

EJERCICIOS INTERDISCIPLINARES. DIÁLOGO ENTRE EL DISEÑO Y EL MACHINE LEARNING PARA EL ANÁLISIS MORFOLÓGICO

INTERDISCIPLINARY EXERCISES. MACHINE LEARNING AND DESIGN IN DIALOGUE FOR MORPHOLOGICAL ANALYSIS STUDIES

PALABRAS CLAVE

Diseño,
Análisis morfosemántico,
Estadística multivariada,
Algoritmos genéticos,
Cluster de análisis,
Producto de diseño,
Machine Learning

KEYWORDS

Design,
Morphosemantic analysis,
Multivariate statistics,
Genetic algorithms,
Cluster analysis,
Design product,
Machine Learning

**ANNA TRIPALDI-PROAÑO, TOA TRIPALDI-PROAÑO y
PIERCOSIMO TRIPALDI-CAPPELLETTI**

Universidad del Azuay
Cuenca, Ecuador

RECIBIDO

23 DE SETIEMBRE DE 2025

ACEPTADO

1 DE JUNIO DE 2026



EL CONTENIDO DE ESTE ARTÍCULO
ESTÁ BAJO LICENCIA DE ACCESO
ABIERTO CC BY-NC-ND 2.5 AR

INFORMACIÓN PARA CITAR ESTE ARTÍCULO

Tripaldi-Proañó, Anna; Tripaldi-Proañó, Toa y Tripaldi-Cappelletti, Piercosimo (2026, Mayo-Octubre). Ejercicios interdisciplinarios. Diálogo entre el Diseño y el Machine Learning para el análisis morfológico. AREA, 32(2), 1-28. <https://doi.org/10.62166/area.32.2.4018>

RESUMEN

Este artículo explora, a través de la revisión de casos, las posibilidades de uso del *Machine Learning* en las investigaciones sobre Diseño, puntualmente en los procesos de análisis morfosemántico. Luego de la revisión de los procesos chemiométricos realizados en una serie de investigaciones tomadas como referentes se evidencia cómo, dentro de la estadística multivariada, los métodos de clasificación, el *cluster* de análisis y la aplicación de algoritmos genéticos permiten obtener resultados factibles de ser triangulados con información cualitativa, altamente descriptivos y estratégicos para los procesos de diseño. Se evidencia también cómo los procesos inter y transdisciplinarios favorecen la emergencia de nuevos descubrimientos y enriquecen la agencia algorítmica en el diseño.

ACERCA DE LAS AUTORAS Y EL AUTOR

Anna Tripaldi-Proaño. Licenciada en Comunicación Social, Magíster en Estudios de la Cultura con mención en Diseño y Arte y PhD en Diseño por la Universidad de Palermo, Argentina. Profesora e investigadora de la Universidad del Azuay desde 2003, ha colaborado con cátedras en las facultades de Diseño, Filosofía, Ciencias y tecnología y Ciencias Jurídicas, así como en posgrados de diversas universidades. Autora de varias publicaciones, artículos indexados, capítulos de libros y libros, entre otros: *Diseñar Hoy* (2016), *Diseño y Arquitectura: Una mirada a las disciplinas desde la academia* (2017), *Una breve historia sobre la interdisciplinariedad del diseño* (2023), *Diseño orientado a las prácticas sociales* (2024), *Diseño y filosofía* (2025), *Imágenes que hablan* (2026). Es parte del Grupo de Investigación en Historia, Teoría y Epistemología del Diseño de la Universidad del Azuay.

✉ <atripaldi@uazuay.edu.ec>

🔗 <https://orcid.org/0000-0001-5068-3266>

Toa Tripaldi-Proaño. Diseñadora, Magíster en Diseño y PhD en Diseño por la Universidad de Palermo, Argentina. Profesora e investigadora de la Universidad del Azuay desde 2004, dicta cátedras de Taller de Diseño, Proyectos de Graduación, Epistemología e Historia del Diseño entre otras, y colabora en la Escuela de Posgrados de la Universidad del Azuay. Es autora de varias publicaciones, artículos indexados, capítulos de libros y libros, entre otros: *Diseño y Arquitectura: Una mirada a las disciplinas desde la academia* (2017), *Una breve historia sobre la interdisciplinariedad del diseño* (2023), *Diseño y filosofía* (2025), *Imágenes que hablan* (2026). Es directora del Grupo de Investigación en Historia, Teoría y Epistemología del Diseño de la Universidad del Azuay. Actualmente se desempeña

ABSTRACT

This article explores, through the review of several cases, the possibilities of using Machine Learning in design research, specifically in the processes of morphosemantic analysis. After reviewing the chemometric processes carried out in each of the research taken as references, it is evident how, within multivariate statistics, classification methods, cluster analysis and the application of genetic algorithms allow obtaining results that can be triangulated with qualitative information and that are also highly descriptive and strategic for design processes. It is also evident how inter- and transdisciplinary processes favor the emergence of new discoveries and enrich algorithmic agency in design.

como decana de la Facultad de Diseño y Arte y como Directora de la Casa Editora de la Universidad del Azuay.

✉ <ttripaldi@uazuay.edu.ec>

🔗 <https://orcid.org/0000-0002-3115-0170>

Piercosimo Tripaldi-Cappelletti. Doctor magistral en Química por la Università di Milano, profesor e investigador principal en la Facultad de Ciencia y Tecnología de la Universidad del Azuay, autor de numerosos artículos indexados y director de proyectos de investigación sobre modelización multivariante en problemas de alimentos, medio ambiente, salud, educación, diseño, entre otros. Asesor en temas de análisis de datos. Miembro del grupo de investigación Quimioinformática de la Universidad del Azuay.

✉ <tripaldi@uazuay.edu.ec>

🔗 <https://orcid.org/0000-0002-0155-828X>

CONTRIBUCIONES DE AUTORÍA (CRediT)

Anna María Tripaldi-Proaño: Conceptualización, Investigación, Metodología, Redacción del borrador original.

Toa Tripaldi-Proaño: Conceptualización, Investigación, Metodología, Administración del proyecto, Supervisión, Validación, Redacción del borrador original, Redacción, revisión y edición.

Piercosimo Tripaldi-Cappelletti: Investigación, Metodología, Análisis formal, Curación de datos, Software, Validación, Recursos, Visualización, Redacción, revisión y edición.

Antecedentes

En el presente estudio se analizan casos de aplicación del *Machine Learning* para el análisis de la forma en productos de diseño. En este contexto, la forma no se entiende únicamente como configuración externa, sino como un sistema de relaciones que articula dimensiones funcionales, perceptivas y significantes. Desde esta perspectiva, el análisis morfosemántico permite abordar la forma como un soporte de sentido, en el que se inscriben patrones que pueden ser identificados, clasificados y correlacionados mediante técnicas de análisis multivariado. La generación y las propiedades de la forma son temas importantes en la agenda actual de la disciplina como se aprecia en el caso de Aitor Lekuona Amundarain, Manuel Domínguez Somonte y María del Mar Espinosa Escudero (2021) quienes estudian el potencial creativo del diseño paramétrico; o bien en el de Diego Rodríguez de Ita (2026) y en coautoría con Sofía Alejandra Luna Rodríguez (2024) quien lo aplica en la arquitectura, junto con la biomimética. En la misma línea encontramos otros estudios como el de Juan José Fontana-Cabezas, Paulo Pereyra-Bonifacio, Marina Piñeyro-Rodríguez y Claudia Chocca-Bosio (2024) y el de María Georgina Bredanini Colombo, Natalia Victoria Acevedo Vacherand y María Soledad Bustamante (2025), quienes trabajan en el diseño de nuevas formas a través de diseño generativo, este estudio se concentra en las propiedades de la forma ya dada y cómo ésta puede ser analizada a través de metodologías mixtas y especialmente mediante el uso de algoritmos. Tradicionalmente el análisis morfológico se realizaba con métodos cualitativos basados en la observación -muchas de las veces no estructurada- de objetos diseñados, en este sentido encontramos trabajos como los de Esteban Cecil Paredes (2024), Kevin Joel Paredes Díaz (2023), Santiago España Muñoz (2023), José André Barreiro Chusan (2021), y el de Anna María Biedermann, Aranzazu Fernández-Vázquez y María Elipe Maldonado (2017). Aquí se presentan casos de análisis morfosemántico que trascienden esta práctica común de enfoque cualitativo y trasladan el estudio al enfoque cuantitativo a través del uso del *Machine Learning* y la estadística multivariada.

El propósito de este análisis es poner en evidencia la utilidad de esta metodología para ampliar el estudio de la forma en diseño. En particular, permite comprender tendencias proyectuales, vincular la forma de los productos con sus contextos de producción, reconstruir su historia material, identificar rasgos distintivos en conjuntos de diseños, mapear su evolución formal a lo largo del tiempo y trazar líneas históricas de desarrollo. En los casos abordados, se observa cómo el análisis de variables, inicialmente definido a partir de indicadores cualitativos -en su mayoría de carácter descriptivo-, es posteriormente traducido a criterios numéricos con el fin de objetivar los resultados. En este marco, el uso de técnicas de análisis multivariado y *Machine Learning* posibilita procesar grandes volúmenes de variables que describen objetos de diseño, dando lugar a la generación de clasificaciones y modelos predictivos. Estos permiten comprender la forma de los objetos con mayor sistematicidad, profundidad y rigurosidad, tanto en su desarrollo temporal como en relación con otros objetos de la misma u otras categorías. Desde estos casos se propone demostrar la relevancia del *Machine Learning* en los estudios de diseño -en particular en el análisis morfosemántico- y, al mismo tiempo, evidenciar el potencial del Diseño como campo de articulación interdisciplinar y transdisciplinar para la comprensión de los ecosistemas objetuales.

