorar la experiencia del estudiante. Al abordar las emociones más comunes, las clases en línea pueden diseñarse de manera más efectiva para promover un entorno emocionalmente saludable y positivo.

Comprender las emociones predominantes permite la personalización del aprendizaje. Los educadores pueden adaptar sus enfoques pedagógicos para abordar las necesidades emocionales de los estudiantes, lo que puede conducir a un aprendizaje más efectivo y satisfactorio.

El uso del principio de Pareto para monitorear las emociones en clases en línea también facilita la evaluación de la efectividad de las intervenciones implementadas. Los cambios en la distribución de las emociones pueden indicar si las estrategias están teniendo un impacto positivo.

Investigaciones centradas en el principio de Pareto en el contexto de la educación en línea pueden motivar la realización de estudios adicionales que examinen la conexión entre las emociones y el proceso de aprendizaje. Además, estas investigaciones pueden abrir nuevas oportunidades para explorar cómo las estrategias pedagógicas pueden influir y modificar las emociones de los estudiantes.

Se debe mencionar que las conclusiones basadas en el principio de Pareto deben interpretarse en el contexto específico de cada clase en línea y sus características. Las emociones predominantes pueden variar según la asignatura y el alumnado, entre otros factores contextuales.

4.3. Experimento No.3: Algoritmo KMEANS

El objetivo principal de este experimento radica en la aplicación del algoritmo KMEANS para la generación de clusters emocionales a partir de las emociones básicas registradas por los estudiantes. Estos clusters se emplearán como datos de entrada en el siguiente experimento, con la finalidad de reducir la presencia de datos redundantes o irrelevantes. Este propósito guarda una estrecha relación con el segundo objetivo específico establecido en esta investigación.

4.3.1 Planteamiento del experimento

El experimento tiene las siguientes características:

- Población: 33 estudiantes, matriculados en la Universidad Técnica de Ambato que asistían regularmente a clases en línea.
- Entrada: 33 archivos de emociones .csv registrados por el software Emotion Recognition.
- Técnica de agrupamiento: Algoritmo KMEANS, se utilizó el algoritmo KMEANS para agrupar las emociones registradas por el software Emotion Recognition en estados emocionales para cada estudiante.

Este experimento plantea el uso del algoritmo KMEANS que recibe como entrada los 33 archivos .csv de los estudiantes y analiza cada archivo individualmente, estos archivos

contienen la información de las emociones con su porcentaje asociado, obtenido mediante el software Emotion Recognition. Cada uno de los archivos de entrada .csv fueron dispuestos en vectores de 7 columnas; es decir por cada T_{-i} , los vectores de entrada ahora tienen 7 elementos numéricos asociados a cada una de las 7 emociones, lo que representaría un estado emocional desde el primer momento de la clase en línea hasta su finalización, para cada estudiante. Por tanto, todo el conjunto de vectores en todos los tiempos registrados en el video conforma el archivo de entrada para el algoritmo KMEANS y son estos grupos de estados emocionales los que son analizados en este experimento para cada estudiante, ver Tabla 8.

Tabla 8. Archivo de entrada para KMEANS del Estudiante 1

Tiempo (seg.)	Emociones básicas del Estudiante 1						
	angry	disgust	scared	happy	sad	surprised	neutral
T_{-1}	19.76	0.14	3.8	4.79	8.8	0.43	62.27
T_{-2}	19.28	0.48	5.2	4.15	11.85	0.91	58.13
T_{-3}	12.64	0.32	3.05	3.48	5.78	0.74	74.0
T_{-4}	8.35	0.1	2.32	4.57	4.49	0.76	79.41
T_{-5}	7.23	0.2	2.5	7.03	4.44	0.8	77.81
T_{-6}	8.86	0.37	3.48	5.19	4.57	1.33	76.2
T_{-7}	7.05	0.51	2.72	8.37	3.04	1.81	76.5
T_{-8}	4.05	0.19	1.86	4.4	2.74	0.42	86.34
T_{-9}	5.13	0.32	2.01	7.54	3.51	0.54	80.96
T_{-10}	8.09	2.71	3.38	3.78	4.11	1.26	76.66
...
T_{-3437}	7.13	0.36	5.02	10.35	8.53	1.42	67.19

A partir del archivo de entrada mostrado en la Tabla 8, se ejecuta el algoritmo KMEANS mediante la interfaz programada en Python y se genera clusters emocionales para el Estudiante 1.

En la Tabla 8, los diferentes intervalos de tiempo T_{-i} de la clase en línea significan que en T_{-1} se representa un estado emocional para el Estudiante 1 al iniciar la clase y así sucesivamente hasta el tiempo T_{-n} que para el caso del Estudiante 1 llega hasta T_{-3438} que fue el final de la clase en línea.

Para la agrupación, el algoritmo KMEANS selecciona aleatoriamente centroides en base al número de clusters que se configure y se calcula en base a la distancia euclídea las emociones que se corresponden con ese centroide, lo que permite crear un cluster.

El centroide es un valor numérico que corresponde al promedio de los valores (que tienen las diferentes emociones) de las entradas que pertenecen a ese cluster.

La distancia euclídea mide la longitud del camino más corto entre el centroide y cada emoción. Cuanto más cercanas estén dos emociones en términos del porcentaje de ocurrencia, menor será la distancia euclídea entre ellas y serán asignadas al mismo cluster.

De esta manera el algoritmo KMEANS genera clusters emocionales para el Estudiante 1 durante la clase en línea completa grabada en video. Este mismo proceso se realiza para cada uno de los 33 estudiantes.

Pero, antes de realizar la agrupación primero fijamos el número de clusters k que tendrá la partición. Existen diferentes técnicas que nos permiten ayudar a estimar el número k , tales como el método del codo según Humaira y Rasyidah (2020); el método de la silueta según Rousseeuw (1987); el método de la validación cruzada según Kaufman y Rousseeuw (2009) entre otros.

Para este experimento elegimos el método del codo que consiste en calcular la suma intra-cluster para diferentes valores de k . La suma intra-cluster es una medida de la proximidad de los puntos dentro de un clúster. A medida que aumenta el valor de k , la suma intra-cluster disminuye. El valor de k donde la suma intra-cluster disminuye abruptamente se considera el número de k óptimo (Humaira y Rasyidah, 2020).

Elegir el número de k correcto es crucial para obtener resultados óptimos. Según el número de clusters k se crearán los centroides. Por tanto, los centroides son valores calculados que indican el centro del grupo en el espacio de atributos.

Se programó el método del codo en Python, se tomó como entrada los datos de los 33 archivos .csv que corresponden a los 33 estudiantes. Se representó gráficamente los resultados obtenidos con cada uno y se identificó aquel punto de la curva a partir del cual la mejora deja de ser sustancial (principio de verosimilitud).

En la Figura 14 se muestra la ejecución del método del codo para los primeros 5 archivos.

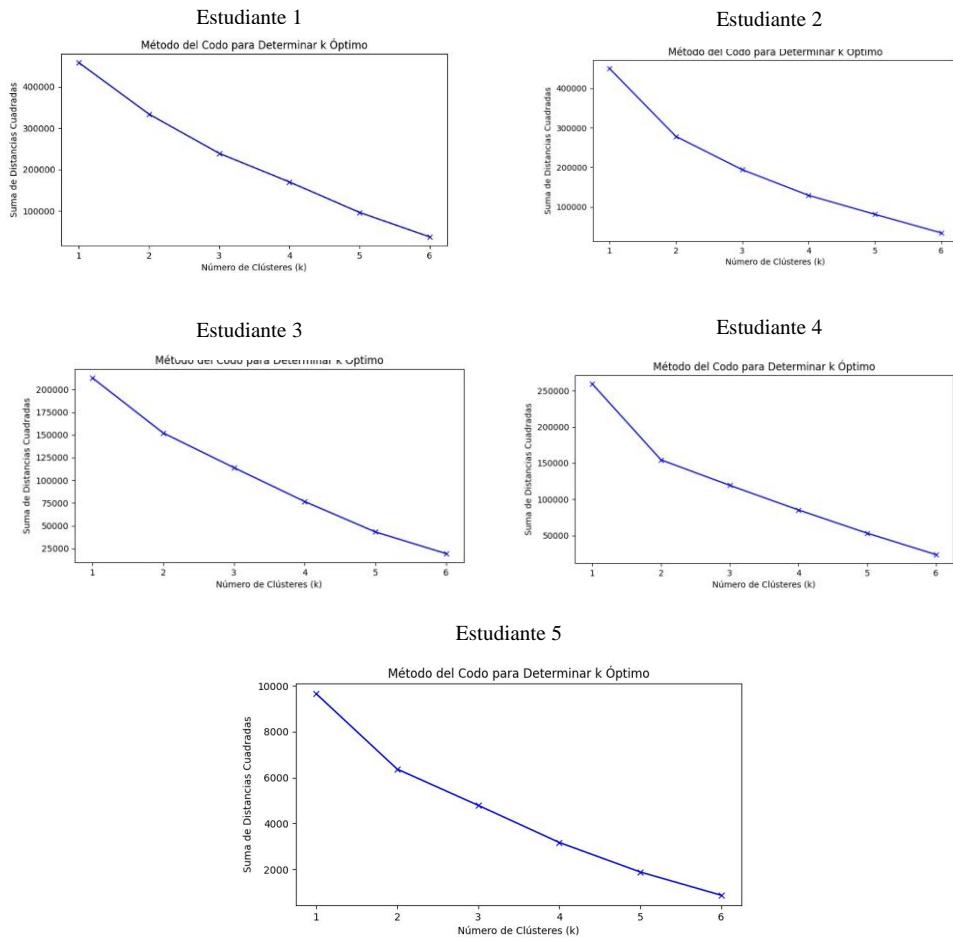


Figura 14 Ejecución del método del codo

El método del codo se utilizó para determinar el número óptimo de clústeres para cada uno de los 33 archivos .csv obtenidos por el software Emotion Recognition. Se utilizó un rango de k de 3 a 4. La Figura 14 muestra la ejecución del método del codo para 5 de los 33 archivos. La curva indica que la mejora en la compactibilidad de los datos es mínima a partir de 3 o 4 clústeres.

Melgare et al. (2019) utilizaron el algoritmo KMEANS para agrupar emociones humanas. Después de analizar los resultados obtenidos utilizando 2, 4 y 6 como valores para k , concluyeron que cuatro grupos ($k = 4$) fue el mejor número de grupos. En este trabajo se realizó experimentación con $k = 3$, pero los resultados no fueron satisfactorios, lo que llevó a concluir que la selección de $k = 4$ se considera adecuada para el propósito investigativo.

4.3.2 Resultados

En nuestro experimento las pruebas de k arrojaron que $k = 4$ fue el mejor número de grupos. Por lo tanto, se ejecutó el algoritmo KMEANS con $k = 4$ para cada uno de los 33 estudiantes, en la Figura 15 se observa la ejecución del Estudiante 1.

Cluster: 1 Emoción: **neutral** Valor: 7.683.464.245 Instancias:1730 Clasificación:MAJOR

	angry	disgust	scared	happy	sad	surprised	neutral
Vector 1 - centroides:	499.012.687	0.16961361	475.673.587	584.594.002	680.628.604	0.59675894	7.683.464.245

Cluster: 2 Emoción: **neutral** Valor: 4.350.684.685 Instancias:333 Clasificación:MINOR

	angry	disgust	scared	happy	sad	surprised	neutral
Vector 2 - centroides:	1.848.198.198	0.73396396	1.324.192.192	792.777.778	1.430.876.877	179.873.874	4.350.684.685

Cluster: 3 Emoción: **neutral** Valor: 4.316.585.526 Instancias:152 Clasificación:MINOR

	angry	disgust	scared	happy	sad	surprised	neutral
Vector 3 - centroides:	770.611.842	0.32184211	541.111.842	3.356.638.158	891.868.421	0.90907895	4.316.585.526

Cluster: 4 Emoción: **neutral** Valor: 6.264.345.933 Instancias:1221 Clasificación:MAJOR

	angry	disgust	scared	happy	sad	surprised	neutral
Vector 4 - centroides:	929.994.248	0.30824979	75.169.926	777.185.703	1.147.447.823	0.98483155	6.264.345.933

Figura 15 Ejecución del algoritmo KMEANS para Estudiante 1

En la Figura 15, el Vector 1 incluye los centroides calculados por el algoritmo KMEANS para las siete emociones. Dentro del Cluster 1 – Vector 1, el valor más elevado es 7.683.464.245, lo cual se designa como el centroide del cluster, representando así la emoción neutral.

