

**APLICACIÓN DE LA LINGÜÍSTICA FORENSE A LOS ESTUDIOS
DE ATRIBUCIÓN DE AUTORÍA LITERARIA. PRINCIPIOS TEÓRICOS,
METODOLÓGICOS Y CONCLUSIVOS¹**

**APPLICATION OF FORENSIC LINGUISTICS TO LITERARY AUTHORSHIP
ATTRIBUTION STUDIES: THEORETICAL, METHODOLOGICAL
AND CONCLUSIVE PRINCIPLES**

Cristina RUIZ URBÓN

Universidad de Valladolid / Universidad de Salamanca
cristina.ruiz.urbon@uva.es

Resumen: En este trabajo se plantea la aplicación de los fundamentos de la lingüística forense a los estudios de autoría literaria, con el objetivo de dotarlos de mayor objetividad, fiabilidad y precisión. Estos fundamentos están relacionados con tres principios rectores esenciales: (i) uno teórico, fundado en el concepto de *idiolecto* como variante individual y distintiva de cada persona; (ii) otro metodológico, basado en la comparación forense de textos, que recomienda la combinación de técnicas cualitativas y cuantitativas y el estudio de variables que afecten a distintos niveles de la lengua; y (iii) otro conclusivo, que se sustenta en el principio de probabilidad y que recomienda la expresión de las conclusiones en escalas de opinión verbal.

Palabras clave: Atribución de autoría. Lingüística forense. Idiolecto. Comparación de textos. Escalas de opinión verbal.

Abstract: This paper proposes applying the fundamental principles of forensic linguistics to literary authorship studies in order to make them more objective, more reliable and more precise. These fundamental principles are related to three essential guiding principles: (i) a theoretical one, based on the concept of idiolect as an individual and distinctive variant of each person; (ii) a methodological one, based on the forensic comparison of texts, which recommends combining qualitative and quantitative techniques and the study of variables that might affect different levels of language; and (iii) a conclusive one, based on the principle of probability, which recommends the expression of the conclusions in verbal opinion scales.

Keywords: Authorship attribution. Forensic linguistics. Idiolect. Comparison of texts. Verbal opinion scales.

¹ Investigadora posdoctoral Margarita Salas, gracias a una ayuda financiada por el Ministerio de Universidades a través de la Unión Europea (NextGenerationEU).

1. INTRODUCCIÓN

En los últimos años, con el auge de las humanidades digitales y las tecnologías del lenguaje, los estudios filológicos tradicionales se han visto complementados —nunca sustituidos— por una serie de estudios de carácter innovador que, basándose en el análisis masivo de datos a través de la estilometría, abordan cuestiones tan complejas como la autoría de un texto o su datación. Gracias a estas nuevas metodologías hemos podido descubrir, por ejemplo, quién es el autor de la comedia aurisecular *Siempre ayuda a la verdad* (García Reidy, 2019), qué partes de las obras de Carmen Mola han sido escritas por cada uno de los tres autores que se ocultan tras ese pseudónimo (Blasco, 2022) o en qué fecha aproximada se escribieron las distintas comedias de Lope de Vega (Cuéllar, 2023). Trabajos que han supuesto un gran avance en el ámbito literario, no solo por los resultados obtenidos, sino también por el prestigio que han aportado a los estudios de corte cuantitativo, tan denostados por la crítica más tradicional.

Cabe advertir, no obstante, del peligro que pueden suponer todos estos estudios si no son abordados con cierta prudencia y rigor. Así, por ejemplo, encontramos trabajos que elevan a verdad absoluta los resultados obtenidos de aplicar la distancia delta a un conjunto determinado de textos, cuando sabemos que el éxito de esta medida reside, precisamente, en las obras que el investigador selecciona para la comparación (*nearest neighbourhood problem*); o que no tienen en cuenta la calidad de los textos que conforman el corpus de trabajo (y que está relacionada, principalmente, con su trazabilidad). También advertimos cierta subjetividad a la hora de expresar las conclusiones alcanzadas, pues con frecuencia leemos que Fulanito *puede ser el autor* o que Menganito *muy probablemente* no lo sea, pero esa expresión semántica no aparece respaldada por una escala de opinión que permita cuantificar el nivel real de la misma. Cuestiones, todas ellas, que sí contempla la lingüística forense, que dispone de un protocolo de actuación objetivo y riguroso, avalado por lingüistas de reconocido prestigio, empleado en el seno de las investigaciones policiales y admitido como prueba pericial en los tribunales de todo el mundo, pero que nunca ha sido acogido por los especialistas del campo literario en el ámbito hispánico. Y ese es, precisamente, el objetivo de este trabajo.

2. LA LINGÜÍSTICA FORENSE COMO DISCIPLINA CIENTÍFICA

La lingüística forense, como rama de la lingüística aplicada, puede definirse de manera global como una ciencia multifacética e interdisciplinar que pone en conexión los campos de la lingüística y el derecho con el fin de dar respuesta a las cuestiones legales que, de un modo u otro, implican la lengua (Imagen 1). Aunque gran desconocida en nuestro país y de muy reciente aplicación, lo cierto es que la lingüística forense posee un

amplio bagaje en el mundo anglosajón, en donde su practicidad y fiabilidad están fuera de toda duda.

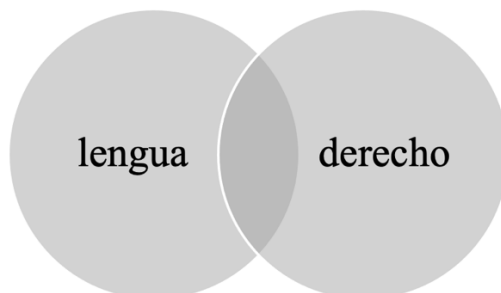


Imagen 1: Definición de lingüística forense. Fuente: Elaboración propia.