Estado de la cuestión

El uso de la estadística multivariada y el *Machine Learning* ha estado en aumento desde el año 2010. Los estudios se dividen entre aquellos que incluyen análisis factorial y estadística multivariada, más concentrados en el análisis de la forma, y aquellos con interés hacia el *Deep Learning*, las lógicas difusas y los análisis multimodales, estos más concentrados en la generación de formas.

En un primer grupo se encuentran los trabajos centrados en el análisis de la forma y sus posibilidades de cuantificación. Estos estudios suelen apoyarse en metodologías de carácter predominantemente artesanal, con escaso uso de métricas globales y modelados estadísticos limitados, como regresiones simples (Song, Xie, Huang y Yu, 2023; Čok, Vlah y Povh, 2021; Čok, Vlah y Žavbi, 2020; Li y Zhu, 2020). A este conjunto pueden sumarse investigaciones que, aunque no implementan procesamientos multivariados completos, avanzan en la codificación sistemática de variables morfológicas y principios de Diseño. Entre ellas se destaca, por un lado, el trabajo de María Tabuenca Bengoa, Laura González-Díez y Belén Puebla Martínez (2020), quienes proponen una metodología para el análisis de carteles basada en fichas que integran datos cualitativos y cuantitativos relativos a la composición, el contenido textual e icónico y la propuesta cromática. Por otro lado, Maria Moga (2025) plantea una metodología semicuantitativa para evaluar la carga morfológica en sillas icónicas de la historia del diseño, a partir de criterios como complejidad, expresividad o función afectiva, lo que permite su clasificación en distintos tipos. En conjunto, estos estudios sientan las bases relevantes para la sistematización del análisis formal, aun cuando no explotan plenamente herramientas multivariadas.

Un segundo grupo incorpora el uso de modelado multivariado clásico para el análisis de la forma, particularmente en aspectos como texturas, curvaturas y morfología superficial. En estos casos se emplean descriptores geométricos y de textura que permiten establecer medidas rigurosas e interpretables, constituyendo una base metodológica sólida para desarrollos posteriores, incluso en el campo generativo (Matsumoto, Sato, Matsuoka y Kato, 2019; Bai, Guo y Jia, 2019; Liu, Lughofer y Zeng, 2015).

En un tercer nivel se sitúan los estudios que profundizan en el uso de *Machine Learning*. Aquí, la morfología deja de codificarse únicamente mediante variables definidas manualmente y pasa a representarse a través de características visuales profundas y multiescala. Esto permite identificar patrones y regularidades de mayor complejidad en los objetos analizados (Zhao, Cao y Lau, 2018; Brown y Mueller, 2018; Yoshimura, Cai, Wang y Ratti, 2018). En esta misma línea se inscriben trabajos que integran criterios Kansei con estadística multivariada y aprendizaje automático, ampliando el análisis hacia dimensiones perceptuales y afectivas (Song, Xie, Huang y Yu, 2023).

Finalmente, un cuarto grupo de estudios se orienta hacia enfoques predictivos y generativos, mediante el uso de técnicas como *clustering*, algoritmos genéticos y modelos de predicción (Wang et al., 2026; Trivedi et al., 2023; Čok, Vlah y Povh, 2021; Li y Zhu, 2020; Brown y Mueller, 2018). Estos trabajos se alinean más directamente con los procesos abordados en el presente estudio, en tanto no sólo analizan la forma, sino que buscan modelar su comportamiento y anticipar posibles configuraciones.

La revisión evidencia que este tipo de estudios son más frecuentes en el campo del Diseño Industrial, el Diseño Gráfico y la Arquitectura que en las otras especialidades (textil, indumentaria e interiorismo). Más significativo aún es que, mayoritariamente son estudios que se están desarrollando en el continente asiático¹. Los ejemplos expuestos permiten evidenciar un vacío en torno al uso de metodologías multivariadas para el análisis en investigaciones de Diseño en Latinoamérica. Esta ausencia no necesariamente implica que tales aproximaciones no existan, sino que muchas de ellas, especialmente aquellas producidas en Iberoamérica, permanecen poco visibles o escasamente sistematizadas en la literatura académica. Por esta razón, resulta pertinente dar cuenta de ejercicios de investigación desarrollados mediante este tipo de métodos, con el fin de mostrar su validez y potencial para el estudio del Diseño en Latinoamérica. En este sentido, visibilizar estos trabajos contribuye no sólo a ampliar el campo metodológico de la disciplina, sino también a reconocer aportes que permanecen insuficientemente representados en el debate internacional.

Marco teórico

El Diseño cuenta con una larga tradición en el uso de algoritmos, tanto en herramientas digitales como en procesos proyectuales. Desde hace décadas, los *software* de diseño incorporan lógicas algorítmicas, y más recientemente, el diseño generativo y las plataformas de inteligencia artificial han profundizado su integración en los procesos creativos y técnicos de producción formal. Sin embargo, en el campo de la investigación sobre la forma del objeto diseñado, el uso de algoritmos como herramientas de análisis ha sido relativamente poco explorado.

En este contexto, la estadística multivariada y el *Machine Learning* ofrecen un conjunto de recursos analíticos rigurosos y versátiles que, si bien tuvieron un desarrollo inicial en disciplinas como la Química, hoy se han expandido a numerosos campos. Su incorporación al análisis morfológico permite avanzar en la formalización, sistematización e interpretación de estructuras formales complejas.

Al mismo tiempo, el creciente debate en torno a la relación entre diseño y algoritmos -frecuentemente polarizado entre posiciones críticas y perspectivas integradoras- abre la posibilidad de repensar el rol del diseñador. En esta línea, Tiziano Bonini y Emiliano Treré (2024) proponen el concepto de *agencia algorítmica*, entendido como la capacidad reflexiva de los sujetos para intervenir en el uso y los efectos de los algoritmos, no sólo operando con ellos sino también reaccionando críticamente a sus resultados.

Desde esta perspectiva, las prácticas de diseño que incorporan algoritmos pueden interpretarse no sólo como adopciones técnicas, sino también como formas de apropiación, innovación e incluso resistencia frente a las condiciones tecnológicas contemporáneas. En este sentido, el presente estudio se propone explorar las posibilidades de los algoritmos -en particular, en el

1 De los mencionados sólo se exceptúan los trabajos de Tabuenca Bengoa, González-Díez y Puebla Martínez (2020) realizado en España y de Moga (2025) en EE. UU. quienes proponen una metodología para analizar carteles desde el Diseño Gráfico, mediante la generación de fichas que permiten recoger datos cualitativos y cuantitativos sobre su composición, contenido textual e icónico y propuesta cromática.

marco de la estadística multivariada y el *Machine Learning*- como herramientas para el análisis morfológico.

El análisis morfosemántico, tradicionalmente basado en criterios cualitativos, permite traducir observaciones en términos cuantificables. Esta transformación resulta especialmente relevante para el estudio de la forma en diseño, ya que posibilita sistematizar y comparar configuraciones formales. Sin embargo, cuando el número de variables descriptivas es elevado, el volumen de datos generado dificulta su análisis integrado.

En este contexto, la estadística multivariada y el *Machine Learning* emergen como herramientas particularmente adecuadas. Ambos enfoques comparten fundamentos matemáticos y estadísticos -como la probabilidad, la correlación y la regresión- y permiten identificar patrones, relaciones y estructuras en conjuntos de datos complejos. Mientras que la estadística multivariada se orienta principalmente a la exploración e interpretación de datos mediante técnicas como el análisis de componentes principales, el análisis factorial o el análisis discriminante, el *Machine Learning* incorpora algoritmos capaces de aprender de los datos para realizar predicciones o clasificaciones. En este estudio, ambos enfoques se articulan con el objetivo de analizar y modelizar patrones en la forma de los productos de diseño.

En los estudios de análisis morfológico es habitual partir de un abordaje cualitativo y, en función de la diversidad de respuestas, avanzar hacia la definición de variables cuantificables. Este pasaje, aunque no siempre sistematizado, resulta clave, pero introduce una complejidad adicional: la generación de grandes matrices de datos abstractos cuya lectura excede las posibilidades de la estadística descriptiva. En estos casos, se requiere un enfoque sistémico que permita captar relaciones, correlaciones y comportamientos grupales, especialmente en fenómenos complejos como los vinculados a la forma.

El análisis multivariado ofrece un marco integral para abordar esta complejidad, permitiendo procesar grandes volúmenes de datos de manera conjunta mediante técnicas de clasificación, regresión, análisis de similitud y reducción de dimensionalidad. Tal como señala Roberto Todeschini (1998), estas herramientas resultan especialmente adecuadas para sistemas caracterizados por múltiples variables, presencia de ruido, correlaciones espurias o no linealidades, así como por efectos sinérgicos y propiedades emergentes.

Metodológicamente, estos análisis se estructuran a partir de matrices de datos en las que las observaciones (objetos de diseño) se organizan en filas y las variables (atributos morfológicos) en columnas. En los casos abordados, estas variables suelen codificarse mediante criterios dicotómicos (presencia/ausencia) o escalas ordinales que indican distintos grados de presencia.