Para el caso del cluster 1 es la emoción neutral la que tiene el valor más alto. Este mismo proceso se realiza para los 3 clusters restantes que le corresponden al Estudiante 1.

Las emociones asignadas a cada cluster serán la entrada para el siguiente experimento en la ontología.

Además, se etiquetó a la emoción asignada a cada cluster como característica MAYOR o MENOR en función del número de instancias pertenecientes al cluster; es decir, se sumaron todas las instancias ejecutadas y se obtuvo la mediana de ellas. Si el valor del número de instancias ejecutadas en un cluster es mayor a la mediana se etiqueta como MAYOR, caso contrario se etiqueta como MENOR.

Recordemos que una característica MAYOR es aquella emoción que mayor frecuencia de repetición tiene en el conjunto de datos, mientras que una característica MENOR es aquella emoción que tiene menor frecuencia de repetición según la definición dada por los expertos.

El algoritmo KMEANS agrupa las emociones registradas para cada estudiante en clústeres emocionales. Para el caso del Estudiante 1, los clústeres tuvieron como centroides las emociones: neutral, neutral, neutral, neutral.

El proceso detallado anteriormente se repite para cada uno de los 33 archivos de los estudiantes que participan en el proyecto. El archivo de salida de cada estudiante del algoritmo KMEANS se envía a la ontología HASIO descrita en el experimento No.4. En otras palabras, las emociones más representativas asignadas a cada cluster, se envían a la ontología.

Estas emociones se utilizan como entrada para inferir el Frijda_Action_Tendency en la ontología HASIO. Esto permite comprender cómo las emociones básicas influyen en las tendencias a la acción de los estudiantes.

4.3.3 Discusión

La aplicación del algoritmo KMEANS para cada archivo individual de los estudiantes, que contienen información sobre las emociones con sus respectivos porcentajes obtenidos a través del software Emotion Recognition, permitió la creación de clusters emocionales que agrupan las emociones experimentadas por cada estudiante durante la clase en línea en términos del porcentaje de ocurrencia.

El análisis de clústeres mediante KMEANS proporciona una forma de agrupar emociones detectadas por el software Emotion Recognition en categorías significativas. Esto puede ayudar en la interpretación y análisis de las reacciones emocionales de los estudiantes.

La salida del algoritmo KMEANS es fundamental para el análisis y comprensión de las emociones individuales experimentadas por los estudiantes durante la clase en línea. Proporciona una estructura organizada que permite identificar patrones emocionales que a simple vista se desconocen y obtener información más detallada sobre las respuestas emocionales individuales en el contexto de clases en línea.

La comprensión de cómo las emociones se agrupan y se asocian con diferentes clústeres es esencial para el diseño de sistemas de detección de emociones más precisos y efectivos.

El uso de KMEANS para agrupar emociones en clústeres proporciona una herramienta valiosa para el análisis de las respuestas emocionales de los estudiantes. La asociación de emociones a múltiples clústeres destaca la complejidad de la percepción emocional y su dependencia del contexto. Esto puede guiar la mejora continua de la detección de emociones y la comprensión de las respuestas emocionales en entornos de aprendizaje en línea.

4.3.4 Conclusiones

Los datos obtenidos en aplicaciones del mundo real, como en el contexto de clases en línea, a menudo son extensos y complejos. La aplicación de técnicas de minería de datos, como el

algoritmo KMEANS, posibilita la reducción de la dimensionalidad de los datos al agruparlos en clusters significativos. Esto simplifica la estructura de los datos y simplifica su gestión y análisis.

El algoritmo KMEANS es conocido por su eficiencia computacional y escalabilidad. Es especialmente adecuado para conjuntos de datos grandes y dimensionalmente altos, lo que lo convierte en una opción eficiente cuando se tienen recursos computacionales limitados.

El algoritmo KMEANS demostró ser eficaz para agrupar las emociones básicas registradas por los estudiantes en clusters emocionales significativos. Esto facilita la identificación y comprensión de patrones emocionales dentro de los datos.

El algoritmo KMEANS puede identificar patrones y relaciones entre los datos que pueden no ser evidentes de manera inmediata. Los clusters emocionales generados por KMEANS pueden revelar cómo las emociones se agrupan y se relacionan en este contexto específico de estudio.

Los clusters emocionales ayudan a contextualizar las emociones de los estudiantes en función de patrones más amplios. Esto puede proporcionar información valiosa sobre cómo las emociones evolucionan en diferentes situaciones o contextos de aprendizaje en línea.

La aplicación del algoritmo KMEANS para generar clusters emocionales puede motivar investigaciones futuras sobre cómo estos clusters se relacionan con el rendimiento académico y el bienestar de los estudiantes en entornos de aprendizaje en línea.

Se utilizó el algoritmo KMEANS para ayudar a reducir la cantidad de datos redundantes o irrelevantes existentes en los archivos individuales del software de reconocimiento de emociones, antes de ingresarlos a la ontología HASIO como se explica en el siguiente apartado. Esto optimiza la eficiencia de la ontología al centrarse en la información más relevante.

4.4. Experimento No.4: Ontología HASIO

El propósito del cuarto experimento consiste en emplear la ontología HASIO para la inferencia de tendencias a la acción relacionadas con el aprendizaje de los estudiantes en un entorno de clases en línea en tiempo real. Este paso es fundamental para alcanzar el tercer objetivo específico establecido en el marco de esta tesis y, finalmente, completar la creación del modelo ubicuo de análisis emocional.

4.4.1 Planteamiento del experimento

El experimento tiene las siguientes características:

- Población: 33 estudiantes, matriculados en la Universidad Técnica de Ambato que asistían regularmente a clases en línea.
- Entrada: los centroides de los clústeres generados por el algoritmo KMEANS (emociones).
- Marco conceptual: Ontología HASIO, específicamente la clase “Frijda_Action_Tendency”, se utilizó para inferir tendencias a la acción.

En la ontología HASIO un componente esencial de la teoría de las emociones es la noción de “Frijda_Action_Tendency”, que se deriva de la teoría de las emociones desarrollada por el psicólogo Nico Frijda. En el capítulo II se explicaba los niveles jerárquicos de HASIO. Según Frijda, las emociones están estrechamente ligadas a tendencias a la acción, lo que significa que cuando experimentamos una emoción, también experimentamos una inclinación automática o una tendencia a realizar ciertas acciones.

La integración de “Frijda_Action_Tendency” en ontologías es crucial para representar y utilizar este conocimiento en sistemas de inteligencia artificial. Se utilizó el razonador ontológico Pellet para presentar las tendencias a la acción como resultado de la ejecución axiomática.

El razonamiento ontológico se basa en el Open World Assumption (OWA), que significa información que no se haya agregado explícitamente y se supone que falta y se puede agregar más tarde. De esa manera, el razonador puede inferir más axiomas en la ontología.

Pellet es un razonador de ontologías OWL de código abierto desarrollado en Java. Puede utilizarse junto con Jena y Librerías OWL API. Pellet es un razonador de alto rendimiento y eficiencia, y es utilizado en una amplia gama de aplicaciones, como la Web Semántica, la Inteligencia Artificial y el procesamiento del lenguaje natural. Pellet incluye funcionalidades como (Abaalkhail, 2018):

- Verificación de consistencia: determina si una ontología es consistente, es decir, si no hay contradicciones entre sus axiomas.
- Clasificación: determina a qué clases pertenecen las instancias de una ontología.
- Realización: determina si una clase puede ser instanciada.

- Inferencia de propiedades: determina si una propiedad se cumple entre dos instancias de una ontología.

- Resolución de conflictos: resuelve conflictos entre axiomas de una ontología.

A continuación, se explica los resultados obtenidos al inferir la clase “Frijda_Action_Tendency”.

4.4.2 Resultados

En la Tabla 9 se muestra los resultados obtenidos por la clase “Frijda_Action_Tendency” en la ontología HASIO para cada uno de los estudiantes.

Tabla 9. Resultados de la clase “Frijda_Action_Tendency”

ONTOLOGIA ACTION_TENDENCY				
	MAYORES 1	MAYORES 2	MENORES1	MENORES2
Estudiante1	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante2	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante3	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting
Estudiante4	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	BeingWith
Estudiante5	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante6	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante7	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante8	NoAttending	NoAttending	Submitting	Agonistic-Dominating-Rejecting
Estudiante9	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante10	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante11	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante12	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting
Estudiante13	NoAttending	NoAttending	Interrupting	Interrupting
Estudiante14	Submitting	NoAttending	BeingWith	Interrupting
Estudiante15	NoAttending	NoAttending	NoAttending	NoAttending

Estudiante16	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante17	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante18	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante19	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante20	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante21	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante22	NoAttending	NoAttending	Submitting	BeingWith
Estudiante23	Submitting	BeingWith	NoAttending	NoAttending
Estudiante24	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante25	NoAttending	NoAttending	Submitting	BeingWith
Estudiante26	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante27	Submitting	NoAttending	NoAttending	NoAttending
Estudiante28	Submitting	BeingWith	NoAttending	NoAttending
Estudiante29	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante30	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante31	NoAttending	NoAttending	BeingWith	Agonistic-Dominating-Rejecting
Estudiante32	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante33	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	BeingWith

En la Tabla 9, se observa por ejemplo que el Estudiante 1 registra tendencias a la acción de NoAttending-NoAttending-NoAttending-NoAttending esto se puede observar en la Figura 16 tomada de la ontología, que muestra los resultados de la ejecución axiomática del razonador ontológico Pellet sobre los clusters de emociones obtenidos por KMEANS en el rostro del Estudiante 1. El mismo proceso se realizó para cada uno de los estudiantes. En el repositorio GitHub se adjunta la inferencia ontológica de los 32 estudiantes restantes.

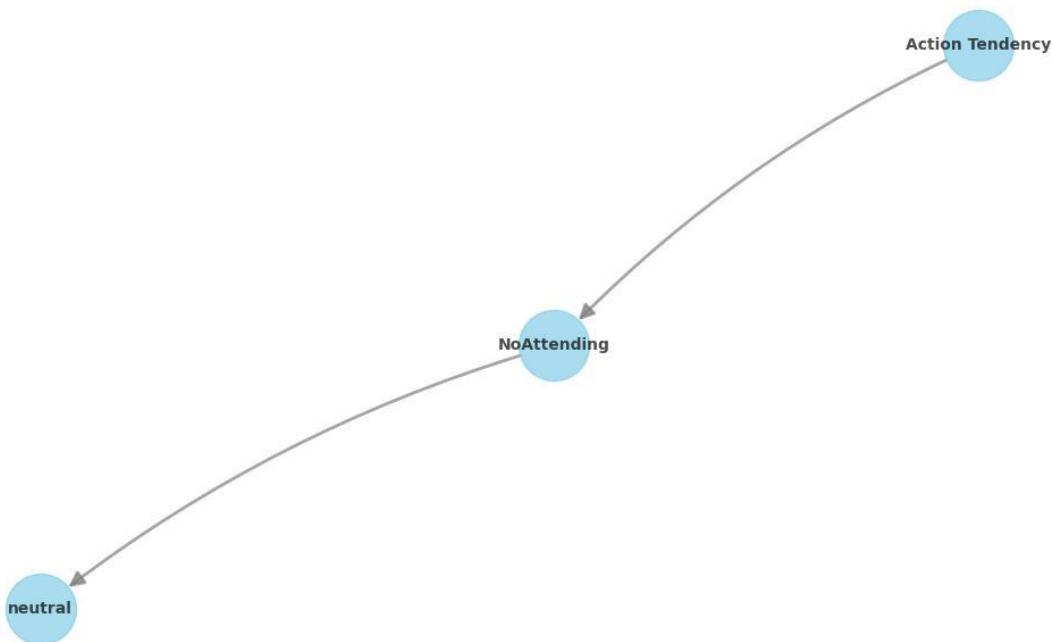


Figura 16 Inferencia de la clase “Frijda_Action_Tendency” para el Estudiante 1

La Figura 16 muestra que el Estudiante 1 presentó cuatro clusters generados por el algoritmo KMEANS cuyas emociones corresponden a: neutral, neutral, neutral y neutral. La instanciación de la clase emoción se realiza una sola vez en la ontología cuando aparecen las repeticiones de las emociones, como es el caso de neutral para el Estudiante1. Esto permitió inferir las tendencias a la acción *NoAttending*.