Los orígenes de esta disciplina se sitúan a mediados del siglo pasado, cuando empieza a utilizarse por primera vez el término *forense* en relación con el lenguaje, aunque no siempre con un mismo sentido. En el año 1949, el filólogo americano Frederick A. Philbrick escribe una obra sobre inglés legal titulada *Language and the Law: the Semantics of Forensic English*, en la que analiza el uso del lenguaje jurídico y judicial en el habla inglesa. Philbrick emplea el término *forensic English* para referirse al lenguaje especializado que utilizan los actores del proceso penal: “a study of forensic English, that is, the English used by advocates and judges in courts of the law” (1949: vi). Casi dos décadas después, en 1968, el lingüista sueco Jan Svartvik publica *The Evans statements. A case for forensic linguistics*, en donde el término *forensic linguistics* adquiere el sentido de prueba o evidencia. En esta obra, Svartvik demuestra con argumentos estrictamente lingüísticos la inocencia del joven galés Timothy John Evans, que había sido injustamente condenado a pena de muerte y ejecutado en la horca en 1950 por los asesinatos de su mujer y su hija (asesinatos que había cometido, en realidad, su vecino John Christie). Gracias al análisis de las declaraciones policiales, Svartvik pudo demostrar que las partes en las que Evans se autoinculpaba de los hechos (dubitadas) presentaban un estilo gramatical muy diferente del resto (indubitadas), lo que permitía inferir que esas partes habían sido manipuladas por la persona encargada de transcribir el interrogatorio. Aunque para Evans fue tarde, esta nueva incursión en el campo de la lingüística forense

has been interesting for a number of reasons, but two in particular: Firstly, it has provided the linguist with one of those rare opportunities of making a contribution that might be directly useful to society. Such a statement does not imply the utility should be a goal of linguistic research, only that, once in a while, it is good for the linguist to know that he can be useful, and that applied linguistics need not be identical with language teaching or machine translation. Secondly, it has highlighted our present inadequate knowledge of how language is used in various situations (Svartvik, 1968: 6).

Desde entonces hasta ahora, la definición de lingüística forense y sus campos de actuación han sido objeto de múltiples debates y estudios teóricos, ya que, como bien

advierde Leonard, el maridaje entre lengua y derecho puede dar respuesta a muchas y muy variadas incógnitas:

Forensic linguistics responds to legal questions that involve language. Who wrote a ransom note or a bomb threat letter? What is the meaning of a word in a contract? Just what constitutive “consenting” to a search? If an interrogator indirectly makes a promise, does that invalidate a confession? Is “Mc” part of the McDonalds trade name or just part of English (and can I name my restaurant McHamburgers)? Could a fourth-grade dropout actually have written a confession with the phrase, “he approached the vehicle and I raised my weapon?” (Leonard, 2006: 3).

Tratando de sistematizar todas estas posibilidades, Gibbons y Turell establecieron los tres campos de actuación que engloba la lingüística forense en su más amplio sentido del término (2008). En primer lugar, *the language of the law*, que examina el lenguaje que se emplea en la legislación, el ordenamiento jurídico y la administración desde muy diversas ópticas, haciendo especial hincapié en la legibilidad y comprensibilidad de cualquier documento relacionado con el derecho, tanto público como privado (leyes, decretos, normas, reglamentos, subvenciones, contratos, testamentos, etc.). En segundo lugar, *the language of the court*, que se centra en el análisis del lenguaje utilizado por los diferentes agentes que intervienen en el procedimiento judicial, lo que engloba tanto el utilizado en la investigación (interrogatorios, entrevistas policiales, etc.) como en los juzgados o tribunales (intervenciones de jueces, abogados, acusados, peritos, testigos, etc.). Y, en tercer lugar, *the language as evidence*, que usa el lenguaje como evidencia para elaborar perfiles lingüísticos, identificar a una persona por su voz o sus producciones escritas, determinar casos de plagio o detectar mecanismos lingüísticos propios de la mentira o el engaño, entre otros.

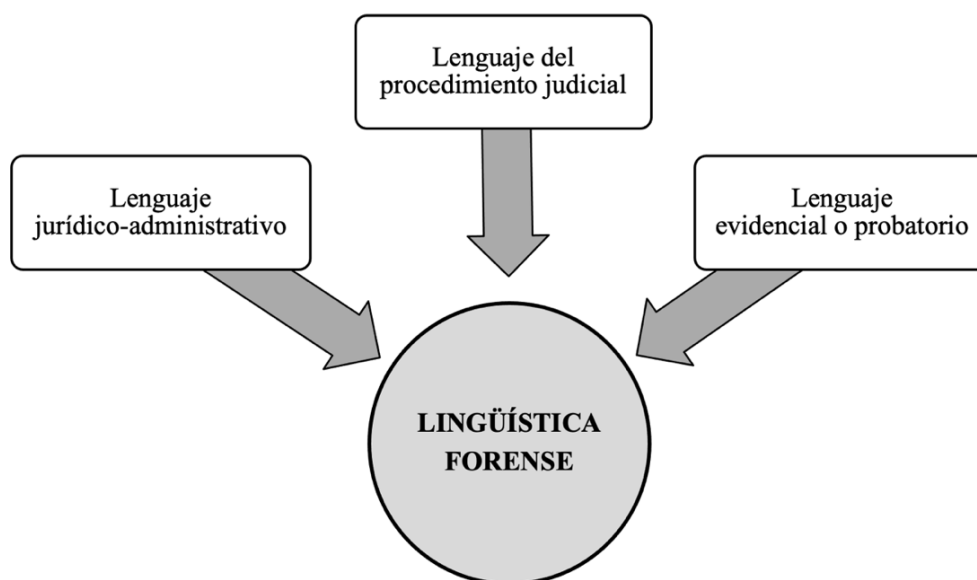


Imagen 2: Campos de actuación de la lingüística forense. Fuente: Elaboración propia.

Aunque esta clasificación se ha ido revisando y matizando con el paso de los años (Fernández Trillo, 2015: 19-34; McMenamin, 2017: 34-38; Coulthard, Johnson y Wright, 2017: 4), lo cierto es que, en líneas generales, podemos hablar de dos grandes posiciones: la de aquellos que por lingüística forense entienden cualquier interacción entre lengua y derecho, lo que englobaría las tres áreas de estudio, y la de aquellos que, adoptando una postura mucho más estricta, consideran que solo debe hacer referencia al lenguaje evidencial o probatorio². Esta última postura será la que adoptemos en este trabajo, cuyo objetivo es la aplicación de los principios teóricos, metodológicos y conclusivos de la evidencia lingüística a los estudios de atribución de autoría en el ámbito literario.