El proceso analítico incluye, en primer lugar, una fase de pretratamiento de datos, que implica la verificación de su consistencia, la eliminación de variables constantes y la estandarización de los valores. Posteriormente, se desarrollan análisis exploratorios -como el *clustering*, frecuentemente mediante métodos aglomerativos como el de Joe Ward (1963)- que permiten identificar agrupamientos significativos de objetos o variables. Cuando estos grupos adquieren sentido en relación con los objetivos del estudio, pueden interpretarse como clases y dar lugar a la aplicación de métodos de clasificación supervisada.

Estos métodos construyen modelos a partir de variables independientes con el objetivo de asignar los objetos a clases previamente definidas, ya sea por criterios teóricos, variables categóricas o resultados de análisis exploratorios.

Entre las técnicas empleadas se incluyen el algoritmo K-Vecinos Más Cercanos (K-Nearest Neighbors K-NN), los árboles de decisión (CART) y diversos algoritmos de *Machine Learning*.

Un aspecto central en este tipo de modelización es la selección de variables, ya que de ella dependen la interpretabilidad y la robustez de los modelos. Para ello pueden emplearse distintas estrategias, entre las que se destacan los algoritmos genéticos, como el enfoque propuesto por Riccardo Leardi (2001), utilizado en los casos analizados. Este tipo de procedimientos permite identificar subconjuntos óptimos de variables tanto para tareas de clasificación como de regresión.

Los resultados obtenidos mediante estos enfoques resultan más robustos, en tanto permiten mitigar la incidencia de factores disruptivos y mejorar la estabilidad de los modelos. Asimismo, facilitan la triangulación con otros métodos -incluidos los cualitativos-, contribuyendo a la validación de hipótesis y al desarrollo de marcos teóricos más consistentes.

Estudio de casos

A pesar de las críticas que señalan la limitada capacidad de generalización de los estudios de casos, este artículo no busca construir teoría, sino evidenciar colaboraciones interdisciplinarias exitosas entre diseño y estadística multivariada. Además, investigaciones de ciencias exactas a menudo emplean muestras similares sin comprometer su validez, lo que respalda la confiabilidad del análisis de múltiples casos en este contexto. Para el presente estudio se seleccionaron los casos en función de su potencial para evaluar en diferentes escenarios el uso de métodos de *Machine Learning*, es decir se aplicó una muestra no probabilística por conveniencia. Se trata de seis casos de estudio en los que se puede apreciar la aplicación de estos métodos de análisis de datos en investigaciones relacionadas con el análisis morfológico y semántico en productos de diseño. En ellos el procesamiento se realizó con los criterios antes descritos y siguiendo procesos que buscan objetivos similares, agrupamientos de objetos y/o identificación de variables clave que permitan encontrar respuestas sobre el análisis morfológico o describir el comportamiento morfológico de los objetos a lo largo del tiempo.

En cada una de las aplicaciones los resultados han devenido en datos interesantes y útiles para la toma de decisiones estratégicas sobre el diseño o para la documentación histórica sobre la evolución de la forma de tal o cual producto. A continuación, se describen los casos revisados.

Caso 1. Estrategias evolutivas del objeto-signo (2011)

Este estudio tiene como objetivo explorar la relación entre diseño y cultura, centrándose en cómo el diseño puede permanecer inalterado o adaptarse con el tiempo (Tripaldi-Proañó, Tripaldi-Proañó, Tripaldi-Cappelletti y Arévalo-Peña, 2017). Utiliza enfoques semióticos y evolucionistas para investigar cómo los productos de diseño transmiten significados y, por lo tanto, contribuyen a la formación y preservación de la identidad cultural. Desde una mirada inter y transdisciplinaria, se presenta un ejercicio teórico que se valida mediante un análisis de casos utilizando metodologías como el análisis de contenidos y el procesamiento multivariado de datos. La conclusión propone una reflexión sobre el rápido cambio de los objetos de consumo en la sociedad contemporánea.

En este estudio se analizan 25 objetos con la finalidad de mapear las modificaciones que, a lo largo de los años, ha sufrido su forma. Se toman como punto de partida las ideas de Donis Dondis (2017), Jean Baudrillard (2010) y Mauricio Sánchez Valencia (2009), y se proponen tres criterios de análisis: contextual, morfológico y semántico, así a través de 63 variables se describen las particularidades históricas de los objetos, las lógicas de valor, la morfología, el nivel de desempeño, los instantes de la forma, los elementos, la composición, los principios estructurales y las complejidades, las posibilidades significativas del signo, la memoria y el lugar en el sistema de signos, las dinámicas de los procesos de significación, entre otras.

Luego de un análisis cualitativo, se construye una matriz cuantitativa con datos dicotómicos, ordinales y continuos. En esta matriz se procede a realizar el análisis multivariado en tres fases.

En la primera fase aplica un escalado por rango para estandarizar las unidades de todas las variables. Este método se seleccionó por su robustez, ya que es adecuado para datos dicotómicos, ordinales y continuos.

En la segunda fase se explora la matriz ya escalada utilizando un método de análisis de *clusters*, el que agrupa los 25 objetos según la similitud o diferencia en sus características dentro del espacio de variables que los describen. El método de Ward (1963) fue seleccionado para este propósito, ya que organiza inicialmente los objetos más similares y luego incorpora gradualmente los demás. Este método de agrupación es no jerárquico, lo que implica que la determinación del número de *clusters* se realiza después de analizar el dendrograma obtenido (Figura 1).

Este enfoque se basa en consideraciones previas para combinar los datos y lograr la máxima homogeneidad en las similitudes entre objetos dentro de los grupos, manteniendo coherencia con los supuestos subyacentes. Aunque el resultado puede variar según el método de agrupación utilizado, los *clusters* tienden a mantenerse compactos si son consistentes, independientemente del método aplicado.




Figura 1

Dendrograma obtenido de los *clusters* con criterio estadístico de mayor homogeneidad (línea horizontal).

Fuente: Tripaldi-Proañó et al. (2017).

Finalmente, en la tercera fase del estudio se desarrolla un modelo que vincula de manera cuantitativa los objetos de los *clusters* con las variables descriptivas, mediante cuatro pasos secuenciales:

1. Se selecciona un subconjunto óptimo de variables para construir el modelo a partir de 63 variables descriptivas, utilizando un algoritmo genético acoplado al método de clasificación K-NN. El método K-NN (Johnson y Ehrlich, 2002) clasifica un objeto basado en la mayoría de las clases presentes entre los K vecinos más cercanos. Generalmente, K es un número impar que se ajusta para obtener el mejor modelo, probando con valores crecientes de K desde 1 hasta 9 u 11 vecinos, seleccionando la distancia adecuada.
2. El proceso de selección genética de variables significativas (Figura 2) se inspira en la selección natural, utilizando secuencias binarias largas de 0 y 1 para representar la presencia o ausencia de variables (cromosomas). Se calcula un modelo para cada cromosoma y se ordenan según su calidad (función de puntuación). En una fase evolutiva, los cromosomas se cruzan para generar descendientes que mantienen características de sus padres y se evalúan nuevamente. Este ciclo se repite hasta alcanzar un criterio de puntuación previamente establecido. Además, cada cierto número de ciclos se introduce una mutación en un cromosoma para simular la variabilidad natural.




Figura 2
Representación del esquema simplificado de la selección genética.
Fuente: Tripaldi-Proañó et al. (2017).

Con la finalidad de emular el mecanismo natural, cada 100 o 500 ciclos se introduce la mutación de un cromosoma: es decir, una variable presente se elimina o en su defecto se introduce si no está presente. De esta manera de un cromosoma padre se obtiene un cromosoma mutado. Se recalcula el modelo con esta mutación incluida y se introduce en la población reordenándola. El último cromosoma se elimina y se continúan los ciclos (Tripaldi-Proañó et al., 2017).

Como resultado se obtiene una población de modelo mejor que la primera; en general se utiliza el primer modelo del ranking. En este trabajo se usa el protocolo de Leardi (1998) implementado como *toolbok* de MATLAB.

3. Se determinan los parámetros de calidad del modelo utilizando el *no error rate* (tasa de no error) en validación cruzada y ajuste. Esta métrica se calcula mediante una matriz de confusión que resume la

clasificación, mostrando cuántos objetos de cada clase se clasifican correctamente. Se calcula el *no error rate* para cada clase y se promedia para evaluar la calidad general del modelo tanto en clasificación como en predicción (Tabla 1).

Tabla 1. Ejemplo de matriz de confusión

Clase inicial	CLASE CALCULADA O PREDICTA			Total de línea
	Clase A'	Clase B'	Clase C'	
Clase A	9	0	1	10
Clase B	0	4	2	6
Clase C	0	0	9	9
Total de columna	9	4	12	25

Fuente: Tripaldi-Proañó et al. (2017).

Para cada clase se calcula el *no error rate* que es la fracción de objetos clasificados correctamente. El *no error rate* total es el promedio aritmético de los *non error rates* de cada clase. Este procedimiento se aplica a la clasificación de un subconjunto de los datos que no ha sido usado en la modelización y se calcula de la misma manera en predicción.