En el capítulo II se hace referencia a la Tabla 2 en la que se encuentran todas las tendencias a la acción que la ontología infiere a partir de las emociones básicas.

Este proceso de inferencia se realiza individualmente y permite obtener un comportamiento emocional de cada estudiante según (Frijda, 1986).

En el contexto de una clase en línea, las emociones de los estudiantes se detectan mediante el software Emotion Recognition las cuales se almacenan en un archivo csv. Este archivo es la entrada del algoritmo KMEANS y el resultado son los clusters cuyas emociones son la entrada para inferir el Action_Tendency en la ontología HASIO de Nico Frijda, esto permite comprender cómo las emociones influyen en las tendencias a la acción de los estudiantes.

4.4.3 Discusión

La ontología HASIO permite inferir tendencias a la acción en función de las emociones agrupadas. Por ejemplo, para el Estudiante 1, en la ontología la clase

“Frijda_Action_Tendency” se instanció con *NoAttending*, y a partir de esta tendencia a la acción se pueden inferir comportamientos emocionales específicos para cada estudiante.

El proceso de inferencia se basa en el análisis de las emociones agrupadas en los clusters obtenidos por el algoritmo KMEANS.

Las emociones básicas son respuestas emocionales fundamentales del ser humano que forman la base de la ontología de Frijda. Las emociones básicas se asocian con una tendencia a la acción específica, por ejemplo, la emoción happy lleva a una tendencia a la acción de buscar más de lo que provocó la alegría, lo que puede manifestarse en celebraciones o el deseo de compartir una experiencia alegre con otros, en el capítulo II en la Tabla 2 la emoción happy tiene un Action_Tendency: *Approach*.

Es importante destacar que estas tendencias a la acción pueden variar según la intensidad y la duración de las emociones experimentadas. Además, la forma en que los estudiantes eligen actuar puede estar influenciada por su personalidad, sus experiencias previas y la cultura en la que se desarrollan.

La ontología también presenta una jerarquía de Action_Tendencies (Tendencias a la acción), que muestra cómo las tendencias a la acción específicas se derivan de las emociones básicas. Por ejemplo, en la emoción de la alegría, las tendencias a la acción pueden incluir celebrar, compartir y buscar experiencias similares. Esta jerarquía agrega capas de complejidad al entendimiento de las respuestas emocionales y cómo evolucionan a partir de las emociones básicas (Frijda, 1984).

Es fundamental comprender que la ontología HASIO reconoce la variabilidad cultural y personal en la expresión emocional y la experiencia de las emociones. Las culturas pueden influir en cómo se expresan y se gestionan las emociones, y las personas individuales pueden experimentar emociones de manera única, lo que enriquece aún más esta fascinante área de estudio (Cronk, 2019).

La ontología de emociones de Nico Frijda ofrece una visión profunda y detallada de cómo las emociones humanas se desarrollan y se relacionan con las tendencias a la acción. Esta teoría ha sido influyente en campos como la psicología, la neurociencia y la inteligencia artificial, proporcionando un marco sólido para explorar y comprender la rica diversidad de las respuestas emocionales humanas en una variedad de situaciones y contextos.

Una de las ideas clave de Frijda es que las emociones están relacionadas con la evaluación de eventos en relación con objetivos personales. Por ejemplo, en un contexto educativo, esto

significa que las emociones de los estudiantes pueden estar influenciadas por cómo perciben los eventos en relación con sus metas académicas y personales.

La importancia de esta metodología radica en su capacidad para proporcionar una estructura semántica base para la retroalimentación académica a través de las tendencias a la acción para el aprendizaje. Al utilizar tendencias a la acción basadas en el comportamiento emocional individual, se logra un enfoque más fundamentado en los estudiantes en comparación con la retroalimentación basada únicamente en opiniones o en la planificación de recursos de aprendizaje en clases en línea. Esto lleva a una comprensión más profunda y personalizada de las necesidades emocionales y académicas de los estudiantes, lo que puede enriquecer significativamente el proceso de enseñanza-aprendizaje en línea.

La aplicación del algoritmo KMEANS para generar clusters emocionales y su posterior integración en la ontología HASIO representan un enfoque innovador y valioso para analizar y comprender las emociones en clases en línea. La inferencia de tendencias a la acción basadas en estas agrupaciones emocionales contribuye a una retroalimentación académica más precisa y personalizada, con el potencial de mejorar la calidad y efectividad de la educación en línea.

Esta es otra contribución como hallazgo de alto nivel de la cúspide ubicua del comportamiento humano emocional. En efecto, los procesos de retroalimentación deben estar guiados por el comportamiento humano individual (tendencias a la acción para el aprendizaje) y no solo por la opinión o por la planificación de recursos de aprendizaje para clases en línea.

4.4.4 Conclusiones

La aplicación de la ontología HASIO permitió una comprensión más profunda del comportamiento emocional de los estudiantes en entornos de aprendizaje en línea. Esto condujo a una mayor claridad sobre las tendencias a la acción relacionadas con su aprendizaje.

Las tendencias a la acción inferidas a través de la ontología HASIO pueden proporcionar una base sólida para la personalización de la educación en línea. Los educadores pueden adaptar sus estrategias y recursos según las necesidades emocionales y académicas de los estudiantes.

Al comprender cómo las emociones básicas influyen en las tendencias a la acción, los educadores pueden ofrecer retroalimentación más precisa y útil para el desarrollo del estudiante.

Las tendencias a la acción identificadas pueden destacar áreas donde los estudiantes pueden necesitar apoyo adicional. Esto facilita la identificación de estrategias de mejora y la implementación de intervenciones específicas.

La ontología HASIO puede contribuir al desarrollo de programas de educación emocional en entornos en línea. Los resultados pueden servir como base para ayudar a los estudiantes a comprender y gestionar sus emociones en el contexto educativo.

4.5. Experimento No.5: Validación semántica de la Ontología HASIO

El objetivo de este experimento es llevar a cabo la validación de los resultados inferidos por la ontología HASIO utilizando el método de validación por expertos, con el fin de confirmar la fiabilidad y precisión de la ontología.

4.5.1 Planteamiento del experimento

El experimento tiene las siguientes características:

- Población: 33 videos de estudiantes, matriculados en la Universidad Técnica de Ambato que asistían regularmente a clases en línea.
- Recursos humanos: 2 expertos en psicopedagogía.
- Herramientas de evaluación: Coeficiente Kappa de Cohen.

Este último experimento, permite validar semánticamente los resultados inferidos por la ontología HASIO, el experimento plantea comparar los resultados obtenidos por la ontología con los resultados obtenidos por los expertos. Los expertos observaron los 33 videos y etiquetaron el comportamiento de los estudiantes según su experiencia (característica MAYOR y MENOR) y las tendencias a la acción de Frijda.

Conviene recordar aquí qué es una característica MAYOR y MENOR explicada en el capítulo III. Una característica MAYOR se refiere a la/s características emocionales más frecuentes en los participantes, mientras que una característica MENOR se relaciona con la/s características emocionales menos frecuentes detectadas en el estudio.

4.5.2 Resultados

En la Tabla 10 se muestra los resultados del trabajo realizado por ambos expertos versus la clase Frijda_Action_Tendency en la ontología. Los expertos fueron instruidos en la interpretación semántica de la clase Frijda_Action_Tendency en la ontología. En este sentido, los expertos averiguan los conceptos semánticos (característica MAYOR y MENOR) y en base a esto, observan los videos de los estudiantes y clasifican el comportamiento de acuerdo con su experiencia y las tendencias a la acción de Frijda (*Approach, Avoidance, Being With, Attending, Rejecting, NoAttending, Agonistic, Interrupting, Dominating, Submitting, Normal, Nodefine*).

Tabla 10. Resultados de los expertos vs. Resultados de la ontología (tabla completa)

Característica MAYOR ACTION_TENDENCY	Experto 1				Experto 2				ONTOLOGIA ACTION_TENDENCY			
	Característica MAYOR1		Característica MENOR1		Característica MAYOR2		Característica MENOR2		Característica MAYOR1		Característica MENOR1	
	MAYOR1	MAYOR2	MENOR1	MENOR2	MAYOR1	MAYOR2	MENOR1	MENOR2	MAYOR1	MAYOR2	MENOR1	MENOR2
Estudiante1	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante2	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante3	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting
Estudiante4	NoAttending	Interrupting	Agonistic-Dominating-Rejecting	BeingWith	NoAttending	Avoidance	Agonistic-Dominating-Rejecting	BeingWith	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	BeingWith
Estudiante5	NoAttending	Attending	NoAttending	BeingWith	NoAttending	Attending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante6	NoAttending	Avoidance	NoAttending	NoAttending	NoAttending	Approach	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante7	Avoidance	Agonistic	Attending	NoAttending	Avoidance	NoAttending	Attending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante8	NoAttending	NoAttending	Submitting	Agonistic-Dominating-Rejecting	NoAttending	NoAttending	Submitting	Agonistic-Dominating-Rejecting	NoAttending	NoAttending	Submitting	Agonistic-Dominating-Rejecting
Estudiante9	NoAttending	Avoidance	NoAttending	NoAttending	NoAttending	Avoidance	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante10	NoAttending	Interrupting	BeingWith	NoAttending	NoAttending	Interrupting	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante11	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante12	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting
Estudiante13	Avoidance	Avoidance	Interrupting	Interrupting	NoAttending	Avoidance	Interrupting	Interrupting	NoAttending	NoAttending	Interrupting	Interrupting
Estudiante14	Submitting	NoAttending	BeingWith	Interrupting	Submitting	NoAttending	BeingWith	Interrupting	Submitting	NoAttending	BeingWith	Interrupting
Estudiante15	NoAttending	NoAttending	Submitting	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante16	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante17	NoAttending	Avoidance	BeingWith	NoAttending	NoAttending	Avoidance	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante18	NoAttending	Avoidance	NoAttending	BeingWith	NoAttending	Avoidance	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante18	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante20	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante21	Submitting	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante22	NoAttending	NoAttending	BeingWith	BeingWith	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	Submitting	BeingWith	NoAttending
Estudiante23	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending
Estudiante24	NoAttending	Avoidance	NoAttending	NoAttending	NoAttending	Avoidance	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante25	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith
Estudiante26	Avoidance	NoAttending	BeingWith	BeingWith	NoAttending	Interrupting	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante27	Submitting	NoAttending	NoAttending	NoAttending	Submitting	NoAttending	NoAttending	NoAttending	Submitting	NoAttending	NoAttending	NoAttending
Estudiante28	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending
Estudiante29	NoAttending	Avoidance	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante30	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante31	NoAttending	NoAttending	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	NoAttending	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	NoAttending	BeingWith	Agonistic-Dominating-Rejecting
Estudiante32	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante33	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	NoAttending	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	BeingWith	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	BeingWith

Capítulo IV: Experimentos

La Tabla 10 muestra una variedad de comportamientos entre los estudiantes.