3. LA EVIDENCIA LINGÜÍSTICA COMO PRUEBA PERICIAL: LOS ESTUDIOS DE ATRIBUCIÓN DE AUTORÍA

Como hemos explicado en el epígrafe anterior, el punto de partida del lenguaje como evidencia lo constituye la obra de Svartvik. Tras su publicación, que causó un gran impacto en el mundo académico —especialmente por las posibilidades que el lenguaje adquiriría como instrumento al servicio de la sociedad—, empiezan a surgir algunos trabajos, generalmente escritos por lingüistas, que analizan confesiones dubitadas, investigan la autenticidad de ciertos discursos o analizan la similitud de ciertas marcas comerciales (Shuy, 1993; Levi, 1994; Eades, 1994). Todos estos trabajos constituyen los primeros pasos de una disciplina aún en ciernes, que no empezará a desarrollar unos principios fiables hasta la llegada del nuevo siglo. Aunque la consolidación ha sido lenta, lo cierto es que la evidencia lingüística ha servido para resolver importantes casos policiales, como la detección del terrorista estadounidense Unabomber (Fitzgerald, 2004: 193-222), la identificación del asesino de Danielle Jones (Coulthard y Johnson, 2010: 508-522) o, en el ámbito español, la liberación de Óscar Sánchez, condenado a 14 años de prisión en Italia por tráfico de drogas tras haber sido víctima de una suplantación de identidad (Cicres y Gavalda, 2014: 64).

En los siguientes apartados vamos a explicar los principios que conforman los estudios de atribución de autoría de la lingüística forense. Aunque algunos autores han propuesto diferentes etiquetas en función de la tipología de los textos (solo dubitados o dubitados e indubitados) y del número de candidatos a autor (ninguno, uno o varios), a día de hoy la etiqueta *atribución de autoría* se utiliza de manera genérica para referirnos

² Cabe mencionar que en septiembre de 2021, tras una votación en la que pudimos participar todos los socios, la *International Association of Forensic Linguists* (AIFL) ha pasado a llamarse *International Association for Forensic and legal Linguistics* (AIFLL), para poner el acento, precisamente, en todas las posibles interacciones entre lengua y derecho.

a cualquier proceso mediante el cual se analizan las características lingüísticas de unos determinados textos para extraer conclusiones sobre su autoría³.

3.1. Principio teórico: la existencia del idiolecto o estilo idiolectal

El concepto de idiolecto está estrechamente relacionado con el de variación lingüística, introducido en el ámbito de la sociolingüística por William Labov a mediados del siglo pasado. Según la perspectiva laboviana, toda producción lingüística es variable —es decir, puede manifestarse de diferentes modos—, lo que implica que incluso los individuos que comparten un mismo código lingüístico produzcan en la práctica estructuras superficiales distintas para una misma estructura profunda (Labov, 1966 y 1972).

La variación lingüística es inherente a todas las lenguas y se puede producir en todos sus niveles, desde el fonético-fonológico hasta el pragmático-discursivo, pasando por el morfológico, el sintáctico y el léxico-semántico. Los factores que determinan la aparición de una variante lingüística en ciertas circunstancias y de otra distinta en circunstancias diferentes pueden ser externos e internos; los primeros hacen referencia a variaciones sociales, tales como el sexo o el género, la edad, la clase social, el nivel educativo, la etnia o la profesión, mientras que los segundos a las variaciones propiamente lingüísticas.

A pesar de que la sociolingüística de la variación contempla ambos factores, la mayor parte de los estudios de esta disciplina se han centrado en la variación en comunidades lingüísticas (sociales) y muy pocos en la variación que atañe a las estructuras internas de las propias lenguas (lingüísticos). Estos últimos demuestran que, incluso dentro de comunidades que comparten contexto social y variedad lingüística, emergen diferencias significativas entre los distintos sujetos que solo pueden explicarse como elecciones individuales; una perspectiva clave para la lingüística forense, que parte del fundamento de que cada persona tiene un uso particular de la lengua que habla y escribe, que lo separa y distingue del resto de usuarios de esa misma lengua⁴. De este modo, el *idiolecto* debe entenderse como la variante lingüística característica de un determinado individuo, al igual que el *dialecto* lo es de una determinada zona geográfica, el *sociolecto* de un determinado estatus social, el *cronolecto* de un determinado grupo de edad o el *sexolecto*

³ Abbasi y Chen hablan de *identification task* cuando conocemos de antemano a los candidatos a autor y de *similarity detection* cuando no es así (2008). Juola distingue entre *open-class problem* y *closed-class problem*, en función de si en el conjunto de sospechosos se encuentra con total seguridad o no el autor real (2008). Koppel, Schler y Argamon plantean tres posibles escenarios: *profiling* cuando disponemos de un texto dubitado, pero no de posibles candidatos a autor, *authorship verification* cuando disponemos de un texto dubitado y de textos indubitados de un solo candidato y *needle-in-a-haystack* cuando disponemos de un texto dubitado y de textos indubitados de infinidad de posibles candidatos (2009). Y Turell diferencia entre *determinación de autoría* (varios candidatos) y *atribución de autoría* (un único candidato) (2011: 77).

⁴ Aunque a día de hoy nadie parece cuestionar la existencia de un habla individual, es importante advertir que no siempre ha sido así. Jakobson creía que “la propiedad privada, en el campo del lenguaje, no existe” y que “todo está socializado”, incluso en el nivel individual, pues todo emisor adapta, en mayor o menor medida, su mensaje al receptor, especialmente en lo que concierne a su vocabulario (1975: 21); Barthes, por su parte, llegó a afirmar que el idiolecto era en gran medida una ilusión (1977: 21).

/ *generolecto* de un determinado género. Nuestro idiolecto, por tanto, está conformado por una serie de rasgos sociolectales, dialectales, cronolectales, sexolectales o generolectales..., pero también por una serie de rasgos propios e individuales, que nada tienen que ver con todas estas variantes.

Uno de los primeros autores que habló del idiolecto desde esta perspectiva fue Baldwin, al definirlo como una forma única que tipifica a un individuo particular y que está constituido por sus preferencias lingüísticas, como, por ejemplo, la predilección por ciertas palabras o patrones de entonación (1979: 231). Brown, poco después, precisó que el idiolecto está conformado por rasgos idiosincrásicos, es decir, marcas lingüísticas individuales, y únicas en su combinación, que no guardan correlación con factores de grupo (sexo o género, edad, origen, posición social, salud, etc.) (1982: 16). Johnstone, recordando a Saussure, advirtió que hay dos modos de entender la variación individual: tratar la idiosincrasia como desviación o hacerlo como “the set of strategic adaptations he or she makes from a closed set of conventional possibilities, in the inter-actions in which he or she takes part” (1996: 12). Burrige y Mulder lo explicaron como la “variation within a language that is associated with individual speakers” (1998: 302). Y ya en el siglo XXI, Coulthard, Johnson y Wright advierten las enormes posibilidades de identificación que facilita la idea de la existencia de una versión individual y distintiva de la lengua:

The forensic linguist approaches the problem of questioned authorship from the theoretical position that every native speaker has their own distinct and individual version of the language they speak and write, their own *idiolect*, and the assumption that this *idiolect* will manifest itself through distinctive and idiosyncratic choices in speech and writing (2017: 15).