- Una vez seleccionadas las variables más importantes, se refina el modelo K-NN utilizando el algoritmo de árbol de decisión CART (Breiman, Friedman, Stone y Olshen, 1984; Todeschini, 1998). Este método divide sucesivamente los datos en función de umbrales de variables para obtener grupos con la menor heterogeneidad posible dentro de cada clase. El modelo resultante es un árbol de decisión que indica todos los objetos que tienen valores menores a 0.5 de la variable la interpretación y aplicación práctica (Figura 3).




Figura 3

Modelo matemático método CART, 2017. La variable "Valor de signo" determina el grupo 3 (MODA), mientras que la variable "Valor de uso" determina a los grupos 2 (ESTILO) y 1 (CLÁSICO), coincidiendo con el planteamiento teórico. Con un NER 0.86.

Fuente: Tripaldi-Proañó et al. (2017).

En este estudio no se incluye un modelo de predicción debido a la limitada cantidad de objetos analizados.

Los resultados de este estudio permitieron identificar un modelo matemático que valida la hipótesis y facilita responder las preguntas de investigación. Por medio de la aplicación de estas metodologías, se identifican dos tipologías de objetos aquellos en los que los cambios responden a lógicas de valor de uso -cambios morfológicos y actualizaciones más lentas- y aquellos que se

modifican por lógicas de valor de signo -que se modifican constantemente en el tiempo con cambios de corto plazo relacionados a lógicas de estatus y diferenciación-.

Además, en función del estudio de casos y de los resultados arrojados en el análisis estadístico, se puede constatar que los altos niveles de utilidad, sencillez y estructuras focales caracterizan a los objetos que permanecen y que se van insertando en la vida cotidiana volviéndose “invisibles” (Tripaldi-Proañó et al., 2017, p. 633).

Como se puede apreciar el modelo matemático se torna una herramienta de predicción de la vida útil del objeto y su permanencia en el contexto, evidencia también posibles aproximaciones al desarrollo histórico evolutivo que el producto de diseño podría tener. Este mismo modelo tiene el potencial de convertirse en una herramienta que permita mapear las estrategias de cambio que se podrían dar en los objetos a lo largo de su existencia; es decir, desde la reflexión teórica y la rigurosidad matemática proporciona al diseñador de datos útiles para la toma de decisiones estratégicas.

Caso 2. El teléfono a lo largo de la historia. Análisis morfológico y multivariado (2022)

Este estudio tiene como objetivo realizar un mapeo de los cambios morfosemánticos que el teléfono ha tenido a lo largo de su historia. Para ello realiza un análisis morfológico de los objetos y se lo complementa con el análisis de contenidos de las publicidades a ellos asociados, se selecciona como lapso temporal desde el teléfono fijo hasta el teléfono celular 4G.

Los objetos se listan en filas y las variables en columnas. La mayoría de las observaciones se registran con criterios dicotómicos en los que se describe la presencia (1) o ausencia (0) de las características definidas por cada variable, algunas de ellas se registran usando escalas en las que 0 indica presencia baja, 1 presencia media y 2 presencia alta.

El estudio presenta una matriz de noventa y cinco teléfonos (objetos) analizados por medio de 141 variables depuradas, es decir, previamente se excluyen las variables que no arrojan resultados positivos (columnas con sólo 0). Este enfoque se utiliza con el objetivo de identificar grupos de objetos de manera objetiva, basándose en la descripción morfológica para confirmar las clases predefinidas (obtenidas teórica e históricamente). Además, se busca identificar las variables más relevantes en la clasificación, separándolas de aquellas que pueden introducir ruido en los resultados.

Para el análisis de datos, se emplea el software MATLAB, siguiendo una metodología específica que incluye el pretratamiento de los datos mediante escalado por rango, donde todas las variables se estandarizan con un valor máximo de 1 y mínimo de 0.

Las clases conocidas teóricamente se basan en el estudio histórico de teléfonos, clasificándolos como fijos de disco o teclado (1), inalámbricos (2), y celulares de generaciones 1G a 4G (3 a 6). Se utilizan métodos de clasificación como K-NN y CART.

Este estudio, al igual que en el caso anterior, utiliza el método no paramétrico K-NN, con la misma dinámica antes explicada.

Finalmente, los resultados del estudio indican la existencia de 6 grupos de objetos, que coinciden al 100% con la clasificación teórica predefinida. Este

método de clasificación se aplica únicamente al 80% de los objetos de la matriz, como se detalla en las Tablas 2 y 3.

Tabla 2. Clasificación K-NN clases encontradas

CLASES PREDECIDAS	CLASS 1	CLASS 2	CLASS 3	CLASS 4	CLASS 5	CLASS 6
Class 1	15	0	0	0	0	0
Class 2	0	8	0	0	0	0
Class 3	0	0	12	0	0	0
Class 4	0	0	0	10	0	0
Class 5	0	0	0	0	6	0
Class 6	0	0	0	0	0	16

Fuente: Tripaldi-Proaña (2022).

Tabla 3. Clasificación K-NN *train test*, *no error rate* de 1

NER	1					
	CLASS 1	CLASS 2	CLASS 3	CLASS 4	CLASS 5	CLASS 6
Presicion	1	1	1	1	1	1
Sensitivity	1	1	1	1	1	1
Specificity	1	1	1	1	1	1

Fuente: Tripaldi-Proaña (2022).

Finalmente, con el 20% de objetos restantes (o no tratados), se pone a prueba el modelo con la finalidad de corroborar si los resultados ya obtenidos permiten la emergencia de un modelo predictivo, o, en otras palabras, verificar que el modelo pueda usarse para predecir comportamientos futuros en los objetos (Tripaldi-Proaña, 2022). El resultado es un *no error rate* de 1, es decir, al 100% de coincidencia en la predicción externa (Tabla 4).

Tabla 4. Clasificación K-NN matriz de predicción, *no error rate* de 1

PREDICCIÓN EXTERNA	
NER	1

	CLASS 1	CLASS 2	CLASS 3	CLASS 4	CLASS 5	CLASS 6
Presicion	1	1	1	1	1	1
Sensitivity	1	1	1	1	1	1
Specificity	1	1	1	1	1	1

Fuente: Tripaldi-Proaña (2022).

Además, K-NN, aplicado conjuntamente con la selección genética de variables, identifica las determinantes de la clasificación: complejidad significativa y complejidad funcional respectivamente (Tabla 5, pág. siguiente).

Tabla 5. Variables identificadas como relevantes para la clasificación según el método K-NN

NO PAR	1	2
NER cv	0.5	1
FREC	52	45
K	3	1
VARIABLES SELECCIONADAS	COMPLEJIDAD SIGNIFICATIVA	COMPLEJIDAD FUNCIONAL

Fuente: Tripaldi-Proañó (2022).

Es poco común obtener *non error rates* equivalentes a 1 en todas las etapas del proceso. Es por ello que en este estudio se aplica otro método de clasificación con la idea de comprobar el resultado obtenido con K-NN, para ello opta también en este estudio por el método CART explicado en el caso 1. Para el procesamiento se trabaja aplicando CART a los resultados de K-NN, con la idea de no tener que usar un método de algoritmo complejo. El resultado obtenido es un gráfico que incluye los umbrales de clasificación (Figura 4). Nuevamente se corre el modelo con el 80% de los objetos y luego se realiza la validación externa. Posteriormente, se corre el modelo matemático sobre el restante 20% de los objetos, con la finalidad de comprobar el poder predictivo del modelo.




Figura 4
Árbol de clasificación
arrojado por el método CART,
variable 1 = complejidad significativa,
variable 2 = complejidad funcional.
Fuente: Tripaldi-Proañó (2022).

La aplicación de CART se usa para confirmar los resultados obtenidos con K-NN e identificar las variables determinantes de la clasificación. En este caso se reafirman las propuestas en el paso previo y se identifican los 6 grupos de objetos -clases-, confirmándose nuevamente las clases asignadas teóricamente (Tablas 6 y 7, pág. siguiente).

Tabla 6. Matriz de clasificación CART. Con un *no error rate* de 1

TRAIN TEST						
NER_CAR	1					
	CLASS 1	CLASS 2	CLASS 3	CLASS 4	CLASS 5	CLASS 6
Presicion	1	1	1	1	1	1
Sensitivity	1	1	1	1	1	1
Specificity	1	1	1	1	1	1

Fuente: Tripaldi-Proaño (2022).

Durante la validación cruzada, CART arroja un *no error rate* ligeramente inferior a 1.

Tabla 7. Matriz de validación cruzada de clasificación CART. Con un *no error rate* de 0.9277

CROSS VALIDATION						
NER_cv_CAR	0.9277					
	CLASS 1	CLASS 2	CLASS 3	CLASS 4	CLASS 5	CLASS 6
Presicion	1	1	1	1	1	1
Sensitivity	1	1	1	1	1	1
Specificity	1	1	1	1	1	1

Fuente: Tripaldi-Proaño (2022).

Finalmente, en la matriz de comprobación externa, con el 20 % de los datos, CART arroja un *no error rate* de 0.9277 (Tabla 8).

Tabla 8. Matriz de predicción externa CART. Con un *no error rate* de 0.9277

PREDICCIÓN EXTERNA						
NER_pred_CAR	0.9277					
	CLASS 1	CLASS 2	CLASS 3	CLASS 4	CLASS 5	CLASS 6
Presicion	1	1	1	1	1	1
Sensitivity	1	1	1	1	1	1
Specificity	1	1	1	1	1	1

Fuente: elaboración propia.