La columna ONTOLOGIA_ACTION_TENDENCY muestra todas las tendencias a la acción que la ontología ha inferido para cada uno de los estudiantes.

Tabla 11. Resultados de los expertos vs. Resultados de la ontología (tabla resumida)

	ONTOLOGIA ACTION_TENDENCY				EXPERTOS			
	Característica MAYOR ACTION_TENDENCY		Característica MENOR ACTION_TENDENCY		Característica MAYOR ACTION_TENDENCY		Característica MENOR ACTION_TENDENCY	
	MAYOR1	MAYOR2	MENOR1	MENOR2	MAYOR1	MAYOR2	MENOR1	MENOR2
Estudiante1	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante2	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante3	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting
Estudiante4	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	BeingWith	NoAttending	FALSO	Agonistic-Dominating-Rejecting	BeingWith
Estudiante5	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	Attending	NoAttending	BeingWith
Estudiante6	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	FALSO	NoAttending	NoAttending
Estudiante7	NoAttending	NoAttending	NoAttending	NoAttending	Avoidance	FALSO	Attending	NoAttending
Estudiante8	NoAttending	NoAttending	Submitting	Agonistic-Dominating-Rejecting	NoAttending	NoAttending	Submitting	Agonistic-Dominating-Rejecting
Estudiante09	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	Avoidance	NoAttending	FALSO
Estudiante10	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	Interrupting	BeingWith	NoAttending
Estudiante11	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante12	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	BeingWith	BeingWith	Agonistic-Dominating-Rejecting
Estudiante13	NoAttending	NoAttending	Interrupting	Interrupting	FALSO	Avoidance	Interrupting	Interrupting
Estudiante14	Submitting	NoAttending	BeingWith	Interrupting	Submitting	NoAttending	BeingWith	Interrupting
Estudiante15	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	FALSO	NoAttending
Estudiante16	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante17	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	Avoidance	BeingWith	NoAttending
Estudiante18	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	Avoidance	NoAttending	BeingWith
Estudiante19	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante20	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith
Estudiante21	NoAttending	NoAttending	NoAttending	BeingWith	FALSO	NoAttending	NoAttending	BeingWith
Estudiante22	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending	FALSO	BeingWith
Estudiante23	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending
Estudiante24	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	Avoidance	NoAttending	NoAttending
Estudiante25	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith
Estudiante26	NoAttending	NoAttending	NoAttending	BeingWith	FALSO	FALSO	FALSO	BeingWith
Estudiante27	Submitting	NoAttending	NoAttending	NoAttending	Submitting	NoAttending	NoAttending	NoAttending
Estudiante28	Submitting	BeingWith	NoAttending	NoAttending	Submitting	BeingWith	NoAttending	NoAttending
Estudiante29	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	FALSO	NoAttending	NoAttending
Estudiante30	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending	NoAttending
Estudiante31	NoAttending	NoAttending	BeingWith	Agonistic-Dominating-Rejecting	NoAttending	NoAttending	BeingWith	Agonistic-Dominating-Rejecting
Estudiante32	NoAttending	NoAttending	BeingWith	NoAttending	NoAttending	NoAttending	BeingWith	NoAttending
Estudiante33	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	BeingWith	NoAttending	NoAttending	Agonistic-Dominating-Rejecting	FALSO

En la Tabla 11, se ubicó la palabra FALSO cuando no hay coincidencia tanto entre expertos como entre ontología y expertos. La columna Expertos refleja las coincidencias entre ellos.

A continuación, se explica cómo se calculó la concordancia entre los 2 expertos, para ello se utilizó el coeficiente Kappa. Luego de observar los videos, los expertos clasificaron el comportamiento de los estudiantes según su experiencia y las tendencias a la acción de Frijda.

Se calcula el coeficiente Kappa con la fórmula:

$$K = \frac{(Po - Pe)}{(1 - Pe)}$$

En donde:

- Po es la proporción de acuerdo observado entre los observadores (expertos).
- Pe es la proporción de acuerdo esperado entre los observadores (expertos) por azar.

4.5.3 Resultados entre Expertos para Kappa

Resultados para características Mayores1:

Matriz de Confusión:

[[1 2 0]]

[0 25 0]

[0 1 4]]

Kappa: 0.7295081967213115

Resultados para característica Mayores2:

Matriz de Confusión:

[[0 0 0 0 0 0 1]]

[0 0 0 0 0 0 0]

[0 0 1 0 0 0 0]

[0 1 0 5 0 0 1]

[0 0 0 0 4 0 0]

[0 0 0 1 0 1 0]

[0 0 0 0 0 1 17]]

Kappa: 0.7587719298245614

Resultados para característica Menores1:

Matriz de Confusión:

[[2 0 0 0 0 0]]

[0 1 0 0 0 0]

[0 0 8 0 1 1]

[0 0 0 1 0 0]

[0 0 0 0 16 0]

[0 0 0 0 1 2]]

Kappa: 0.8597733711048159

Resultados para característica Menores2:

Matriz de Confusión:

[[4 0 0 0 0]]

[0 8 0 0 0]

[0 0 2 0 0]

[0 1 0 17 0]

[0 1 0 0 0]]

Kappa: 0.9033674963396778

Promedio de Kappa: 0.8128552484975917, acuerdo casi perfecto entre los expertos.

4.5.4 Resultados Ontología vs. Expertos

Resultados para característica Mayores1:

Matriz de Confusión:

[[0 0 1 0]]

[0 0 3 0]

[0 0 25 0]

[0 0 0 4]]

Kappa: 0.6206896551724137

Resultados para característica Mayores2:

Matriz de Confusión:

[[0 0 0 0 0 1]

[0 0 0 0 0 5]

[0 0 4 0 0 0]

[0 0 0 0 0 5]

[0 0 0 0 0 1]

[0 0 0 0 0 17]]

Kappa: 0.3172413793103449

Resultados para característica Menores1:

Matriz de Confusión:

[[2 0 0 0 0 0 0]

[0 0 0 0 0 1 0]

[0 0 8 0 0 0 0]

[0 0 0 0 0 2 1]

[0 0 0 0 1 0 0]

[0 0 0 0 0 16 0]

[0 0 0 0 0 0 2]]

Kappa: 0.8140845070422535

Resultados para característica Menores2:

Matriz de Confusión:

[[4 0 0 0 0]]

[0 8 0 0 0]

[0 2 0 0 0]

[0 0 0 2 0]

[0 0 0 0 17]]

Kappa: 0.9057142857142857

Promedio de Kappa: 0.6644324568098244

La Tabla 12, muestra las valoraciones del coeficiente Kappa según (Landis y Koch, 1977).

Tabla 12. Valoraciones del coeficiente Kappa

Coeficiente Kappa	Fuerza de la concordancia
0,00	Pobre
0,01 – 0,20	Leve
0,21 – 0,40	Aceptable
0,41 – 0,60	Moderada
0,61 – 0,80	Considerable
0,81 – 1,00	Casi perfecta

Un acuerdo de 0.66 en el coeficiente kappa indica un nivel considerable de acuerdo entre la ontología y los expertos.

4.5.5 Discusión

Cada estudiante muestra un patrón de comportamiento único en la Tabla 10, lo que sugiere que hay una variedad de personalidades y tendencias emocionales en el grupo estudiantil. Es importante notar que estos comportamientos son etiquetas abstractas y que cada estudiante puede tener circunstancias individuales que influyen en su comportamiento.

Por ejemplo, el comportamiento NoAttending que proviene de la emoción neutral, sugiere que los estudiantes no mostraron reacciones emocionales en la clase en línea frente al estímulo (Cabral y De Almeida, 2019). En la Tabla 10, se presentan estudiantes con esa

Action_Tendency. Esto podría sugerir una tendencia general del comportamiento de los estudiantes, ya que se la observa con mayor frecuencia.

Un valor de Kappa cercano a 1 indicaría una concordancia casi perfecta, mientras que un valor cercano a 0 indicaría una concordancia similar a la que se esperaría por azar.

Es importante tener en cuenta que el nivel de concordancia considerado “aceptable” puede variar según el contexto y la naturaleza de la evaluación. En algunos casos, una concordancia moderada puede ser suficiente, mientras que, en otros, se pueden requerir niveles más altos de concordancia.

El coeficiente Kappa general obtenido es 0,81 lo que implica una concordancia casi perfecta según la Tabla 12 entre los dos expertos, lo que confirma la consistencia en las observaciones. Entre ontología y expertos el resultado de Kappa es 0,66, lo que indica una concordancia considerable que permite obtener conclusiones válidas del estudio.

4.5.6 Conclusiones

La tarea de los expertos es fundamental para el análisis de los resultados de la ontología. Su tarea fue observar los videos y obtener las características emocionales MAYORES y MENORES. Fue necesario obtener las coincidencias de las observaciones entre ellos, y luego entre sus coincidencias y la ontología. Para ello se procedió a aplicar el índice de Kappa.

El índice Kappa general obtenido fue del 0,81, esto corresponde con una concordancia casi perfecta entre los dos expertos. Si bien es cierto hay acuerdo en una proporción considerable de casos, también existen desacuerdos. Estos desacuerdos pueden requerir una revisión de criterios, capacitación adicional o una comprensión más profunda de las razones detrás de los desacuerdos para mejorar la calidad de las evaluaciones. Cuanto mayor sea la concordancia, mayor será la fiabilidad percibida.

Los expertos actúan como un estándar de referencia confiable. Sus conocimientos y experiencia se utilizan para establecer la precisión y la calidad de los datos evaluados.

El proceso de etiquetado de videos por parte de los expertos en características MAYORES y MENORES desempeña un papel esencial en la evaluación y comprensión del proceso de aprendizaje y el bienestar emocional de los estudiantes. A través de esta actividad, se busca identificar y analizar una amplia gama de características y comportamientos específicos que

proporcionan información valiosa para mejorar la calidad de la educación y el apoyo emocional en el contexto educativo en línea.

La comparación de los resultados de los expertos versus la ontología sirve como un proceso de validación crucial para determinar si la ontología es efectiva en la captura y representación de conocimiento. Además, proporciona una medida de la fiabilidad de la ontología en términos de su capacidad para reflejar de manera precisa y coherente la información evaluada por expertos.

La ontología puede ser una herramienta eficiente y escalable para la evaluación de datos en comparación con la revisión manual de expertos. Esto es especialmente relevante en conjuntos de datos grandes y complejos.

La comparación entre los resultados de la ontología y las evaluaciones de los expertos, con concordancia considerable, puede ser un ciclo de retroalimentación constante que permite la mejora continua de la ontología con el tiempo.

Los resultados de la evaluación por expertos a menudo se utilizan para identificar áreas donde se pueden realizar mejoras o correcciones. Esto contribuye a la mejora de la calidad de los datos o los procesos evaluados.

4.6 Conclusiones del capítulo

Este capítulo detalla los resultados de la experimentación del modelo ubicuo de análisis emocional aplicado en el contexto de las clases en línea. El objetivo principal fue recopilar información detallada sobre el estado emocional de los estudiantes y, a partir de esta información, identificar las tendencias que ejercen influencia sobre sus acciones de aprendizaje. Además, se busca comprender cómo estas tendencias afectan su comportamiento emocional en el contexto de las clases en línea.

Para lograr este propósito, se implementa el modelo ubicuo de análisis emocional y se aplica a un conjunto de datos de estudiantes en situaciones de clases en línea. Durante el proceso de experimentación, se recopila una amplia gama de datos relevantes relacionados con las emociones básicas, emociones predominantes, clusters de emociones y tendencias a la acción para el aprendizaje de los estudiantes.