Es importante advertir que la variación lingüística afecta a todos los niveles y que, por tanto, los rasgos lingüísticos caracterizadores del idiolecto de una persona también mostrarán cierta variación, dependiendo del contexto social en que se produzca el mensaje, el registro que se emplee, el género textual que se adopte o el momento vital y personal en que se encuentre su emisor. Y por eso algunos han visto en esta variabilidad la principal diferencia entre la evidencia lingüística y otros tipos de evidencia no cambiantes, como la huella dactilar o el ADN⁵.

⁵ Foster equipara el idiolecto a la huella dactilar o al ADN, al afirmar que “after the crime, the words remain; like fingerprints and DNA” (2000: 4). Coulthard, por el contrario, desaconseja usar el término *linguistic fingerprint* (huella lingüística) al entender que es una metáfora poco fiable, pues “the value of the physical fingerprint is that every sample is both identical and exhaustive, that is, it contains all the necessary information for identification of an individual, whereas, by contrast, any linguistic sample, even a very large one, provides only very partial information about its creator’s idiolect” (2005b: 14); y en la misma línea se han manifestado muchos otros. Tal vez sea pretencioso comparar el poder discriminatorio de la evidencia lingüística con el de la evidencia dactiloscópica, pero lo cierto es que cada vez son más los estudios orientados a determinar la fuerza idiosincrásica de ciertas marcas lingüísticas. No creemos que el problema resida tanto en la variabilidad de la muestra lingüística (pues a día de hoy parece estar demostrado

El idiolecto es una consecuencia de la variación lingüística, de eso no cabe duda⁶. Pero lo cierto es que los estudios de los últimos quince años han demostrado que la variación interpersonal (entre muestras lingüísticas de diferentes individuos) es muy superior a la variación intrapersonal (entre muestras lingüísticas de un mismo individuo), también en español (Cicres y Gavalda, 2014: 63), lo que hace posible poder identificar a una persona por los rasgos idiosincrásicos que caracterizan su voz o sus escritos: “The analysis of variation is important in the forensic sciences because the variation left in trace evidence can be associated with the individual or class characteristics of the instruments or persons involved in a crime” (McMenamin, 2002: 45).

Entender el idiolecto como marca personal e intransferible, así como su variabilidad, no solo debe ser el principio teórico fundamental de los estudios de atribución de autoría literaria (de obras anónimas, apócrifas, escritas bajo pseudónimo o por los mal llamados *negros literarios*), sino que, además, debe servir para fundamentar otros estudios relacionados con la autoría, como, por ejemplo, los estudios cronológicos basados en la evolución estilística de un autor. Se han dado algunos primeros pasos en este sentido (Celma Valero y Ruiz Urbón, 2022; Cuéllar, 2023), pero falta profundizar en los conceptos teóricos que respaldan dichas apreciaciones.

3.2. Principio metodológico: la comparación forense de textos

Los estudios de atribución de autoría literaria que se llevan a cabo actualmente se basan en la comparación de textos, sin embargo, no tienen en cuenta —o no de manera sistemática— algunos requisitos esenciales establecidos por la lingüística forense. Para que la metodología sea efectiva, debemos tener en cuenta las características de las muestras textuales objeto de estudio, así como ciertos aspectos relacionados con la tipología de los análisis o la elección de variantes.

3.2.1. Características de las muestras textuales

El primer paso para llevar a cabo una comparación forense de textos es valorar el material objeto de estudio, principalmente en relación a su extensión y tipología, pues, aunque “no one has ever speculated about, let alone tested, how much text and of what kind would be required to allow one to successfully and exhaustively specify an individual’s idiolect” (Coulthard, 1998: 141), parece lógico pensar que cuanto mayor

que las marcas que conforman la huella dactilar de un individuo también presentan cierta variación con el paso del tiempo, aunque esta sea mínima) como en el peso identificativo de la misma: tanto una huella dactilar como un ADN contienen toda la información de un determinado individuo, mientras que una evidencia lingüística solo contiene una ínfima parte de los rasgos idiosincrásicos que componen el idiolecto.
⁶ La idea de variación no se opone ni al orden ni a la regularidad; el lenguaje no tiene por qué carecer de polimorfismo para ser estructurado, ni necesita ser homogéneo para ser regular; y en este sentido, “natural language cannot be successfully observed outside a theoretical paradigm, but the paradigm cannot be constructed without the observation of language as it is used” (McMenamin, 2002: 65).

longitud tengan las muestras y cuanto más rasgos genéricos compartan entre sí, más variables podremos analizar y más fiables serán los resultados alcanzados. De igual modo, debemos tener en cuenta su temática y datación.

3.2.1.1. Extensión de las muestras

No hay una longitud mínima establecida y es bastante habitual que los lingüistas forenses deban enfrentarse a textos extremadamente breves, como *whatsapps*, *tuits*, *posts* o correos electrónicos que rara vez superan las 200 palabras (Coulthard, 2005a). Aunque hay estudios que han alcanzado resultados prometedores con textos muy breves (Sanderson y Guenter, 2006; Koppel, Schler y Bonchek-Dokow, 2007; Luyckx, 2010), lo cierto es que la precisión de los análisis cuantitativos decrece significativamente cuando la longitud del texto es inferior a las 1.000 palabras (Feiguina y Hirst, 2007). En todo caso, y tal y como advierte Stamatatos, la longitud no es el único requisito esencial:

It is not yet clear whether other factors (beyond text length) also affect this process. For example, let a and b be two texts of 100 words and 1,000 words, respectively. A given authorship attribution tool can easily identify the author of a, but not the author of b. What are the properties of a that make it an easy case, and what makes b so difficult, albeit much longer, than a? On the other hand, what are the minimum requirements in training text we need to be able to identify the author of a given text? (2009: 553).

3.2.1.2. Calidad de las muestras

La calidad de las muestras está relacionada con la contaminación textual o autorial que estas hayan podido sufrir. En relación con la contaminación textual, es importante considerar si los textos nos han llegado completos o sesgados y si, además, la versión de que disponemos es absolutamente fiable (como sería un texto autógrafo) o si, por el contrario, es una copia del original (como sería, por ejemplo, la transcripción de una grabación de voz o de las declaraciones policiales de un acusado) y susceptible, por tanto, de contener errores de transmisión textual. En relación con la contaminación autorial, como advierte Love, es necesario distinguir lo que podríamos llamar la *autoría puramente ejecutiva* (en la que el texto nos llega en su versión más primigenia) de otro tipo de autorías, como la *autoría de revisión*, que se produce cuando el autor repasa el texto; la *autoría colaborativa*, cuando son terceros los que revisan y corrigen; la *autoría declarativa*, que se da cuando un tercero asume la autoría de un texto escrito por otro (es el caso de los famosos *negros literarios*); o la *autoría precursora*, en la que el autor reproduce de manera más o menos sistemática los textos de otros, ya sea en forma de cita textual o de parafraseo (2002: 32-50). Para Love, “the attributionist who sees furthest is the one with the richest sense of the possibilities in the given case” (2002: 50).