Los resultados del procesamiento indican que, efectivamente, el modelo K-NN y CART son confiables para este tipo de estudios, al igual que los resultados del caso 1, ya que permiten identificar una clasificación de manera eficiente.

En este caso el resultado es significativo, en el análisis se introduce ruido tanto en el procesamiento matemático de los datos, como en la matriz usada -en esta se incluyeron variables relacionadas con la imagen gráfica de

cada objeto, los valores gráficos a él asociados y los discursos publicitarios-, con la idea de poner a prueba la clasificación, aun así, los resultados son contundentes.

Los resultados de este caso, son importantes para futuros análisis de los criterios morfosemánticos del objeto, ya que permiten establecer -con evidencia matemática- la dupla de variables que determinan la evolución del objeto -complejidad significativa y complejidad funcional-, de allí que estas dos variables se consideran posteriormente en el estudio como las más importantes en el proceso de triangulación de datos a través de las matrices de comparación y los gráficos relacionales que incluye la investigación.

Aquí se evidencia el potencial de la multivariada y la aplicación de algoritmos para estudios prospectivos, el estudio de los datos, en este caso, posteriormente permite la teorización más abstracta de las dimensiones del diseño. Sin embargo, este tipo de resultados aplicados a otros estudios podrían orientar decisiones productivas y de mercadeo, por ejemplo, la decisión de producir tal o cual diseño en función de la tendencia general del mercado en una tipología de productos. También permitiría hacer estudios comparativos con la competencia para comprender la tendencia de su línea de diseño.

Caso 3. Análisis morfosemántico de la gráfica de productos alimenticios ecuatorianos con denominación de origen (2019)

En este caso de estudio, Ana Belén Viñansaca Cabrera (2019), en su tesis de pregrado, busca identificar las estrategias visuales empleadas en los empaques de chocolate y café que tienen un origen geográfico declarado, en el estudio se utilizan métodos de Análisis de Contenidos y procesamiento multivariado de datos con la finalidad de identificar los modos en que la gráfica comunica los valores de las marcas y cómo se insertan en el contexto contemporáneo.

Para ello, recurre a un análisis bastante sencillo fundamentado en el uso del método genético de extracción de variables significativas de Leardi acoplado a K-NN. Los resultados permiten inferir que el modelo formado por tres variables (Objeto signo sustitutivo metábasis, simetría y jerarquización) sea en *fitting* (NER 88%) como en predicción (NER en pred 89%) es válido para predecir casos nuevos y que hay altas probabilidades de que esta tendencia de distinción marcada entre chocolate y café se mantenga en futuros casos de diseño de empaques. La variación de los centroides de las variables en las dos clases se muestra en la Figura 5.




Figura 5

Centroides de las tres variables en las dos clases.

Fuente: Viñansaca Cabrera (2020).

Se puede notar que sólo en el caso de la jerarquización hay coincidencia, mientras que en las otras variables son totalmente opuestas.

Estos resultados le permiten a la investigadora realizar un proceso de inferencia y discusión teórica sobre el diseño de embalajes fundamentada en modelos matemáticos más objetivos. Los resultados le permiten identificar, en el estudio, la tendencia en el diseño de embalajes de chocolate y de café, además le permiten identificar que, aunque ambas categorías de productos tienen elementos en común como sector productivo y de mercado -denominación de origen, certificaciones orgánicas, canales de distribución similares, exhibición en el punto de venta- la gráfica se desarrolla con lógicas diferentes.

Este estudio, a pesar de presentar un caso relativamente simple de aplicación demuestra la claridad de los resultados obtenidos además de que pone en evidencia el proceso de reducción de variables a aquellas que son realmente importantes a considerar en el caso del diseño de un empaque en esa tipología de productos. Esto puede contribuir a optimizar significativamente los procesos decisionales y estratégicos del diseño de empaques en un mercado altamente competitivo.

Caso 4. Proyecto de investigación: Diseño Gráfico y propaganda (2024)

Este estudio de Tripaldi-Proañón et al. (2026) desarrollado en 2024 y publicado en 2026, presenta el análisis de contenidos de propaganda gráfica. Nuevamente la intención es la de encontrar patrones a lo largo de la historia, según el origen y según el acontecimiento en el que se da el proceso comunicativo (guerra, movimiento social, revolución civil, entre otros).

Los datos utilizados para este estudio se ensamblan en una matriz de 125 variables de tipo dicotómico (1 = presencia; 0 = ausencia) y para iniciar el estudio se realiza una depuración de los datos y se confirman las condiciones definitivas para el estudio multivariado con 162 casos descritos por 125 variables.

El estudio se limita a la exploración de similitudes entre los diferentes carteles analizados, para ello se utiliza la técnica *cluster analysis* o análisis de conglomerados (usa la distancia de Rogers-Tanimoto) y aplica un método de clusterización no jerárquico K-Means.

Posteriormente los resultados se aplican como Clases en modelos predictivos de clasificación. Al igual que en los casos previos, en este trabajo se utiliza el algoritmo de clasificación K-NN acoplado a un método genético de selección de las variables realmente importantes. El enfoque utilizado en este trabajo se inspira en el que se muestra en el artículo de Riccardo Leardi y Andrés Lupianez (1998).

Los resultados muestran que, utilizando la distancia de Rogers-Tanimoto con el número de vecinos óptimo de 4 se ha obtenido un modelo con un *no error rate* de 0.74. Posteriormente en la validación cruzada el *no error rate* subió a 0.81.

El modelo resultante identifica tres variables clave: Discurso, Abstracto/Simbólico y Estetización del Poder. Posteriormente se confirma el modelo mediante validación externa con el 30% de las variables y se ha obtenido un *no error rate* en predicción de 0.78. Los demás parámetros de calidad se presentan a continuación en la Tabla 9.

Tabla 9. Parámetros de calidad del modelo K-NN

MODELIZACIÓN			
NER	0.74		
ACC	0.74		
	CLASS 1	CLASS 2	CLASS 3
Precisión	0.61	0.70	1.00
Sensitivity	0.63	0.74	0.74
Specificity	0.77	0.83	1.00
VALIDACIÓN CRUZADA			
NER	0.81		
ACC	0.81		
	CLASS 1	CLASS 2	CLASS 3
Precisión	0.77	0.78	0.90
Sensitivity	0.89	0.76	0.77
Specificity	0.86	0.89	0.96
PREDICCIÓN			
NER	0.78		
ACC	0.78		
	CLASS 1	CLASS 2	CLASS 3
Precisión	0.75	0.70	0.93
Sensitivity	0.60	0.88	0.88
Specificity	0.91	0.81	0.97

Fuente: cortesía del Grupo de Investigación en Teoría, Filosofía y Epistemología del Diseño de la Universidad del Azuay.

En la Figura 6 se presenta el gráfico de los centroides de las tres clases.




Figura 6
Gráfico de los centroides de las tres clases.
Fuente: cortesía del grupo del Grupo de Investigación en Teoría, Filosofía y Epistemología del Diseño de la Universidad del Azuay.

El análisis realizado permitió identificar tres grandes grupos de piezas propagandísticas, diferenciadas por la estrategia de comunicación visual predominante. El primer grupo se caracteriza por el uso del discurso directo, donde la

comunicación interpela explícitamente al espectador mediante llamados a la acción, expresiones exclamativas y el uso frecuente de la primera y segunda persona. Estas piezas buscan implicar al público dentro de una comunidad política concreta, apelando a nociones como patria, guerra, libertad o lucha. Visualmente, se apoyan en imágenes realistas, símbolos reconocibles y colores intensos, acompañados de tipografías sans serif de alto impacto que refuerzan el carácter urgente y movilizador del mensaje.

Un segundo grupo se organiza en torno al uso de escenarios abstractos y simbólicos como estrategia central. En lugar de representar situaciones concretas, estas piezas recurren a símbolos universales y arquetipos culturales capaces de comunicar ideas complejas de forma inmediata y transversal. El uso del lenguaje simbólico permite trascender barreras culturales y cognitivas, apelando incluso a niveles más profundos de interpretación vinculados al imaginario colectivo. A nivel visual, estos afiches suelen presentar composiciones audaces, tipografías directas y una marcada temporalidad en presente, con el fin de enfatizar la urgencia de los problemas representados y promover una reacción inmediata en la audiencia.

Finalmente, el tercer grupo se articula alrededor de la estetización del poder como recurso comunicacional. En estas piezas se establece una relación entre valores estéticos y valores morales, donde la belleza visual se asocia a nociones de legitimidad, heroicidad o justicia. La propaganda recurre con frecuencia a figuras heroicas, símbolos de autoridad o representaciones idealizadas de actores políticos y sociales, construyendo una narrativa visual que busca generar admiración y confianza. Desde el punto de vista formal, este grupo presenta composiciones más complejas, un uso más diverso de tipografías -incluyendo serifas, caligráficas o decorativas- y una fuerte integración entre imagen y texto, configurando mensajes conceptuales que apelan tanto a la emoción como a la reflexión del espectador.

En este caso se concluye el estudio extrayendo de la información cuantitativa obtenida una caracterización clasificatoria teórica de las propagandas analizadas, demostrando cómo los datos pueden pasar de lo cualitativo a lo cuantitativo y de vuelta a la inferencia teórica.