El objetivo final fue emplear estos resultados con el propósito de adaptar y mejorar las estrategias de enseñanza-aprendizaje en el contexto de las clases en línea. Esto implicó

considerar de manera integral las necesidades de bienestar emocional de los estudiantes como parte fundamental de estas estrategias, con la meta de facilitar un proceso de aprendizaje exitoso y significativo.

A través de la comprensión de cómo las emociones influyen en el proceso de aprendizaje en línea, se espera proporcionar insights valiosos para el diseño de experiencias educativas más efectivas y personalizadas.

La culminación de este proceso experimental es la creación de un modelo sólido de análisis emocional diseñado específicamente para las clases en línea. Este modelo representa el enfoque central de esta tesis y ofrece perspectivas prometedoras para enriquecer significativamente el proceso de enseñanza - aprendizaje en línea al abordar las necesidades emocionales de los estudiantes de manera más efectiva.

Se empieza utilizando y validando el sistema de reconocimiento de emociones, utilizando curvas ROC para medir su rendimiento. Los resultados mostraron que los valores de AUC oscilaban entre 0.47 y 0.9. Esto indica que el software es capaz de detectar emociones en los rostros de los estudiantes de manera eficaz en la mayoría de los casos.

Además, se aplicó el principio de Pareto para identificar las emociones predominantes en una clase en línea. Al seleccionar las emociones predominantes y distintivas, se aumenta la capacidad de identificar con precisión las emociones en los rostros de los estudiantes. Esto puede ser valioso en contextos educativos y de evaluación emocional, donde comprender las emociones predominantes entre los estudiantes puede ser fundamental para brindar un mejor apoyo y atención. Los resultados revelaron que aproximadamente el 20% de las emociones estaban relacionadas con las emociones "happy" y "neutral".

La aplicación de la regla 80/20 en este contexto específico sugiere que mejorar la calidad emocional se logra eficientemente al centrarse en un conjunto minoritario de emociones clave. Este enfoque estratégico puede traducirse en mejoras sustanciales en la experiencia emocional de los estudiantes. La educación en línea presenta desafíos únicos, y el estado emocional de los estudiantes desempeña un papel crucial en su experiencia de aprendizaje. Al concentrarse en mejorar las emociones "happy" y "neutral", podemos anticipar impactos significativos en el comportamiento emocional de los estudiantes durante las clases online. El resultado de abordar las emociones del 20% superior puede ser estudiado en investigaciones futuras que reflejen la importancia de centrarse en las emociones seleccionadas. Por ejemplo, según (Alzina, 2008) los beneficios pueden ser:

- Mayor participación y compromiso:

Estudiantes en un estado emocional “happy” y “neutral” tienden a participar más activamente en las discusiones y actividades.

La sensación de bienestar emocional puede actuar como un motivador intrínseco, fomentando un mayor compromiso con el contenido del curso.

- Reducción del estrés y la ansiedad:

Al abordar y mejorar el estado emocional neutral, se puede reducir el estrés y la ansiedad asociados con el aprendizaje en línea.

Un ambiente menos estresante contribuye a una mejor concentración y retención de información.

- Clima positivo en la clase en línea:

La presencia de estudiantes en estados emocionales happy (positivos) contribuye a crear un clima positivo en la clase en línea.

Un entorno positivo promueve interacciones más constructivas y colaborativas entre estudiantes y profesores.

- Desarrollo de habilidades socioemocionales:

Mejorar el estado emocional neutral y happy puede influir en el desarrollo de habilidades socioemocionales, como la empatía y la autorregulación emocional.

Estas habilidades son fundamentales para la adaptación a entornos virtuales y para la vida en general.

Enfocarse en el bienestar emocional, especialmente en los estados neutrales y happy, no solo mejora la experiencia de aprendizaje durante las clases en línea, sino que también sienta las bases para un desarrollo académico y socioemocional más sólido. La atención a estas emociones contribuye a un ambiente educativo en línea más saludable y efectivo.

Continuando con la descripción, se utilizó el algoritmo KMEANS para generar clusters emocionales y se usó la ontología HASIO para inferir tendencias a la acción.

Los clusters emocionales generados por KMEANS pueden servir como atributos clave que enriquecen la ontología. Estos atributos pueden utilizarse para describir y contextualizar las tendencias a la acción en el dominio de estudio.

La ontología HASIO proporciona una herramienta valiosa para comprender en profundidad cómo las emociones influyen en las acciones y decisiones de aprendizaje de los estudiantes. Al analizar las emociones en categorías específicas relacionadas con tendencias a la acción, podemos obtener una visión más completa de cómo los estados emocionales impactan en el proceso educativo.

También se evaluó el modelo ubicuo de análisis emocional mediante la comparación de los resultados entre expertos versus la ontología, obteniéndose un nivel de acuerdo considerable.

El modelo ubicuo se implementó en un entorno de clases en línea real, por lo que puede formar parte de los sistemas de retroalimentación educativa para apoyar al profesor en el monitoreo de los estudiantes en cada semestre académico.

La aplicación metodológica de esta tesis implicó la obtención de las tendencias a la acción para el aprendizaje en los estudiantes. Este trabajo puede complementarse con otros que permitan corroborar resultados y consolidar conclusiones, como la posibilidad de configurar grupos de emociones, que luego pueden interpretarse como tendencias hacia un comportamiento específico (Palmer, 2017).

Al reducir con KMEANS la cantidad de datos que ingresan a la ontología, se optimizan los recursos computacionales y de almacenamiento necesarios para su gestión. Esto puede ser especialmente importante en aplicaciones de gran escala.

Otros trabajos como Vallerand y Blanchard (2000), Petrova et al. (2020), Anzelin et al. (2020) y Kramer (2020) analizan la emoción, en esta tesis se analiza la interpretación semántica necesaria para los procesos de retroalimentación (Behnagh, 2020); dado que el comportamiento grupal e individual conciben relaciones semánticas. Podemos usar ontologías para crear instancias de clases emocionales y verificar las tendencias a la acción, como la interpretación del comportamiento que se registra en el proceso de enseñanza-aprendizaje.

Las decisiones que se pueden tomar a partir de las conclusiones semánticas del comportamiento emocional son la base para las mejoras educativas.

Capítulo IV: Experimentos

En el siguiente apartado, se detallan las conclusiones generadas a partir de cada objetivo desarrollado en la presente tesis, así como también los trabajos futuros para mejorar o incrementar el trabajo presentado.

CAPÍTULO V. CONCLUSIONES

Durante el proceso de enseñanza-aprendizaje, las emociones desempeñan un papel crucial en la experiencia educativa de cada estudiante. Mientras que en entornos presenciales los profesores pueden influir directamente en el control emocional de los estudiantes, en las clases en línea este proceso presenta desafíos adicionales. Por lo tanto, es fundamental desarrollar estrategias que permitan comprender y abordar las emociones en este contexto, con el objetivo de mejorar la calidad del aprendizaje y la retroalimentación.

Para ello, debemos responder a las siguientes cuestiones: ¿qué ocurre en los entornos de aprendizaje en línea? ¿Existen emociones predominantes en las clases en línea? ¿Cómo se pueden crear clusters emocionales que permitan una interpretación semántica del comportamiento emocional? ¿Es posible inferir tendencias a la acción para el aprendizaje que sirvan de base para la retroalimentación del proceso de enseñanza-aprendizaje?

El trabajo realizado en esta tesis propone un enfoque integral para abordar estos interrogantes de investigación. Para ello se ha propuesto un modelo ubicuo de análisis emocional específicamente diseñado para el contexto de las clases en línea. Este modelo se fundamentó en el reconocimiento automático de emociones básicas en los rostros de los estudiantes, lo que permitió identificar emociones predominantes y, crear clusters emocionales para inferir tendencias a la acción para el aprendizaje basándose en estados emocionales detectados en los estudiantes, con el fin de brindar un mejor apoyo y atención en los entornos de aprendizaje en línea.

En los entornos de aprendizaje en línea, ocurre una interacción entre estudiantes y profesores a través de las clases en línea. Allí, se lleva a cabo la transmisión de conocimientos en la participación de actividades de aprendizaje. Este trabajo demostró que en las clases en línea aparecieron emociones predominantes. Además, surgieron emociones que al agruparse conducían a tendencias a la acción para el aprendizaje, elemento semántico que servía de base para la retroalimentación del proceso de enseñanza-aprendizaje.

La experimentación se llevó a cabo en un entorno de clase virtual auténtico. Para evaluar la efectividad del modelo propuesto, se contó con la revisión de expertos, quienes verificaron los resultados obtenidos por el modelo automático. Se confirmó que las tendencias a la acción identificadas por el modelo coincidieron con los criterios de los expertos. Este hallazgo es de suma importancia, dado que, en entornos de aprendizaje en línea, los profesores enfrentan dificultades para observar a todos los estudiantes simultáneamente, lo que dificulta su comprensión del comportamiento estudiantil en línea, especialmente debido a las limitaciones impuestas por el uso de cámaras web.

A continuación, analicemos cómo cada objetivo específico contribuyó a alcanzar el objetivo general de esta tesis y la validación de la hipótesis planteada.

5.1. Análisis del cumplimiento de los objetivos

En el ámbito de la educación en línea, entender las emociones es esencial debido a las limitaciones en la comunicación no verbal y las interacciones en tiempo real. La computación ubicua se presenta como un enfoque prometedor para recopilar datos emocionales en contextos educativos, lo que podría mejorar la personalización del aprendizaje. Investigar un modelo automático de análisis emocional no solo beneficiaría la calidad de la educación en línea, sino que también impulsaría el avance del análisis emocional en general, abriendo nuevas oportunidades para diseñar intervenciones y modelos pedagógicos más efectivos.

Aunque aún no se ha determinado cómo las emociones durante las clases en línea afectan a las tendencias a la acción para el aprendizaje, es crucial abordar los desafíos emocionales para fomentar un entorno de apoyo y proporcionar retroalimentación frecuente y positiva (Hartnett, 2016; Rodríguez-Galván et al., 2022).

5.1.1 Identificación de Emociones Predominantes

El primer objetivo específico de esta tesis consistió en determinar las emociones predominantes en una clase en línea mediante la identificación automática de emociones en el rostro de los estudiantes. Para lograr este propósito, se empleó el software Emotion Recognition el cual analiza las emociones reflejadas en el rostro de los estudiantes y proporciona un porcentaje de ocurrencia durante las sesiones en línea. Se evaluó el rendimiento del software mediante el análisis de las curvas ROC, demostrando una capacidad aceptable para distinguir entre emociones presentes y ausentes en los rostros de los estudiantes, según los criterios establecidos por Ampudia (2017). Los valores de AUC obtenidos oscilaron entre 0.47 y 0.9.

Una vez registradas las emociones de los estudiantes, se identificaron las emociones predominantes utilizando el principio de Pareto, el cual postula que un reducido número de estados emocionales, representando el 20%, inciden mayormente en los resultados del proceso de aprendizaje, tales como la participación del estudiante en clase y su capacidad para asimilar conocimientos (Alzina, 2008). En este estudio, el 20% superior de las emociones detectadas en las clases en línea estuvieron principalmente asociadas con los estados emocionales “happy” y “neutral”. Este hallazgo puede ser utilizado de manera general para comprender el comportamiento del grupo de estudiantes y en consecuencia

retroalimentar el proceso de enseñanza-aprendizaje. Además, comprender el impacto de estos estados emocionales en la educación puede asistir a los educadores en la creación de entornos de aprendizaje más efectivos, fomentando un mayor compromiso por parte de los estudiantes.

Esta identificación automática de emociones sentó las bases para comprender cómo las expresiones faciales de los estudiantes reflejan sus estados emocionales, un aspecto fundamental para agrupar estas emociones en clusters y posteriormente inferir tendencias de acción para el proceso de aprendizaje.

5.1.2 Creación de Clústeres Emocionales

El segundo objetivo específico de esta tesis se enfocó en establecer una estructura clara y comprensible para analizar las emociones expresadas en el entorno educativo en línea, que permita una interpretación semántica del comportamiento emocional. Para alcanzar este propósito, se agrupó las diversas emociones identificadas automáticamente en clústeres que posean un significado e interpretación semántica específica.