3.2.1.3. Género textual y circunstancias comunicativas de las muestras

Otro requisito importante a la hora de enfrentarnos a una comparación de textos con fines de atribución de autoría —aunque no imprescindible— es el de disponer de muestras indubitadas del mismo género textual que las dubitadas y que, a ser posible, todas ellas compartan unas mismas circunstancias comunicativas. Es evidente que un mismo sujeto (emisor) no se expresará de igual modo si escribe un informe sobre el impacto económico de la COVID-19 en la hostelería o una poesía amorosa (mensaje), ni si el mensaje se lo dirige a su jefe o a su novia (receptor), ni si lo hace en un entorno laboral o familiar (contexto); tampoco se expresará de la misma manera en su lengua materna que en una adquirida (código), ni si lo hace a través de un correo electrónico o un tuit, en el que hay un número limitado de caracteres que fuerzan la escritura abreviada (canal). Y lo mismo ocurre, evidentemente, en los textos literarios, en donde el idiolecto de cada autor sufre variaciones en función del género textual seleccionado.

En un caso modélico de comparación forense con fines de atribución de autoría, las muestras dubitadas y las indubitadas comparten un mismo género textual, van dirigidas a una misma persona o tipo de persona, están escritas en la misma lengua, tienen un mismo canal y han sido producidas en un contexto similar; pero en la práctica, pocas veces ocurre así y, a menudo, los peritos lingüistas deben enfrentarse a textos de diversa naturaleza. En estos casos, en base a su experiencia y leal saber y entender, deberán decidir la viabilidad de dicha comparación, teniendo en cuenta que “genre effects generally will supersede authorial features in the discrimination process” (Holmes, 1998: 111).

3.2.1.4. Tema de las muestras

Junto al género textual, la temática es otra de las variables a tener en cuenta a la hora de realizar un estudio de atribución de autoría. Los textos que comparten unos mismos temas van a compartir también ciertas analogías léxicas, que poco o nada tienen que ver con el idiolecto de sus autores, por lo que debemos tener en cuenta también esta circunstancia a la hora de discriminar autorías. Si analizamos dos noticias periodísticas sobre un mismo hecho (por ejemplo, la contaminación acústica en las ciudades) van a darse, inevitablemente, una serie de palabras coincidentes relacionadas con la propia materia de estudio (*ruido, decibelios, tráfico, volumen*, etc.), pero solo si han sido escritas por la misma persona encontraremos, además, otras variables coincidentes (como, por ejemplo, el empleo de unas mismas palabras de función o la presencia compartida de una secuencia de más de cinco palabras iguales o de una falta de ortografía determinada).

3.2.1.5. Fecha de las muestras

Por último, es importante considerar la fecha de las muestras textuales, pues está demostrado que el idiolecto de una persona varía con el paso del tiempo, aunque no

siempre al mismo ritmo, ni con la misma intensidad (Koppel, Schler y Argamon, 2009: 26).

Por todos estos motivos, en los estudios de atribución de autoría, como advierte Holmes, “it is certainly wise to work within the same genre when faced with a list of candidate authors for a disputed work and to work within as close a time period as possible when selecting appropriate ‘control’ authors” (1998: 111). No obstante, aunque la alternancia genérica o la evolución estilística de un autor pueda condicionar los resultados, es importante destacar que los estudios parecen demostrar que la variación intrapersonal siempre será menor que la variación interpersonal:

A pesar de que nuestros patrones lingüísticos cambian con el tiempo, debido a muchas circunstancias —el nivel cultural, el medio social en el que nos desenvolvemos, el tema sobre el que hablamos— los estudios forenses del habla y la escritura precisan que algo permanezca constante en nuestra producción verbal y escrita (Fernández Trillo, 2015: 49).

3.2.2. *Tipología de los análisis*

El principio de certeza, que propugna que para llegar a conclusiones robustas debemos realizar análisis cualitativos y cuantitativos de las evidencias, es uno de los principios esenciales de la criminalística moderna; y asumido, como tal, por la lingüística forense. Los análisis cualitativos, basados en la observación y lectura minuciosa de los textos, ofrecen mucha información y muy valiosa, pero los datos que manejan son subjetivos y menos controlables que los cuantitativos. Por su parte, los análisis cuantitativos, basados en la medición, proporcionan datos objetivos y replicables, pero a veces insuficientes para dilucidar el complejo proceso de la autoría. Por eso, un buen estudio de atribución de autoría debe contemplar —siempre que sea posible— una comparación de textos que combine ambos tipos de análisis (Jeffries y McIntyre, 2010: 12).

Hasta hace relativamente poco tiempo, los estudios lingüísticos —y también los literarios— eran eminentemente cualitativos; de un tiempo a esta parte, sin embargo, se han ido adoptando técnicas cuantitativas para analizar el lenguaje y entender su variación en relación con factores como el periodo histórico, el contexto, el género o el autor (Savoy, 2020). Así, gracias a la estilometría, podemos realizar análisis estadísticos del estilo de un determinado autor, entendiendo por *estilo* el idiolecto escrito que caracteriza su forma de escribir en una situación concreta:

By style I mean the set of linguistic features that, taken together, uniquely identify a language user. The notion presupposes that there has been a choice —that someone has opted for Feature P rather than Feature Q (or R, S, ...). In this view, if we have no choice in the use of a feature, that feature cannot be a part of our style (Crystal, 2008: 16).