Caso 5. Análisis comparativo entre los procesos de Diseño Gráfico tradicional y generativo para la creación de elementos de comunicación visual (2020)

Este estudio es una tesis de pregrado de David León Guerrero realizada en la Universidad del Azuay en 2020; en ella la intención versa en descubrir diferencias entre los productos de diseño gráfico generados a través del proceso de diseño tradicional (analógico), definido así por Umberto Roncoroni Osio (2016) y el diseño generativo, puntualmente en marcas (León Guerrero, 2020).

Se usaron fichas de análisis para describir el proceso empleado por los distintos estudios de diseño, así como las variables morfológicas. La estadística multivariada, en este caso, se usó con la finalidad de establecer a detalle las variables que en forma más directa diferencian al Diseño Gráfico tradicional del diseño generativo.

En total se incluyen en el estudio 20 marcas, de las cuales 10 fueron creadas con diseño tradicional y 10 con diseño generativo. Todas ellas con procesos de diseño bien documentados.

Las variables analizadas en este caso son diversas, e incluyen tanto factores de procedimiento de creación como características formales finales de las

marcas diseñadas. Para el análisis morfológico se revisaron los elementos básicos y técnicas de composición sustentadas en la teoría de Dondis (2017), tomando en consideración, aquellos que aparecen con mayor frecuencia. También se usaron otras variables como tipo de marca, tipografías usadas, paletas cromáticas, entre otras.

En total se analizaron 27 variables procedimentales y 68 variables morfológicas que, para el procesamiento multivariado, se trataron con criterios dicotómicos con 0 y 1 para indicar presencia o ausencia.

En este estudio, se utilizó el software MINITAB 18 para realizar un análisis de conglomerados empleando el método de K-Means (Jain y Dubes, 1988) presentado en el caso anterior. Este análisis se realizó con el fin de determinar las características de cada variable (centroide) dentro de los grupos tradicional y generativo. El análisis se realiza por separado en el caso de las variables procedimentales y las variables morfológicas.

El centroide de cada grupo permite examinar el comportamiento de cada variable y proporciona resultados sobre las variables más representativas en cada grupo. El método de K-Means es no jerárquico y consiste en agrupar observaciones en conglomerados que comparten características similares, procurando alcanzar la máxima homogeneidad dentro de cada grupo y la mayor diferencia entre los grupos.

Se comparan los centroides de cada variable entre ambos grupos para identificar diferencias significativas. Esto se realiza evaluando si la diferencia supera un umbral predefinido, que corresponde al porcentaje de influencia que cada variable tiene sobre el grupo.

Se usa además una función condicionante para identificar qué valor es mayor o menor a otro. Utilizando ese criterio se realizan cálculos con diferentes porcentajes de influencia y en función de estos porcentajes, se definen las variables más importantes con relación a cuánto difieren entre el diseño tradicional y el diseño generativo. Se presentan en las Tablas 10 y 11 los resultados de los dos procedimientos realizados por David León Guerrero (2020).

Tabla 10. Resumen del procesamiento de las variables procedurales

TODOS LOS DATOS CORRESPONDEN AL GRUPO DEFINIDO				
1	1-0.75	0.75-0.25	0.25-0	0
siempre	mucho	medio	poco	nunca

	TRADICIONAL	GENERATIVO	IMPORTANCIA
Vectorización	siempre	poco	Variables importantes
Programación	nunca	siempre	
Disposición de elementos según base de datos	nunca	mucho	
Software	nunca	siempre	

	TRADICIONAL	GENERATIVO	IMPORTANCIA
Bocetaje	medio	poco	Variables mediamente importantes
Selección de idea final	medio	nunca	
Disposición de elementos aleatorios	nunca	medio	
Investigación de referentes conceptuales	mucho	medio	
Señalética	poco	medio	
Logística	medio	nunca	
Revisión de homólogos	nunca	poco	
Creación del concepto	siempre	mucho	
Mantener antiguo concepto	nunca	poco	
Idea creativa	mucho	siempre	
Selección de tipografía	mucho	medio	
Selección de paleta cromática	medio	medio	
Ajustes	medio	poco	
Diseño interior	poco	poco	
Publicidad	medio	medio	Variables no importantes
Papelería	medio	mucho	
Diseño	mucho	mucho	
Rediseño	poco	poco	
Recepción del brief	siempre	siempre	
Revisión de la marca previa	poco	poco	
Sistema gráfico	mucho	mucho	
Souvenirs	medio	medio	
Página web	medio	medio	

Fuente: León Guerrero (2020).

Tabla 11. Resumen del procesamiento de las variables morfológicas

LAS VARIABLES QUE DIFERENCIAN LOS DOS GRUPOS SON						
1	1-0.9	0.9-0.75	0.75-0.25	0.25-0.1	0.1-0	0
siempre	muchísimo	mucho	medio	poco	muy poco	nunca

	TRADICIONAL	GENERATIVO	IMPORTANCIA
Policromía	muy poco	mucho	Variables más importantes
Complementarios	nunca	mucho	
Tríada	nunca	mucho	
Movimiento	poco	siempre	
Colores fríos	poco	siempre	
Actividad	poco	siempre	
Pasividad	mucho	nunca	

	TRADICIONAL	GENERATIVO	IMPORTANCIA
Tono	nunca	medio	Variables importantes
Monocromía	medio	nunca	
Colores cálidos	poco	mucho	
Análogos	poco	mucho	
Equilibrio	siempre	medio	
Tensión	nunca	medio	
Negativo	muchísimo	poco	
Inestabilidad	nunca	medio	
Plano	siempre	medio	
Profundo	nunca	medio	
Serif	poco	nunca	Variables presentes de mediana importancia
Sans serif	medio	siempre	
Regular	muchísimo	medio	
Fina	muy poco	medio	
Bold	nunca	poco	
Fina	medio	poco	
Recta	medio	medio	
Polígonos mayores a 4 lados	nunca	poco	
Textura	medio	mucho	
Escala	nunca	medio	
Dimensión	nunca	medio	
Simetría	medio	nunca	
Asimetría	medio	siempre	
Simplicidad	medio	poco	
Complejidad	medio	mucho	
Aleatoriedad	poco	medio	
Imagotipo	mucho	mucho	
Punto	muy poco	poco	
Ondulada	medio	poco	
Cuadrado	poco	nunca	
Dicromía	medio	poco	
Colores Neutros	mucho	medio	
Secuencialidad	poco	poco	
Unidad	medio	mucho	
Fragmentación	poco	poco	
Agudeza	siempre	mucho	
Difusión	nunca	poco	

	TRADICIONAL	GENERATIVO	IMPORTANCIA
Logotipo	muy poco	nunca	Variables presentes siempre poco o sin importancia
Isotipo	muy poco	poco	
Isologotipo	muy poco	nunca	
Gráfica	muy poco	nunca	
Gruesa	medio	poco	
Circular	medio	medio	
Triangular	muy poco	poco	
Horizontal	medio	poco	
Vertical	poco	poco	
Positivo	muchísimo	siempre	
Verticalidad	poco	poco	
Script	nunca	nunca	
Cursiva	nunca	nunca	
Diagonal	nunca	nunca	
Curva	nunca	nunca	
Nivelación	siempre	siempre	
Aguzamiento	nunca	nunca	
Atracción/Agrupamiento	siempre	siempre	
Opacidad	siempre	siempre	
Transparencia	nunca	nunca	
Horizontalidad	poco	poco	
Exageración	nunca	nunca	
Reticencia	nunca	nunca	

Fuente: León Guerrero (2020).

En este caso de estudio, se evidencia que el uso de la estadística multivariada permite sintetizar patrones clave que se ven compartidos en las etapas de desarrollo de las marcas y, por tanto, describir de una manera más focalizada los procesos seguidos dentro de la operatoria de diseño de Abraham Moles y Roland Caude (1977).

Interpretando la tabla de análisis multivariado se logra identificar las variables procedimentales más importantes en cada tipo de proceso y, a la vez, contrastar la dinámica de las variables conjuntas en ambos tipos de diseño. Esto permite a los investigadores obtener conclusiones también respecto a la optimización del proceso de diseño generativo.

Por otro lado, el análisis morfológico asistido por estadística multivariada permite caracterizar y diferenciar los elementos constitutivos de la marca en cada uno de los procesos de diseño. Es decir, identificar las formas o lenguajes propios de las marcas generadas de tal o cual manera. El estudio arroja que la cromática, la composición y el uso tipográfico serán variables de diferenciación clave entre el proceso de diseño tradicional y el generativo.

Como se evidencia en el estudio, el uso de la estadística multivariada, en este caso, permite identificar patrones diferenciadores entre técnicas/tecnologías diferentes de diseño y además identificar fases y factores procedimentales que pueden optimizarse o deben revisarse en función del tipo de proceso y los resultados esperados. En este sentido, la aportación de la estadística multivariada va más allá del análisis morfológico para, desde los mismos procesos, aportar información sobre maneras de hacer diseño. Permite profundizar en la comprensión de los procesos, fases, ordenamientos de la operatoria del diseño en sí.

Caso 6. Explorando las relaciones entre los objetos y el espacio en el diseño de autor: Análisis Morfológico de la obra de Wilmer Chaca (2018)

Este caso responde a otra tipología de investigación, más ligada a la identificación de un estilo de diseño. Busca reflexionar en las relaciones que se establecen alrededor del objeto, y entre el objeto y el espacio en el caso de la obra de un diseñador específico, para desde allí caracterizar la naturaleza formal de sus diseños.