La agrupación de emociones identificadas en clústeres fue facilitada mediante el uso del algoritmo de minería de datos KMEANS. En otras palabras, se generaron clústeres emocionales individuales para cada estudiante. Estos clústeres no solo contribuyeron a comprender las emociones expresadas, sino que también ofrecieron una estructura para inferir tendencias a la acción.

El algoritmo KMEANS se emplea para agrupar las emociones registradas de cada estudiante en clústeres emocionales. Para esta tarea, se utilizó el método del codo para determinar el número adecuado de clusters, siendo este número igual a 4, y se aplicó el algoritmo KMEANS generando así cuatro clústeres para cada uno de los 33 estudiantes. Los resultados obtenidos de este proceso se envían a la ontología HASIO, lo que significa que las emociones más representativas asignadas a cada clúster son transmitidas a dicha ontología.

Aplicar el algoritmo KMEANS previamente a la consecución del próximo objetivo específico, es decir, antes de que los datos lleguen directamente desde el software de reconocimiento de emociones a la ontología HASIO, potenció tanto la calidad como la eficiencia de esta última; es decir, simplificó los datos al permitir la identificación de agrupamientos de emociones más y menos frecuentes, identificó patrones, y enriqueció la descripción y contextualización de los datos dentro del dominio específico de las clases en línea. Esta acción facilitó la búsqueda, recuperación e interpretación posterior de la información en la

ontología y posibilitó la reducción de la dimensionalidad de los datos al agruparlos en clusters significativos.

5.1.3 Inferencia de Tendencias a la Acción

El tercer objetivo específico de esta tesis consistió en inferir tendencias a la acción para el aprendizaje, las cuales se obtuvieron a partir de los clústeres emocionales individuales previamente establecidos en el segundo objetivo.

Para lograr este último objetivo específico, se empleó la ontología HASIO. Se tomaron las emociones representativas de cada cluster por estudiante y se instanciaron en la ontología para inferir la clase Frida_Action_Tendency, lo que posibilitó obtener las tendencias a la acción relacionadas con el aprendizaje. Esto permitió obtener una tabla de características MAYORES (emociones que mayor frecuencia de repetición tienen en el conjunto de datos) y MENORES (emociones que tienen menor frecuencia de repetición) para las tendencias a la acción basada en la asignación otorgada a las emociones en el cluster.

El papel de los expertos resultó crucial en el análisis de los resultados de la ontología. Ellos se encargaron de examinar los videos y determinar las características emocionales MAYORES y MENORES. Fue esencial buscar la concordancia entre las observaciones de cada experto y luego entre las coincidencias de ambos y la ontología. Para este fin, se aplicó el índice de Kappa obteniéndose una concordancia casi perfecta entre los dos expertos con un valor de 0,81; mientras que se obtuvo con concordancia considerable entre los resultados de la ontología y las evaluaciones de los expertos con un valor de 0,66.

Una vez que se ha demostrado el logro de los objetivos específicos, estos han cimentado el desarrollo metodológico para alcanzar el objetivo general de esta tesis: la creación de un modelo semántico ubicuo que permita el registro emocional y la inferencia de tendencias de acción en el aprendizaje durante las clases en línea grabadas en video. La metodología propuesta en este estudio proporciona un marco para recopilar datos y realizar análisis que ayudan a validar positivamente la hipótesis H_0 : Es posible inferir tendencias de acción para el aprendizaje de los estudiantes en clases en línea a partir del registro de emociones básicas grabadas en video.

La respuesta a esta hipótesis es afirmativa: sí es posible inferir tendencias a la acción para el aprendizaje a partir del registro de emociones básicas grabadas en video, las cuales han sido validadas por expertos. Este hallazgo provee el insumo necesario para retroalimentar el proceso de enseñanza-aprendizaje.

5.2. Resumen de contribuciones

El desarrollo metodológico de cada objetivo ha dado lugar a diferentes contribuciones que se han reflejado en publicaciones científicas. Estas exponen ante la comunidad los hallazgos más relevantes, detallando los resultados obtenidos en cada fase del modelo semántico ubicuo para el registro emocional y la inferencia de tendencias a la acción para el aprendizaje durante las clases en línea grabadas en vídeo. A continuación, se presenta los aportes realizados:

- 1) Hemos construido un modelo capaz de identificar las emociones predominantes en una clase en línea mediante el reconocimiento automático de las expresiones faciales de los estudiantes. Para alcanzar este propósito, empleamos software especializado en el reconocimiento de emociones faciales y nos guiamos por el principio de Pareto.
El reconocimiento automático de las expresiones faciales en los estudiantes de una clase en línea fue presentado en el artículo: Arias T. S. A., Moreno-Ger, P., & Verdu, E. (2020, September). Towards identifying emotional human behavior in online classes: first steps: Human emotional behavior in a virtual class. In 2020 IEEE Learning With MOOCS (LWMOOCS) (pp. 207-210). IEEE.
- 2) A partir del reconocimiento automático de las expresiones faciales de los estudiantes, hemos empleado técnicas de minería de datos para generar clústeres emocionales, estos clústeres posibilitarán una interpretación semántica del comportamiento emocional de los estudiantes, ofreciendo una visión más detallada y estructurada de las emociones expresadas.
La aplicación de técnicas de minería de datos se presenta en el artículo: Arias, S. A., Moreno-Ger, P., & Verdu, E. (2021). Hierarchical clustering to identify emotional human behavior in online classes: the teacher's point of view. In Comprehensible Science: ICCS 2020 (pp. 269-275). Springer International Publishing.
- 3) Hemos realizado inferencias de tendencias a la acción para el aprendizaje a partir de los clústeres emocionales previamente establecidos mediante razonamiento semántico usando la ontología HASIO, lo que permitió identificar los comportamientos emocionales de los estudiantes durante las clases en línea. Estas tendencias a la acción son valiosas para proporcionar retroalimentación efectiva en el proceso de enseñanza-aprendizaje.

- 4) Hemos validado los resultados obtenidos por la ontología HASIO mediante su comparación con las evaluaciones realizadas por expertos. Para determinar el nivel de concordancia entre los resultados de la ontología y los de los expertos y entre expertos, empleamos el Coeficiente Kappa de Cohen, una herramienta de evaluación reconocida.

Al integrar las contribuciones mencionadas anteriormente, la principal aportación de este trabajo de tesis es la creación de un modelo semántico ubicuo diseñado específicamente para registrar emociones e inferir tendencias a la acción en el contexto del aprendizaje durante clases en línea grabadas en video. Este modelo representa un avance significativo al posibilitar la captura y comprensión de las emociones experimentadas por los estudiantes durante las clases en línea.

La creación del modelo semántico ubicuo para el registro de emociones e inferir tendencias a la acción es presentado en el artículo: Arias T. S. A., Moreno-Ger, P., & Verdú, E. (2023). A Ubiquitous Model of Emotional Tracking in Virtual Classes: From Simple Emotions to Learning Action Tendency. *IEEE Latin America Transactions*, 21(8), 889-896

5.3. Trabajos futuros

El estudio realizado por Petrova et al. (2020) predice el comportamiento humano mediante un análisis unimodal. Esta investigación complementa ese enfoque, ya que emplea vectores que relacionan emociones con tendencias a la acción. Es probable que esto conduzca a mejoras en la identificación de áreas de oportunidad en el proceso de enseñanza-aprendizaje en entornos de clases en línea.

Otros estudios, como los realizados por Behnagh (2020), Kaviani (2020), Rowe y Lester (2020), y Anzelin (2020), se centran en el análisis de las emociones. Este trabajo, por su parte, aborda la interpretación semántica necesaria para los procesos de retroalimentación basados en emociones, ya que el comportamiento implica relaciones semánticas. Se pueden utilizar ontologías para crear instancias de clases emocionales y verificar el comportamiento semántico emocional registrado en el proceso de enseñanza-aprendizaje.

El modelo automático encuentra su apoyo no únicamente en la individualidad, sino también en el sentido grupal. Puede identificar el fenómeno tanto hacia un estudiante como hacia el grupo. Actúa, por tanto, como un simulador de la vigilancia emocional presencial, que generalmente es realizada por el profesor (Cobos-Guzman et al., 2021) (Colomo-Palacios et al., 2020).

Este estudio evidenció la presencia de emociones predominantes en las clases en línea. Como área de investigación futura, se plantea explorar cómo estas emociones pueden variar en función de distintos factores, tales como el contexto, la dinámica grupal y la naturaleza del contenido enseñado.

La capacidad de sentir y expresar emociones de forma adecuada pone de manifiesto grandes diferencias entre hombres y mujeres en entornos en línea (Colomo-Palacios et al., 2020) (Kramer, 2020) (Rattel et al., 2020). Para futuros trabajos estudiaremos esta propuesta utilizando el modelo ubicuo semántico desarrollado. Así mismo, se abordará la influencia emocional del profesor sobre los estudiantes.

En el presente estudio, se grabaron videos para obtener las tendencias a la acción de las emociones expresadas en los rostros de los estudiantes, pero no se consideró ninguna otra entrada. Considerar las interacciones de los estudiantes con otros elementos fuera del aula en línea, pero dentro del entorno propio de la computadora, puede implicar problemas de privacidad. Las tendencias a la acción pueden darle al profesor una pista de si el estudiante está prestando atención a la clase o a otros elementos, en contexto presencial o mixto (en línea y presencial). Sin embargo, exploraremos la posibilidad de capturar otras interacciones para un análisis más profundo y una mejor retroalimentación en trabajos futuros. Por último, en una próxima etapa, estudiaremos el enfoque pedagógico para proporcionar una retroalimentación adecuada a partir de las tendencias a la acción del estudiante y la posibilidad de integración en entornos mixtos.

Se enfrentó una limitación en esta tesis al emplear el método para asignar las características MAYOR o MENOR al utilizar el algoritmo KMEANS. Como trabajo futuro, se plantea mejorar esta asignación mediante métodos de clasificación, donde los vectores sirvan como entrada y la asignación de características sea realizada por un experto durante la fase de entrenamiento.

El modelo propuesto también sugiere la posibilidad de clasificar a los estudiantes en grupos emocionales, lo que permitiría un tratamiento más individualizado en el proceso educativo. Para ello, se podrían aplicar técnicas como la lógica difusa y las redes neuronales para obtener el grado de pertenencia a un grupo emocional específico.

Una de las contribuciones principales del psicólogo Nico Frijda fue la idea de que las emociones están intrínsecamente ligadas a la evaluación de eventos en relación con metas personales. En el ámbito educativo, esto implicaba que las emociones de los estudiantes podían ser moldeadas por su percepción de los eventos en relación con sus objetivos

académicos y personales. La exploración de esta percepción será abordada en futuras investigaciones, donde se buscará establecer conexiones entre las tendencias a la acción y el rendimiento académico. Es probable que se confirme que las tendencias a la acción positivas tengan un impacto significativo en la mejora del desempeño estudiantil.

Las definiciones de comportamiento emocional mediante las tendencias a la acción han permitido una identificación algorítmica de la estructura semántica fundamental para la retroalimentación académica. Es aquí donde la característica individual del aprendizaje en línea cumple sus objetivos. Esto subraya la importancia de que los procesos de retroalimentación se basen en patrones emocionales, no limitándose únicamente a la opinión o a la planificación de recursos de aprendizaje en entornos en línea. Además, este estudio señala una nueva área de investigación: la evaluación del impacto conductual emocional y semántico del feedback (Zhang et al., 2019; Reina González y Domínguez, 2019).

El presente trabajo de tesis doctoral, unido a los avances futuros propuestos, no solo representa una base sólida para construir futuros modelos de aprendizaje en línea, sino que también marca un hito fundamental en el mejoramiento de la conexión entre estudiantes y profesores. Al enfocarse en el impacto emocional de la interacción, se aspira a construir una docencia en línea más efectiva y humanizada, cimentando así el camino hacia un proceso educativo más enriquecedor y significativo para todos involucrados.