El uso de métodos estilométricos en los estudios de atribución de autoría es relativamente reciente. Como recuerdan Holmes (1998), Juola (2006) y Stamatatos

(2009), los primeros intentos por cuantificar el estilo de escritura se remontan al siglo XIX, cuando el físico estadounidense Thomas Mendenhall midió la extensión de varios cientos de miles de palabras de las obras de Bacon, Marlowe y Shakespeare, tratando de demostrar que la longitud de palabra no es una variable discriminadora entre autores. Ya en el siglo XX, George Unde Yule en Inglaterra y George Kingsley Zipf en Estados Unidos intentaron establecer fórmulas matemáticas para discriminar autorías, basadas en la frecuencia léxica, como la característica K de Yule, ineficaz según los estudios posteriores, y la ley Zipf, que a día de hoy se sigue utilizando. Pero no fue hasta el trabajo de Mosteller y Wallace (1964) sobre la autoría de los *Papeles Federalistas* cuando los análisis computacionales empezaron a ganar adeptos entre los lingüistas: su método, basado en el análisis estadístico bayesiano de la frecuencia de palabras funcionales (como *y* o *a*), ofreció resultados de discriminación significativos entre los distintos candidatos a autor. Otras investigaciones estilométricas posteriores, sin embargo, dieron lugar a múltiples controversias, como el estudio sobre la autoría de *El Libro del Mormón*, que generó un intenso debate entre los defensores de la autoría de Joseph Smith, su firmante, y los defensores de una autoría compartida por al menos cuatro personas; un debate que puso sobre la mesa la necesidad de testar algunos de los métodos propuestos. Desde finales de los años 80, y más intensamente en el siglo XXI, los esfuerzos de la estilometría han ido encaminados en esta dirección; así, se han ido descartando algunos parámetros propuestos para discriminar autorías, como la característica K de Yule, antes comentada, y validando otros nuevos, como la distribución de la frecuencia de las palabras más utilizadas (*delta distance*), el análisis de componentes principales (PCA) de las palabras de función, la localización de cadenas de 5 o más palabras coincidentes (*verbatim*) o el estudio de las clases de palabras mediante etiquetadores gramaticales automáticos (*Part-Of-Speech Tagger* o *Pos tagging*) (Savoy, 2020). No obstante, y retomando lo que decíamos al principio de este epígrafe, “a traditional authorship study looking at all of the external and traditional internal evidence must be completed before a non-traditional study is undertaken”, pues “non-traditional attribution studies provide only a few of the tools for the attribution scholar. And these tools are by no means the most important” (Rudman, 1998: 359).

3.2.3. Variables de análisis

Las variables lingüísticas son las elecciones habituales e inconscientes que una persona realiza al escribir y que pueden, por tanto, constituirse como prueba o indicio para discriminar autorías. Como advierte McMEnamin, hay dos tipos generales de variables: la elección de formas opcionales o la desviación de una norma (2017: 134).

Hay infinidad de variables lingüísticas susceptibles de poder ser analizadas cualitativa y cuantitativamente. Rudman ya indicó hace unos años que se habían propuesto más de mil variables diferentes para los estudios de atribución de autoría y que, desgraciadamente, no había consenso en el establecimiento de las más mismas, siendo

los especialistas los encargados de seleccionar las más útiles para cada caso (1998: 360)⁷; sin duda las preferidas, tal y como fueron caracterizadas por Labov, son aquellas de “alta frecuencia, inmunes a la supresión consciente, codificables (y contables), y ampliamente distribuidas a lo largo de una cierta población (o individuo)” (McMenamin, 2017: 134). Incidiendo en este aspecto, Garayzábal Heinze, Queralt Estévez y Reigosa Riveiros establecen las distintas características que debemos contemplar a la hora de seleccionar una variante en contextos forenses de atribución de autoría (2019: 62-63): (a) que sea muy frecuente y esté estratificada; (b) que muestre alta variabilidad interescritor y baja variabilidad intraescritor; (c) que sea relativamente fácil de extraer y calcular; (d) que pueda ser intercambiable en algunos contextos; (e) que sea lo más independiente posible de otras variables; (f) que su producción sea lo más inconsciente posible; (g) que esté definida lingüísticamente de manera clara y precisa; y (h) y que tengan en cuenta la inestabilidad del rasgo.

Las variables lingüísticas se dan en todos los niveles de la lengua, desde el fonético-fonológico hasta el pragmático-discursivo. Aunque en un texto escrito el nivel fonético-fonológico, a priori, no es relevante, deberemos tenerlo en cuenta a la hora de estudiar aspectos relacionados con el acento o la rima (en el caso de textos en verso) o con ciertas figuras retóricas vinculadas a los sonidos y la musicalidad, como la aliteración, la onomatopeya, la similitudencia o la paranomasia. Pero, sin duda, las variables que debemos contemplar en el nivel más bajo del texto escrito serán todas aquellas relacionadas con el empleo de grafemas y caracteres⁸ y, en especial, con el uso de n-gramas de caracteres. Grieve defiende la efectividad de los n-gramas de dos caracteres, con un 65% de precisión cuando deben discriminar entre 40 autores y de un 94% cuando deben hacerlo entre dos (2007); no obstante, para el español, y tal y como estudiamos hace unos años, la precisión aumenta progresivamente a medida que lo hace también el número *n* del n-grama (Blasco y Ruiz Urbón, 2009).

Muy interesantes resultan también las variables morfológicas, como, por ejemplo, la alternancia del morfema de tiempo-modo-aspecto en el pretérito imperfecto de subjuntivo (-ra / -se), el estudio de los mecanismos de formación de palabras o la frecuencia relativa de las distintas categorías gramaticales (una variable muy efectiva y que ahora, gracias a los programas de etiquetado automático, ha cobrado una especial dimensión).

También deberemos tener en cuenta las variables relacionadas con el nivel sintáctico, como el estudio del tipo de oración, la utilización de bigramas y trigramas de clases de palabras, el uso de ciertas construcciones sintácticas, la posición relativa de una palabras con respecto a otras o los pronombres utilizados para introducir las oraciones

⁷ Afortunadamente, la investigación en atribución de autoría ha avanzado mucho desde el estudio de Rudman (1998) y ya disponemos de varios estudios que revisan los distintos parámetros utilizados y dan cuenta de la efectividad de cada uno de ellos (Juola, 2006; Grieve, 2007; Koppel, Schler y Argamon, 2009; Stamatatos, 2009; Luyckx, 2010; Jockers y Witten, 2010; Savoy, 2020). Algo similar hicimos hace unos años para la lengua española (Blasco y Ruiz Urbón, 2009).

⁸ Tomando como referencia a Grieve (2007), *grafema* hace referencia a una letra del alfabeto y *carácter* a cualquier tipo de unidad gráfica, ya sea una letra, un dígito, un signo de puntuación o un espacio en blanco.

subordinadas (Svartvik, 1968; Baayen, Van Halteren y Tweedie, 1996; Feiguina y Hirst, 2007; Spassova, 2009; Turell, 2011; Stamatatos, Fakotakis y Kokkinakis, 2001).