Las unidades de análisis seleccionadas para este estudio son 40 proyectos realizados por Wilmer Chaca, la gran mayoría de ellos son objetos destinados al descanso y la alimentación y pertenecen a una línea de diseño de autor. Igual que en el caso 1, fueron muestreados con métodos no probabilísticos.

En este estudio se toman como base los principios rectores del análisis morfológico propuestos por Jorge Pokropek (2020) y dentro de este marco se establece una cantidad de variables morfológicas y semánticas de carácter polar, es así como en el registro de datos se aplica un criterio de análisis de orden dicotómico, se registra la presencia o ausencia de variables donde la presencia de uno de los pares polares implica necesariamente la ausencia del otro. El análisis propone la observación rigurosa y cualitativa de 40 objetos seleccionados descritos con 79 variables.

En la matriz de datos se usó el sistema de registro con 0 y 1, el mismo que además es sumamente flexible para el caso del procesamiento de datos. Si bien las respuestas dicotómicas no ofrecen mayor información, para este estudio fue suficiente debido a que al ser un estudio con un fuerte componente de análisis cualitativo, únicamente se requería ordenar la información para facilitar el proceso de inferencia (Tripaldi-Proañó, Tripaldi-Proañó y Vanegas Peña, 2020).

En el procesamiento de datos se intenta agrupar las variables en grupos homogéneos utilizando como métrica el coeficiente de correlación entre las variables y método de clusterización Ward, un método diferente a los antes expuestos, sin embargo, sigue siendo un proceso de clusterización.

El resultado es un dendrograma que evidencia la presencia de cuatro *clusters* de variables (Figura 7, pág. siguiente).

En este caso, se identifican cuatro grupos de objetos en función del comportamiento de las variables morfológicas incluidas en el estudio. El grupo 1, se caracteriza por el uso de una estructura focal, una direccionalidad múltiple, predominio de la virtualidad, aleatoriedad, sistemas multidireccionales, interacciones y complejidad estructural, materiales de origen mixto.




Figura 7

Dendrograma que evidencia la presencia de cuatro *clusters*.

Fuente: cortesía de Tripaldi-Proañó, Tripaldi-Proañó y Vanegas Peña (2020).

Pero pese a esta complejidad y a ser sistemas abiertos, no pierden su característica unívoca, en el ámbito simbólico/funcional [...] Además los objetos que lo componen tienen características singulares, evidenciándose su protagonismo expresivo con relación a su contexto objetual y espacial (Tripaldi-Proañó, Tripaldi-Proañó y Vanegas Peña, 2020, p. 112).

En el caso del grupo 2 las variables clave son el uso de planos, volúmenes, color y espacio, prevalencia de super signos y en la materialidad los acabados con brillo, composiciones regulares, cargadas de agudeza en las que prevalece la interacción entre las partes. Por otro lado, el grupo 3 caracterizado por la textura, estructuras independientes, complejidad estructural, composiciones fragmentadas, audaces y variables, con cambios abruptos en la forma, la materialidad y la direccionalidad “que se constituye como una característica esencial en este grupo de objetos, de sistemas abiertos. En el ámbito semiótico prevalecen los objetos-signos sustitutivos, en un nivel de metonimia, y en las articulaciones predominan las de contacto y penetración” (Tripaldi-Proañó, Tripaldi-Proañó y Vanegas Peña, 2020, p. 113).

Finalmente, el grupo 4 caracterizado por el uso de estructuras focales e independientes, uso de la línea, el plano y el ritmo, las composiciones buscan la simetría, materiales de origen mixto, la articulación de contacto. En el ámbito de la semiótica son signos unívocos y unisignos. Estos diseños presentan más posibilidades de establecer relaciones con otros objetos y espacios permitiendo relaciones con otros objetos del mismo grupo.

El uso de este tipo de *Machine Learning* en este caso es bastante sencillo, sin embargo, muy eficiente para cumplir con los objetivos planteados. El análisis multivariado define cuatro grupos y los criterios que los caracterizan. La identificación de las variables más relevantes permite además una descripción detallada de la morfología de los objetos que componen cada uno de los grupos, llegando así a una descripción minuciosa de la obra del diseñador. Este caso evidencia cómo este tipo de aplicaciones podrían usarse no sólo para caracterizar obras actuales, sino identificar patrones en conjuntos de objetos a lo largo de la historia, identificar sus rasgos formales y estilísticos. Este tipo de uso podría ser relevante inclusive para la investigación antropológica, arqueológica y del arte. Esta posibilidad evidencia, además, el potencial del diseño como disciplina articuladora de procesos en otros saberes.

Conclusiones

A partir del análisis de los casos, puede afirmarse que la estadística multivariada y el *Machine Learning*, utilizados como herramientas auxiliares en el análisis morfosemántico, permiten profundizar los procesos de análisis, modelización y predicción en estudios de diseño –ya sea industrial, gráfico u otras especialidades–, al tiempo que contribuyen a una mayor objetivación de los resultados.

Asimismo, estos enfoques favorecen un diálogo disciplinar que amplía el alcance de los datos cualitativos. En la mayoría de los casos revisados, la construcción de matrices a partir de variables definidas cualitativamente y su posterior procesamiento cuantitativo posibilitan la triangulación de datos, enriqueciendo la inferencia al diversificar los tipos de información considerados. Esto habilita abordajes más complejos, sistemáticos y productivos en el estudio de la forma.

En relación con los métodos empleados, se observa una recurrencia en el uso de algoritmos como K-NN, CART y K-Means, así como estrategias de optimización basadas en algoritmos genéticos. Estos recursos permiten desarrollar modelos predictivos y simulaciones orientadas a identificar tendencias en la evolución formal de los productos. No obstante, su aplicación se realiza en marcos controlados, lo que garantiza la coherencia y la interpretabilidad de los resultados. Al mismo tiempo, la amplitud de técnicas disponibles en el campo sugiere la existencia de un amplio margen para futuras exploraciones. Por otra parte, los casos analizados evidencian que la calidad de los resultados depende en gran medida de una sólida fundamentación teórica previa, que oriente la definición de variables, criterios de medición y objetivos del análisis. En este sentido, no es posible establecer un modelo estándar de aplicación de estos métodos en diseño, sino más bien reconocer la necesidad de adaptar herramientas provenientes de otros campos a problemáticas específicas, en un marco de trabajo interdisciplinar o transdisciplinar.

El potencial de estos enfoques se vuelve particularmente significativo en contextos aplicados, como la articulación entre diseño y mercado. La construcción de bases de datos sobre configuraciones formales permitiría monitorear la evolución de tendencias a lo largo del tiempo y anticipar escenarios, aportando insumos relevantes para la toma de decisiones estratégicas.

Desde una perspectiva más amplia, este tipo de aproximaciones contribuye también al desarrollo de las humanidades digitales, en tanto promueve el uso de herramientas computacionales para el análisis de grandes volúmenes de datos, la generación de nuevas metodologías y la integración de múltiples fuentes y enfoques. En línea con lo señalado por Isabel Galina Russell (2011), el uso de *Machine Learning* en el análisis morfológico posibilita la construcción, estructuración y análisis de bases de datos complejas, ampliando las formas de producción de conocimiento en el campo.

En síntesis, la estadística multivariada y el *Machine Learning* se consolidan como herramientas relevantes no sólo para la investigación sobre el diseño, sino también para la investigación en diseño y para el diseño, en tanto aportan recursos para el análisis, la toma de decisiones y el desarrollo de procesos proyectuales más informados y estratégicos ■