BIBLIOGRAFÍA

Abaalkhail, R. (2018). *Ontology Based Framework for Conceptualizing Human Affective States and Their Influences* [Thesis, Université d'Ottawa / University of Ottawa]. <http://hdl.handle.net/10393/38418>

Abraira, V. (2001). El índice kappa. *SEMERGEN - Medicina de Familia*, 27(5), 247-249. [https://doi.org/10.1016/s1138-3593\(01\)73955-x](https://doi.org/10.1016/s1138-3593(01)73955-x)

Ahmed, M., Seraj, R., & Islam, S. M. S. (2020). The k-means Algorithm: A Comprehensive Survey and Performance Evaluation. *Electronics*, 9(8), 1295. <https://doi.org/10.3390/electronics9081295>

Alzina, R. B. (2008). Educación emocional para la convivencia: las competencias emocionales. In *Educación emocional y convivencia en el aula* (pp. 143-162). Subdirección General de Información y Publicaciones.

Ampudia Rueda, A., Sánchez Crespo, G., & Jiménez Gómez, F. (2017). Precisión diagnóstica del MMPI-2 con la personalidad delictiva: un análisis con la curva ROC. *Revista de Psicología*, 35(1), 167-192. <https://doi.org/10.18800/psico.201701.006>

Anzelin, I., & Marín-Gutiérrez, A. (2020). Relación entre la emoción y los procesos de enseñanza aprendizaje. *Sophia*, 16(1), 48-64. <https://doi.org/10.18634/sophiaj.16v.1i.1007>

Ayvaz, U., Gürüler, H., & Devrim, M. O. (2017). USE OF FACIAL EMOTION RECOGNITION IN E-LEARNING SYSTEMS. *Information Technologies and Learning Tools*, 60(4), 95. <https://doi.org/10.33407/itlt.v60i4.1743>

Azevedo, R., & Gašević, D. (2019). Analyzing Multimodal Multichannel Data about Self-Regulated Learning with Advanced Learning Technologies: Issues and Challenges. *Computers in Human Behavior*, 96, 207-210. <https://doi.org/10.1016/j.chb.2019.03.025>

Behnagh, F. R. (2020). Emotions and emotional energy in the science classroom: A discussion of measurement. *Cultural Studies of Science Education*, 15(1), 307-315. <https://doi.org/10.1007/s11422-019-09929-8>

Brickley, D. y Miller, L. (14 de enero de 2024). FOAF vocabulary specification 0.99. Recuperado de <http://xmlns.com/foaf/spec/>

Burke, M. A., & Sass, T. R. (2008). Classroom Peer Effects and Student Achievement. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1260882>

Bibliografía

- Cabada, R. Z., Barrón Estrada, M. L., & Cárdenas López, H. M. (2019). Reconocimiento multimodal de emociones orientadas al aprendizaje. *Research in Computing Science*, 148(7), 153–165. <https://doi.org/10.13053/rcc-148-7-12>
- Cabral, J. C. C., & De Almeida, R. M. M. (2019). Effects of anger on dominance-seeking and aggressive behaviors. *Evolution and Human Behavior*, 40(1), 23-33.
- Cárdenas-Robledo, L. A., & Peña-Ayala, A. (2018). Ubiquitous learning: A systematic review. *Telematics and Informatics*, 35(5), 1097–1132. <https://doi.org/10.1016/j.tele.2018.01.009>
- Castillo, G., & Neff, M. (2019, May). What do we express without knowing? Emotion in Gesture. In *Proceedings of the 18th International Conference on Autonomous Agents and MultiAgent Systems* (pp. 702-710).
- Cernian, A., & Olteanu, A. (2015). Ontology based emotion detection training tool. In *The International Scientific Conference eLearning and Software for Education* (Vol. 1, p. 343). "Carol I" National Defence University.
- Chen, H., Liu, X., Li, X., Shi, H., & Zhao, G. (2019, May). Analyze spontaneous gestures for emotional stress state recognition: A micro-gesture dataset and analysis with deep learning. In *2019 14th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2019)* (pp. 1-8). IEEE.
- Chen, S.-Y. (2016). An Ontology-Based Approach to Emotional Learning in Virtual Learning Communities. *IEEE Transactions on Learning Technologies*, 9(4), 360-370. <https://doi.org/10.1109/TLT.2016.2559978>
- Chen, L., Wang, K., Li, M., Wu, M., Pedrycz, W., & Hirota, K. (2022). K-means Clustering-based Kernel Canonical Correlation Analysis for Multimodal Emotion Recognition in Human-Robot Interaction. *IEEE Transactions on Industrial Electronics*, 70(1), 1016-1024. <https://doi.org/10.1109/tie.2022.3150097>
- Clore, G. L., & Ortony, A. (1988). The semantics of the affective lexicon. Cognitive perspectives on emotion and motivation, 367-397.
- Cobos-Guzman, S., Nuere, S., De Miguel, L., & König, C. (2021). Design of a Virtual Assistant to Improve Interaction Between the Audience and the Presenter. *International Journal of Interactive Multimedia and Artificial Intelligence*, 7(2). <https://doi.org/10.9781/ijimai.2021.08.017>

Code, J., Ralph, R., & Forde, K. (2022). A Disorienting Dilemma: Teaching and Learning in Technology Education During a Time of Crisis. *Canadian Journal of Science, Mathematics and Technology Education*. <https://doi.org/10.1007/s42330-022-00191-9>

Colomo-Palacios R., Casado-Lumbreras C., Álvarez-Rodríguez J. M., & Yilmaz M. (2020). Coding vs presenting: a multicultural study on emotions. *Information Technology and People*, 33(6), 1575-1599. doi: 10.1108/ITP-12-2019-0633

Cronk, L. (2019). *That complex whole: Culture and the evolution of human behavior*. Routledge.

Cui, Q., & Gou, J. (2019). Review of Online Learning Behavior Analysis. En *Proceedings of the 4th International Conference on Economy, Judicature, Administration and Humanitarian Projects (JAHP 2019)*. Atlantis Press. <https://doi.org/10.2991/jahp-19.2019.214>

Datcu, D., & Rothkrantz, L. J. (2011, June). Emotion recognition using bimodal data fusion. In *Proceedings of the 12th International Conference on Computer Systems and Technologies* (pp. 122-128).

Deldjoo, Y., Schedl, M., Cremonesi, P., & Pasi, G. (2020). Recommender systems leveraging multimedia content. *ACM Computing Surveys (CSUR)*, 53(5), 1-38.

Dicheva, D., & Dichev, C. (2012). Domain-specific ontology-based learning object recommendation. *International Journal of Learning Technology*, 7(2), 190-210.

Dutt, A., Aghabozrgi, S., Ismail, M., & Mahroreian, H. (2015). Clustering Algorithms Applied in Educational Data Mining. *International Journal of Information and Electronics Engineering*. <https://doi.org/10.7763/ijiee.2015.v5.513>

Ekman, P. (1984). Expression and the nature of emotion. *Approaches to emotion*, 3(19), 344.

Ekman, P. (1999). Basic emotions. *Handbook of cognition and emotion*, 98(45-60), 16.

Evanger, L. N., Bjorvatn, B., Pallesen, S., Hysing, M., Sivertsen, B., & Saxvig, I. W. (2023). Later school start time is associated with longer school day sleep duration and less social jetlag among Norwegian high school students: Results from a large-scale, cross-sectional study. *Journal of Sleep Research*, e13840.

Eynde, P. O. T., & Turner, J. E. (2006). Focusing on the complexity of emotion issues in academic learning: A dynamical component systems approach. *Educational Psychology Review*, 18, 361-376.

Bibliografía

- Frijda, N. H. (1986). *The emotions*. Cambridge University Press.
- García-Cabrero, B., Luna-Serrano, E., Ponce-Ceballos, S., Cisneros-Cohenour, E., Cordero-Arroyo, G., Espinoza-Díaz, Y., & García-Vigil, M. H. (2018). Las competencias docentes en entornos virtuales: un modelo para su evaluación. *Revista Iberoamericana de Educación a Distancia*, 21(1), 343-365.
- García-Silva, A., García-Sánchez, F., y Pazos-Sanou, L. (2020). Ontology-based affective computing: A systematic review. *Information Fusion*, 58, 66-80.
- Gneiting, T., & Vogel, P. (2018). Receiver operating characteristic (ROC) curves: equivalences, beta model, and minimum distance estimation. *Machine Learning*, 111(6), 2147-2159. <https://doi.org/10.1007/s10994-021-06115-2>
- Goleman, D., & ONAL, I. N. G. A. E. (1995). Inteligencia emocional. Barcelona: Paidós.
- Gomez, H. F., Arias, S. A., Lozada, T. E., Martinez, C., Robalino, F., Castillo, D., & Aguirre, P. (2019). Emotional strategy in the classroom based on the application of new technologies: an initial contribution. *Information and Communication Technology for Intelligent Systems*. Singapore.
- González-Calvo, G., Barba-Martín, R. A., Bores-García, D., & Gallego-Lema, V. (2020). Aprender a ser docente sin estar en las aulas: La covid-19 como amenaza al desarrollo profesional del futuro profesorado. *International and Multidisciplinary Journal of Social Sciences*, 9(2), 152-177.
- Grassi, M. (2009, September). Developing HEO human emotions ontology. In *European workshop on biometrics and identity management* (pp. 244-251). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Haan, M., Gautier, P., Oosterbeek, H., & van der Klaauw, B. (2015). The Performance of School Assignment Mechanism in Practice. *Econstor*(113991).
- Harley J. M., Pekrun R., Taxer J. L. & Gross J. J. (2019) Emotion Regulation in Achievement Situations: An Integrated Model, *Educational Psychologist*, 54:2, 106-126, DOI: [10.1080/00461520.2019.1587297](https://doi.org/10.1080/00461520.2019.1587297)
- Hartnett, M., & Hartnett, M. (2016). The importance of motivation in online learning. *Motivation in online education*, 5-32.

Harvey H. B. & Sotardi S. T., "The Pareto Principle," *Journal of the American College of Radiology*, vol. 15, no. 6, p. 931, 2018, doi: 10.1016/j.jacr.2018.02.026.

Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). The elements of statistical learning: data mining, inference, and prediction (Vol. 2, pp. 1-758). New York: Springer.

Hennessey, A., & Humphrey, N. (2019). Can social and emotional learning improve children's academic progress? Findings from a randomized controlled trial of the Promoting Alternative Thinking Strategies (PATHS) curriculum. *European Journal of Psychology of Education*, 1-24.

Hingu, D. H., Khan, S., Sinha, K., & Aditya, M. (2019). Facial Expression Analysis for Emotion and Behavior of Online Learner and Framework for Content Adaptation: A Survey. IJRAR-*International Journal of Research and Analytical Reviews (IJRAR)*, E-ISSN, 2348-1269.

Hokka, P., Vahasantane, K., & Paloniemi, S. (2019). Emotions in learning at work: A literature review. *Vocations and Learning*, 1-26.

Horvat, M., Jović, A., & Burnik, K. (2021). Assessing the robustness of cluster solutions in emotionally-annotated pictures using monte-carlo simulation stabilized K-means algorithm. *Machine Learning and Knowledge Extraction*, 3(2), 435-452.

Howe, C., Hennessy, S., Mercer, N., Vrikki, M., & Wheatley, L. (2019). Teacher-student dialogue during classroom teaching: Does it really impact on student outcomes? *Journal of the learning sciences*, 28(4-5), 462-512.

Humaira, H., & Rasyidah, R. (2020, February). Determining the appropriate cluster number using Elbow method for K-Means algorithm. In *Proceedings of the 2nd Workshop on Multidisciplinary and Applications (WMA) 2018*, 24-25 January 2018, Padang, Indonesia.