Pero sin duda, uno de los niveles que más páginas de investigación ha ocupado hasta ahora es el del léxico⁹. Dentro de las variables léxicas, destaca el estudio de las palabras más frecuentes, la riqueza de vocabulario, las erratas ortográficas, el porcentaje de ciertos radicales o la frecuencia relativa de las palabras funcionales, entre otras; en este nivel también han resultado ciertamente interesantes la aplicación de distintos métodos estadísticos, como el análisis clúster, el análisis de componentes principales (PCA) o el análisis multivariante (Mosteller y Wallace, 1964; Woolls y Coulthard, 1998; Holmes y Forsyth, 1995; Burrows, 1989, 2002 y 2003; Hoover, 2004a y 2004b; Argamon y Levitan, 2005; Stamatatos, 2009; Savoy, 2020). Aunque todos estos análisis poseen gran fuerza discriminante, las palabras de función se han constituido en la marca preferida por muchos investigadores, especialmente por tres motivos: por su alta frecuencia de uso, que facilita su cuantificación y posterior análisis estadístico; por su papel gramatical, que restringe el control consciente; y por su fuerza idiosincrásica, al no estar condicionados a un contexto concreto (Spassova, 2009: 45).

De un tiempo a esta parte están cobrando también cierto protagonismo las variables semánticas relacionadas con la expresión de ciertos sentimientos, como la alegría, la tristeza, el miedo o la ira, pues se sabe que el idiolecto está conformado —además de por el conocimiento lingüístico y las influencias extralingüísticas— por las asociaciones cognitivas (McMenamin, 2002). Y también las variables pragmático-discursivas, como las fórmulas de salutación y despedida, los marcadores, la puntuación o el número de palabras por frase o párrafo (Mannion y Dixon, 1997; Gains, 1999; Wright, 2013).

En todo caso, es importante advertir que no hay una variable única y definitiva, sino que lo importante es la acumulación de rasgos:

We must strive to identify all of the markers that make up “style” —to map style the way biologists are mapping the gene. Function words, type/tokens, word lengths, hapax legomena, and other specific style markers may not in themselves be an indicator of a unique style, but when used in conjunction with all of the other quantifiable indicators that make up style, they become important (Rudman, 1998: 360).

3.2.4. Herramientas de análisis textual

A día de hoy disponemos de muchas y muy variadas herramientas para el análisis (semi)automático de los textos (Woolls y Coulthard, 1998; Woolls, 2003; Garayzabal Heinze, Queralt Estévez y Reigosa Riveiros, 2019: 65-66), como, por ejemplo, *WordSmith Tools*, *AntLab*, *Contawords*, *Voyant Tools*, *Linguistic Inquiry and Word*

⁹ Las marcas léxicas siguen siendo las más utilizadas en los análisis cuantitativos, tomando como referencia la afirmación que hizo Tallentire en 1973: “no potential parameter of style below or above that of the word is equally effective in establishing objective comparison between authors and their common linguistic heritage” (Citamos por Holmes, 1998: 112).

Count (LIWC), *CopyCatch Gold* o *JVocalyse*. Aunque todos estos programas ofrecen grandes posibilidades, de un tiempo a esta parte la utilización de lenguajes de programación —principalmente R o Python— en los estudios de atribución de autoría está creciendo exponencialmente, ya sea a través de paquetes desarrollados por especialistas en esta materia, como “stylo”, “koRpus” o “syuzhet”, o a través de códigos específicos, en los que el analista puede configurar a su gusto las variables de análisis conforme a las características concretas de esos textos.

3.3. Principios conclusivos: escalas de opinión verbal y estadística

Uno de los puntos más endebles en los trabajos de atribución de autoría literaria es el de la expresión de las conclusiones, que rara vez cumplen con el principio de probabilidad de la criminalística moderna —enunciado en 1910 por Edmond Locard— que establece que la acumulación de datos o evidencias debe permitir inferir probabilidades en relación con los hechos delictivos, que van desde la probabilidad nula al grado máximo de probabilidad. Siguiendo este principio, los lingüistas forenses han expresado tradicionalmente sus conclusiones a través de escalas de opinión verbal, también llamadas escalas de probabilidad, para poder traducir todos los resultados de las metodologías combinadas a unos resultados ecuanímenes, que todos los receptores sean capaces de interpretar de igual modo. Las primeras escalas adoptadas por los lingüistas forenses europeos —basándose en escalas de la American Society for Testing and Materials (ASTM) o del Scientific Working Group for Forensic Document Examination (SWGDOC)— fueron estrictamente verbales, tal y como puede verse en los ejemplos que proponen Coulthard (Tabla 1) y McMEnamin (Tablas 2 y 3) a principios de los 2000:

Más positivo	
5	“Estoy personalmente <i>convencido</i> de que X es el autor”
4	“En mi opinión, es <i>muy probable</i> que X sea el autor”
3	“En mi opinión, es <i>probable</i> que X sea el autor”
2	“En mi opinión, es <i>bastante probable</i> que X sea el autor”
1	“En mi opinión, es <i>algo probable</i> que X sea el autor”
0	“En mi opinión, es <i>posible</i> que X sea el autor”
-1	“En mi opinión, es <i>algo probable</i> que X no sea el autor”
-2	“En mi opinión, es <i>bastante probable</i> que X no sea el autor”
-3	“En mi opinión, es <i>probable</i> que X no sea el autor”
-4	“En mi opinión, es <i>muy probable</i> que X no sea el autor”
-5	“Estoy personalmente <i>convencido</i> de que X no es el autor”
Más negativo	

Tabla 1. Traducción de la escala propuesta por Coulthard para el caso de Danielle Jones.
Fuente: Coulthard, Johnson y Wright, 2017: 197 y 198.

¿Lo escribió el sospechoso?	Escala	Conclusión
SÍ	9	Identificación
	8	Altamente probable: lo escribió
	7	Probable: lo escribió
	6	Indicios: lo escribió
INCONCLUSO	5	No concluyente
NO	4	Indicios: no lo escribió
	3	Probable: no lo escribió
	2	Altamente probable: no lo escribió
	1	Eliminación

Tabla 2. Traducción de la escala propuesta por McMenamin para responder a la pregunta “Did the suspect write it?”. Fuente: McMenamin, 2002: 125.

¿Lo escribió un único autor?	Escala	Conclusión
SÍ	9	Definitivo: un escritor
	8	Altamente probable: un escritor
	7	Probable: un escritor
	6	Indicios: un escritor
INCONCLUSO	5	No concluyente
NO	4	Indicios: más de un escritor
	3	Probable: más de un escritor
	2	Altamente más de un escritor
	1	Definitivo: más de un escritor

Tabla 3. Traducción de la escala propuesta por McMenamin para responder a la pregunta “Did one author write it?”. Fuente: McMenamin, 2002: 125.