REFERENCIAS

- Amundarain, Aitor Lekuona; Domínguez Somonte, Manuel y Espinosa Escudero, María del Mar (2021, julio). El diseño paramétrico como herramienta creativa en diseño de producto. *Técnica Industrial*, (329), 32-40.
- Bai, Ruyi; Guo, Xiaoying y Jia, Chunhua (2019). What is the correct hanging orientation for abstract painting?: Orientation judgment and detection. *Proceedings of the 3rd International Conference on Computer Science and Application Engineering*, 1-9. <https://dl.acm.org/doi/10.1145/3331453.3361299>
- Barreiro Chusan, José André (2021). *Análisis morfológico de insectos del ecuador, para la generación de nuevos elementos gráficos*. [Tesis de Grado]. Universidad del Azuay.
- Baudrillard, Jean (2010). *Crítica a la economía política del signo*. Siglo XXI.
- Biedermann, Anna María; Fernández-Vázquez, Aranzazu y María Elipe Maldonado (2017). Aplicación del análisis morfológico de productos existentes para el diseño de packaging: estudio de caso [pp. 26-31]. En Actas del Congreso Internacional INGEGRAF, *Nuevos modelos de investigación y colaboración en Ingeniería Gráfica*. Universidad de Oviedo.
- Bonini, Tiziano y Treré, Emiliano (2024). *Algorithms of resistance: The everyday fight against platform power*. Mit Press.
- Breiman, Leo; Friedman, Jerome; Stone, Charles J. y Olshen, Richard (1984). *Classification and Regression Tree*. Taylor & Francis.
- Brown, Nathan C. y Mueller, Caitlin (2018). Quantifying diversity in parametric design: A comparison of possible metrics. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 33, 40-53. <https://doi.org/10.1017/S0890060418000033>
- Čok, Venja; Vlah, Daria y Povh, Janez (2021). Methodology for mapping form design elements with user preferences using Kansei engineering and VDI. *Journal of Engineering Design*, 32(3), 144-170. <https://doi.org/10.1080/09544828.2021.2012133>
- Čok, Venja; Vlah, Daria y Žavbi, Roman (2020). An investigation into 2D and 3D shapes perception. *Tehnički Vjesnik*, 27(1), 37-45. <https://doi.org/10.17559/tv-20190627180712>
- Bredanini Colombo, María Georgina; Acevedo Vacherand, Natalia Victoria y Bustamante, María Soledad (2025). Inteligencia artificial para la generación de nuevos modelos formales. *Modelos Educativos Innovadores en Educación Superior*. <https://doi.org/10.33132/27449394.2490>
- Dondis, Donis A. (2017). *La sintaxis de la imagen. Introducción al alfabeto visual*. Editorial GG.
- España Muñoz, Santiago (2023). *Análisis morfológico de una muestra de carteles del Pastojazz 2012-2019*. [Trabajo Final de Grado]. Universidad de Nariño.
- Fontana-Cabezas, Juan José; Pereyra-Bonifacio, Paulo; Piñeyro-Rodríguez, Marina y Chocca-Bosio, Claudia (2024). Diseño paramétrico y fabricación digital de estructuras plegadas con formas complejas en Uruguay. *Legado de Arquitectura y Diseño*, 19(36), 123-132.
- Galina Russell, Isabel (2011). ¿Qué son las humanidades digitales? *Revista Digital Universitaria*, 12(7), 3-8. <https://biblat.unam.mx/hevila/Revistadigitaluniversitaria/2011/vol12/no7/5.pdf>
- Jain, Anil K. y Dubes, Richard C. (1988). *Algorithms for clustering data*. Prentice-Hall, Inc.
- Johnson, Glenn W. y Ehrlich, Robert (2002). State of the Art Report on Multivariate Chemometric Methods in Environmental Forensics. *Environmental forensics*, 3(1), 59-79. <https://doi.org/10.1006/enfo.2002.0080>
- Leardi, Riccardo (2001). Genetic algorithms in chemometrics and chemistry: a review. *Journal of Chemometrics: A Journal of the Chemometrics Society*, 15(7), 559-569.
- Leardi, Riccardo y Lupianez, Andrés (1998). Genetic algorithms applied to feature selection in PLS regression: how and when to use them. *Chemometrics and intelligent laboratory systems*, 41(2), 195-207.
- León Guerrero, David F. (2020). *Análisis comparativo entre los procesos de diseño gráfico tradicional y generativo para la creación de elementos de comunicación visual*. [Tesis de licenciatura inédita]. Universidad del Azuay.

- Li, Yongfeng y Zhu, Liping (2020). Extracting knowledge for product form design by using multiobjective optimisation and rough sets. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, 14(1). <https://doi.org/10.1299/jamdsm.2020jamdsm0009>
- Liu, Jianli; Lughofer, Edwin y Zeng, Xianyi (2015). Aesthetic perception of visual textures: A holistic exploration using texture analysis, psychological experiment, and perception modeling. *Frontiers in Computational Neuroscience*, 9. <https://doi.org/10.3389/fncom.2015.00134>
- Matsumoto, Taishi; Sato, Koichiro; Matsuoka, Yoshiyuki y Kato, Takeo (2019). Quantification of "complexity" in curved surface shape using total absolute curvature. *Computers y Graphics*, 78, 108-115. <https://doi.org/10.1016/j.cag.2018.10.009>
- Moga, Maria (2025). Visual Complexity and Aesthetic Value in Design: Between Hedonomics, Emotional Experience, and Ergonomic Aesthetics. *AHFE International*, 198. <https://doi.org/10.54941/ahfe1006777>
- Moles, Abraham y Caude, Roland (1977). *Creatividad y métodos de innovación*. Ibérico europea de ediciones.
- Paredes, Esteban Cecil (2024). Posmodernidad, apropiación y pastiche en la cartelística cinematográfica de James Verdesoto: un análisis crítico de su obra en el período comprendido entre 1990 y 2020 en el contexto del diseño gráfico y la cultura visual contemporánea. *Cuadernos del Centro de Estudios en Diseño y Comunicación*, (245), 182-189.
- Paredes Díaz, Kevin Joel (2023). *Texturas gráficas en base al análisis morfológico de las máscaras de la diablada pillareña y su incidencia en la industria textil*. UTC.
- Pokropek, Jorge (2020). Lógicas de coherencia para la interpretación y producción del diseño interior y sus criterios de selección de formas objetuales. *Cuadernos del Centro de Estudios en Diseño y Comunicación. Ensayos*, (81), 19-29.
- Rodríguez de Ita, Diego (2026). *Diseño paramétrico y biomimético, como modelo de arquitectura evolutiva*. [Tesis Doctoral]. Universidad Autónoma de Nuevo León.
- Rodríguez de Ita, Diego y Luna Rodríguez, Sofía Alejandra (2024). Diseño generativo en diseño computacional: obtener patrones morfológicos inéditos. *Diseño, Arte y Arquitectura*, (16), 95-109.
- Roncoroni Osio, Umberto (2016). *Manual de diseño generativo*. Universidad de Lima.
- Sánchez Valencia, Mauricio (2009). *La forma como hecho social de convivencia. Morfogénesis del Objeto de Uso*. Universidad de Bogotá Jorge Tadeo Lozano. <https://www.utadeo.edu.co>
- Song, Wengang; Xie, Xinse; Huang, Wenyue y Yu, Qianqian (2023). The design of automotive interior for Chinese young consumers based on Kansei engineering and eye-tracking technology. *Applied Sciences*, 13(19), 10674. <https://doi.org/10.3390/app131910674>
- Tabuenca Bengoa, María; González-Díez, Laura y Martínez Puebla, Belén (2020). Propuesta metodológica para el análisis gráfico, tipográfico y cromático de cartelería. *Pensar la Publicidad. Revista Internacional de Investigaciones Publicitarias*, 14(2), 269-280. <https://doi.org/10.5209/pepu.72134>
- Todeschini, Roberto (1998). *Introduzione alla chemiometria*. Edises.
- Tripaldi-Proano, Anna (2022). *El objeto diseñado, a la luz de la teoría de la práctica social. Caso el teléfono, desde el teléfono fijo de disco hasta el celular 4G en Ecuador*. [Tesis de Doctorado en Diseño]. Universidad de Palermo.
- Tripaldi-Proano Anna, Tripaldi-Proano, Toa; Jadán-Heredia, D., Carrión-Martínez, P., Tripaldi-Cappelletti, Piercosimo y Vanegas-Peña, Santiago (2024). *Informe final del proyecto de investigación: Diseño y propaganda* (Reporte de investigación). Vicerrectorado de Investigaciones Universidad del Azuay.
- Tripaldi-Proano, Anna; Tripaldi-Proano, Toa; Jadán-Heredia, Diego; Vanegas-Peña, Santiago; Carrión-Martínez, Paúl; Tripaldi-Cappelletti, Piercosimo (2026). *Imágenes que hablan: El diseño en la propaganda del siglo XX*. Casa Editora Universidad del Azuay.
- Tripaldi-Proano, Anna; Tripaldi-Proano, Toa; Tripaldi-Cappelletti, Piercosimo y Arevalo-Pena, Daniel (2017). Estrategias evolutivas del objeto-diseño. *Arte, Individuo y Sociedad*, 29(3), 619-635.

- Tripaldi-Proañ, Anna; Tripaldi-Proañ, Toa y Vanegas-Peña, Santiago (2020). Explorando las relaciones entre los objetos y el espacio en el diseño de autor: Análisis Morfológico de la obra de Wilmer Chaca. *Cuadernos del Centro de Estudios en Diseño y Comunicación. Ensayos*, (86), 102-115.
- Trivedi, Naresh Kumar; Tiwari, Raj Gaurang; Gautam, Vinay y Singh, Anshbir (2023). Deep learning architect: Classification for architectural design using artificial intelligence. 2023 *International Conference on Sustaining Heritage: Innovative and Digital Approaches (ICSH)*, 45-50. <https://doi.org/10.1109/ICSH57060.2023.10482827>
- Viñansaca Cabrera, Ana Belén (2019). *Análisis morfosemántico de la gráfica de productos alimenticios ecuatorianos con denominación de origen*. [Tesis de licenciatura inédita]. Universidad del Azuay.
- Ward, Joe H. (1963). Hierarchical grouping to optimize an objective function. *Journal of the American statistical association*, 58(301), 236-244. <https://doi.org/10.2307/2282967>
- Wang, Huaxiaoyue; Choudhary, Sunav; Derroncourt, Franck; Shen, Yu y Petrangeli, Stefano (2026). PRISM: Learning design knowledge from data for stylistic design improvement. *ArXiv*. <https://doi.org/10.48550/arXiv.2601.11747>
- Yoshimura, Yuji; Cai, Bill; Wang, Zhoutong y Ratti, Carlo (2018). Deep learning architect: Classification for architectural design through the eye of artificial intelligence [pp. 249-265]. En Stan Geertman, Qingming Zhan, Andrew Allan y Christopher Pettit (eds.), *Computational Urban Planning and Management for Smart Cities*. Springer Nature. https://doi.org/10.1007/978-3-030-19424-6_14
- Zhao, Nanxuan; Cao, Ying y Lau, Rynson W. H. (2018). What characterizes personalities of graphic designs? *ACM Transactions on Graphics (TOG)*, 37, 1-15. <https://doi.org/10.1145/3197517.3201355>