Humphry, D., & Hampden-Thompson, G. (2019). Primary school pupils' emotional experiences of synchronous audio-led online communication during online one-to-one tuition. *Computers & Education*, 100-112.

Jain, A. K., & Dubes, R. C. (1988). Algorithms for clustering data. Prentice-Hall, Inc.

Jalolov, T. S. (2023). TEACHING THE BASICS OF PYTHON PROGRAMMING. *International Multidisciplinary Journal for Research & Development*, 10(11).

Jeong, H., & Yoo, J. H. (2022). Opera Clustering: K-means on librettos datasets. *Journal of Internet Computing and Services*, 23(2), 45-52.

Bibliografía

- Jung, Y., Kim, J., & Kim, H. (2015). Statistical relationships between journal use and research output at academic institutions in South Korea. *Scientometrics*, 103(3), 751-777.
- Kateb, D., & Ali, S. A. L. W. A. (2020). The Relationship between Teaching Characteristics and Students' Academic Emotions in the Classroom. *International Journal for Research in Education*, 44(1), 250-283.
- Kaufman, L., & Rousseeuw, P. J. (2009). Finding groups in data: an introduction to cluster analysis. John Wiley & Sons.
- Kaviani, A., Tammin, R., & Ghaemi, H. (2020). Teaching and learning during a global pandemic: an ecological approach. *Modern Journal of Language Teaching Methods (MJLTM)*, 10(8), 0-0.
- Khanzada, A., Bai, C., & Celepcikay, F. T. (2020). Facial expression recognition with deep learning. *arXiv preprint arXiv:2004.11823*.
- Kossaifi, J., Tzimiropoulos, G., Todorovic, S., & Pantic, M. (2017). AFEW-VA database for valence and arousal estimation in-the-wild. *Image and Vision Computing*, 65, 23-36.
- Kramer, B. L. (2020). Effect of Emotional Intelligence, Collaboration Technology, Team Climate, and Intrinsic Motivation on Virtual Team Effectiveness: A Study of Team Member Perceptions. Eastern Michigan University.
- Landis J, & Koch G. The measurement of observer agreement for categorical data. *Biometrics* 1977; 33: 159-74
- Latinjak, A. T., Lopez Ros, V., & Font Llado, R. (2014). Las emociones en el deporte: Conceptos empleados en un modelo tridimensional. *Revista de psicología del deporte*, 23(2), 0267-274.
- Lazarus, R. S. (1991). *Emotion and adaptation*. Oxford University Press.
- Ledger, S., Ersozlu, Z., & Fischetti, J. (2019). Preservice teacher's confidence and preferred teaching strategies using TeachLivE virtual learning environment: A two-step cluster analysis. *EURASIA Journal of Mathematics Science and Technology Education*, 15(3).
- Liaw, S. S., Huang, H. M., & Chen, G. D. (2018). Surveying instructor and learner attitudes toward e-learning. *Computers & Education*, 61, 158-169.

López-Guil, J. M., & Garay-Vitoria, N. (2019, June). Emotion recognition in video and audio through the use of Artificial Intelligence techniques. In *Proceedings of the XX International Conference on Human Computer Interaction* (pp. 1-2).

Mandelbrot, B. (1960). The Pareto-Levy law and the distribution of income. *International economic review*, 1(2), 79-106.

Manea, V. I., Macavei, T., & Pribeanu, C. (2020). Stress, frustration, boredom, and fatigue in online engineering education during the pandemic. *International Journal of User-System Interaction*, 13(4), 169-181.

Marsh, A. A., Rhoads, S. A., & Ryan, R. M. (2019). A multi-semester classroom demonstration yields evidence in support of the facial feedback effect. *Emotion*, 19(8), 1500.

Mcilhany, K., y Wiggins, S. (2018). High Dimensional Cluster Analysis Using Path Lengths. *Journal of Data Analysis and Information Processing*, 06(03), 93-125. <https://doi.org/10.4236/jdaip.2018.63007>

McLeod, S. (2018). Pareto Principle. *Simply Psychology*.

Mel, D., Phan, T., Damarla, T., Vasconcelos, W., & Norman, T. (2011). Semantically Enriched Data for Effective Sensor Data Fusion. ACITA. Maryland: University of Maryland.

Melgare, J. K., Musse, S. R., Schneider, N. R., & Queiroz, R. B. (2019, October). Investigating emotion style in human faces and avatars. In *2019 18th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames)* (pp. 115-124). IEEE.

Meyers, D., Domitrovich, C., Dissi, E., Trejo, J., & Greenberg, M. T. (2019). Supporting systemic social and emotional learning with a schoolwide implementation model. *Evaluation and Program Planning*, 73, 53-61.

Mohanty, S., & Swain, B. K. (2010). Emotion recognition using fuzzy K-means from Oriya speech.

Neoh, S. C., Zhang, L., Mistry, K., Hossain, M. A., Lim, C. P., Aslam, N., & Kinghorn, P. (2015). Intelligent facial emotion recognition using a layered encoding cascade optimization model. *Applied soft computing*, 34, 72-93.

Ortis, A., Farinella, G. M., & Battiato, S. (2020). Survey on visual sentiment analysis. *IET Image Processing*, 14(8), 1440-1456.

Pal, S., Hitchens, M., Rabehaja, T., & Mukhopadhyay, S. (2020). Security requirements for the internet of things: A systematic approach. *Sensors*, 20(20), 5897.

Bibliografía

- Palmer, D. (2017). The action tendency for learning: Characteristics and antecedents in regular lessons. *International Journal of Educational Research*, 82, 99-109.
- Parkinson, B. (2019). Emotion. In *Companion Encyclopedia of Psychology* (pp. 485-505). Routledge.
- Pazos-Sanou, L., García-Silva, A., & García-Sánchez, F. (2018). Ontology-Based Emotion Recognition for Human-Machine Interaction. *IEEE Transactions on Affective Computing*, 9(2), 215-228.
- Pazos-Sanou, L., García-Silva, A., & García-Sánchez, F. (2021). Affective computing: Recent advances and future directions using ontology-based approaches. *Information Processing and Management*, 58(4), 102565.
- Petrova, A., Vaufreydaz, D., & Dessus, P. (2020, October). Group-level emotion recognition using a unimodal privacy-safe non-individual approach. In *Proceedings of the 2020 International Conference on Multimodal Interaction* (pp. 813-820).
- Plutchik, R. (2001). The nature of emotion. *American Scientist*, 89.
- Raes, A., Vanneste, P., Pieters, M., Windey, I., Van Den Noortgate, W., & Depaepe, F. (2020). Learning and instruction in the hybrid virtual classroom: An investigation of students' engagement and the effect of quizzes. *Computers & Education*, 143, 103682.
- Rattel, J. A., Mauss, I. B., Liedlgruber, M., & Wilhelm, F. H. (2020). Sex differences in emotional concordance. *Biological Psychology*, 151. doi: 10.1016/j.biopsych.2020.107845.
- Rebollo Catalán, M. Á., García Pérez, R., Buzón García, O., & Vega Caro, L. (2014). Las emociones en el aprendizaje universitario apoyado en entornos virtuales: diferencias según actividad de aprendizaje y motivación del alumnado. *Revista Complutense de Educación*, 25 (1), 69-93.
- Reina González, M. C., & Domínguez, C. M. (2019). Soporte emocional docente y ajuste escolar de los estudiantes de las sedes San Cristóbal Bajo y Mirasol de las zonas rurales de la ciudad de Ibagué.
- Rodríguez-Galván, L. C., Abbas, A., Ar, A. Y., Garza-González, B., & Alonso-Galicia, P. E. (2022). Do sentiments of professors feedback change after migrating from in-person to online modalities? Pre-and during COVID-19 experience. *Universal Access in the Information Society*, 1-10.

Romania, V. (2021). Vilfredo Pareto. In *The Emotions in the Classics of Sociology* (pp. 96-112). Routledge.

Rousseeuw, P. J. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, 20, 53-65.

Rowe, J. P., & Lester, J. C. (2020). Artificial intelligence for personalized preventive adolescent healthcare. *Journal of Adolescent Health*, 67(2), S52-S58.

Ruiz, M. C., Bortoli, L., & Robazza, C. (2020). The multi-states (MuSt) theory for emotion-and action-regulation in sports. In *Feelings in Sport* (pp. 3-17). Routledge.

Russo, T. C., & Benson, S. (2005, January). Learning with invisible others: Perceptions of online presence and their relationship to cognitive and affective learning. *International Forum of Educational Technology and Society*.

Sánchez Chacón, C. L., & Duarte Sabogal, D. C. (2020). Percepción emocional del docente-tutor en el proceso de aprendizaje de estudiantes de educación superior en modalidad distancia.

Schunk, F., Trommsdorff, G., Wong, N., & Nakao, G. (2021). Associations between emotion regulation and life satisfaction among university students from Germany, Hong Kong, and Japan: The mediating role of social support. *Frontiers in psychology*, 12, 4631.

Shichuan, D., Yong, T., & Martinez, A. (2014). Compound facial expressions of emotion. *PNAS*, 111(15).

Shinwari, M. N., Iqbal, H., Yasir, W., Akbar, S., Andleeb, I., & Jamil, M. N. (2023). Exploring The Nexus Between Emotional Intelligent And Academic Engagement Of University Students. *Journal of Positive School Psychology*, 1762-1772.

Simonyan, K., & Zisserman, A. (2014). Two-stream convolutional networks for action recognition in videos. *Advances in Neural Information Processing Systems*, 27.

Stark, L., Brünken, R., & Park, B. (2018). Emotional text design in multimedia learning: A mixed-methods study using eye tracking. *Computers & Education*, 120, 185-196.

Storey, V. C., & Park, E. H. (2022). An ontology of emotion process to support sentiment analysis. *Journal of the Association for Information Systems*, 23(4), 999-1036.

Strapparava, C., & Mihalcea, R. (2007). Semeval-2007 task 14: Affective text. In *Proceedings of the 4th International Workshop on Semantic Evaluations (SemEval-2007)* (pp. 70-74).

Bibliografía

- Tao, X., Gao, H., Liao, R., Wang, J., & Jia, J. (2017). Detail-revealing deep video super-resolution. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 4472-4480).
- Thaler, R. H., y Sunstein, C. R. (2009). Nudge: Improving decisions about health, wealth, and happiness. *Penguin*.
- Tooby, J., & Cosmides, L. (2008). The evolutionary psychology of the emotions and their relationship to internal regulatory variables.
- Vallerand, R. J., & Blanchard, C. M. (2000). The study of emotion in sport and exercise: Historical, definitional, and conceptual perspectives. In Y. L. Hanin (Ed.), *Emotions Sport* (pp. 3-37).
- Vedder-Weiss, D., Segal, A., & Lefstein, A. (2019). Teacher face-work in discussions of video-recorded classroom practice: Constraining or catalyzing opportunities to learn? *Journal of Teacher Education*, 70(5), 538-551.
- Villamizar, S. B. C., Ruiz, L. L. V., & Suarez, A. A. G. (2023). Perspectives of ubiquitous learning in educational contexts. *Journal of Positive Psychology and Wellbeing*, 86-90.
- Wang, Z., Ho, S. B., & Cambria, E. (2020). Multi-level fine-scaled sentiment sensing with ambivalence handling. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 28(04), 683-697.
- Zhang, M., Wang, J., & Zhou, R. (2019). Entropy value-based pursuit projection cluster for the teaching quality evaluation with internal number. *Entropy*, 21(2), 203.
- Zubair Asghar, M., Subhan, F., Imran, M., Masud Kundi, F., khan, A., Shamshirband, S., Mosavi, A., R. Varkonyi Koczy, A., & Csiba, P. (2020). Performance Evaluation Of Supervised Machine Learning Techniques For Efficient Detection Of Emotions From Online Content. *Computers, Materials & Continua*, 63(3), 1093-1118. <https://doi.org/10.32604/cmc.2020>.