Como puede verse en los ejemplos propuestos, las escalas de opinión verbal recogen los distintos niveles de probabilidad dentro de los cuales debe enmarcarse el resultado global de nuestro análisis comparado de textos. Estas escalas se han ido perfeccionando con el tiempo, pues si la de Coulthard no contemplaba la posibilidad de que el análisis fuera inconcluso, las de McMenamin, sí. Mcmenamin, además, ofrece un listado de los criterios que permiten determinar los distintos niveles de conclusión, tratando así de objetivar al máximo las escalas propuestas (2002: 126-127).

Aunque las escalas de probabilidad verbal son la opción más utilizada por los lingüistas forenses, no están exentas de crítica; sobre todo desde que el Tribunal Supremo de Estados Unidos estableciera en 1993 unos estándares para determinar si los métodos científicos utilizados por los peritos eran fiables (entre los que incluía la necesidad de contemplar una tasa de error real o probable sobre la técnica aplicada). En 1999, Broeders denunció el carácter subjetivo de las propuestas verbales al considerar que dos expertos podrían establecer diferentes niveles de la escala basándose en unos mismos datos (1999:

237); algo que también fue comentado por Champod y Evett (2000), que defendían un enfoque bayesiano. Pero precisamente Evett, junto a Weir, había propuesto unos años antes (1998) una correspondencia verbal para la escala de razón de verosimilitud utilizada en la identificación de personas mediante el ADN (Tabla 4), poniendo así de manifiesto la importancia de emplear escalas verbales que ayuden a comprender los valores de LR (*Likelihood Ratio*):

Razón de verosimilitud (LR)	Correspondencia verbal
De 1 a 100	Respaldo limitado
De 10 a 100	Respaldo moderado
De 100 a 1000	Respaldo fuerte
Más de 1000	Respaldo muy fuerte

Tabla 4. Traducción de la escala de equivalencias entre ratios de verosimilitud y conceptos de probabilidad verbal en la evidencia de ADN. Fuente: Evett y Weir, 1998: 244.

En relación con este asunto, Delgado Romero, jefe de la Sección de acústica forense de la Comisaría general de la Policía científica española, comentó las ventajas de utilizar el teorema de Bayes para establecer la relación de probabilidades sobre dos hipótesis competitivas y que, a su vez, son excluyentes (“el sospechoso ha realizado la voz dubitada vs. la voz dubitada no ha sido realizada por el sospechoso”), pero también las dificultades de hacerlo en el entorno lingüístico (2005: 122-127). En el caso del ADN, cada genotipo suele comprender 15 marcadores genéticos y a cada uno de ellos se le otorga un valor de verosimilitud, y, puesto que cada marcador es independiente del resto, el valor final del LR para cada individuo (producto de las probabilidades que definen el LR de cada uno de los 15 marcadores) puede llegar a expresarse en términos de billones o trillones; pero en el caso de la voz —y añadimos nosotros, más aún en el del texto—, el cálculo del LR está claramente influenciado por las características de las muestras que, a diferencia de las del ADN, son fractales y variables, lo que dificulta, además, la determinación de los ejes que dimensionan la población de referencia. Por este motivo, Delgado Romero sigue apoyando el uso de las escalas de probabilidad verbal, pues la propuesta de interpretación del teorema de Bayes, aunque interesante, “no acaba de ofrecer el grado de satisfacción que sería deseable”; y concluye:

En el caso de la Identificación Forense de Locutores (IFL), la interpretación de conclusiones de estudio a través de un entorno bayesiano resulta difícil de concretar. Existen aspectos, no sólo referidos a la población de referencia utilizada, sino también a la naturaleza de la variable del habla de un mismo individuo, que aparecen como serios obstáculos al carácter objetivo que dicho ámbito pretende conferir a las tareas asignadas a los científicos. Por otra parte, y haciéndolo ya extensivo a otras disciplinas forenses, es complicado evitar el uso de equivalencias verbales para expresar de una forma más comprensible los niveles de certeza alcanzados por los expertos (2005: 128).

En la misma línea se manifestaron un grupo de fonetistas forenses del Reino Unido (French y Harrison, 2007), que si bien aceptaban la conveniencia de aplicar proporciones de verosimilitud —incluidas las bayesianas— para la expresión de las conclusiones en grados de convicción, advertían que la falta de datos poblacionales de referencia lo imposibilitaba. Una declaración que dio lugar a otras manifestaciones a favor, pero también en contra, como la de Rose y Morrison (2009), que consideraban que el marco conceptual apropiado es el de la razón de verosimilitud bayesiana, que es en el que se están desarrollando otras ciencias forenses. Como explican estos dos autores, si un proceso judicial consiste en tomar decisiones sobre incertidumbres, la mejor manera de cuantificar dichas incertidumbres es utilizar el teorema de Bayes, que permite calcular la probabilidad de una hipótesis dada la evidencia:

Bayes' Theorem is of paramount importance when one wants to know the probability of a hypothesis given the evidence, and this is what gives it its special status in forensic identification. Bayes' Theorem states informally that the probability of the hypothesis, given the evidence, can be estimated from two things: firstly, how probable the hypothesis is, before the evidence is adduced; and secondly, the strength of the evidence (2009: 144).

Aunque el debate teórico sigue abierto, lo cierto es que, en la práctica, la opción más utilizada por los lingüistas forenses de todo mundo sigue siendo la de la escala de probabilidad verbal, ya que la falta de estudios poblacionales, indispensables para el cálculo de la razón de verosimilitud, así como la naturaleza del propio idiolecto, hacen aún muy difícil la aplicación de escalas bayesianas (Gold y French, 2011: 6; Coulthard, Johnson y Wright, 2017: 198-206). Y esa es la opción que proponemos para los estudios de atribución de autoría en el campo literario, al menos hasta que las escalas estadísticas se conviertan en una opción factible.

En la siguiente tabla ofrecemos una propuesta para expresar las conclusiones en el marco de los estudios de autoría literaria, que podría adaptarse a cada caso concreto. Como puede verse, esta escala de opinión verbal permite encuadrar las conclusiones alcanzadas para cada una de las hipótesis posibles (sí/no) dentro de seis grados de probabilidad, así como, dado el caso, declarar la imposibilidad de establecer una conclusión (no concluyente) (Tabla 5). Se destierran así las conclusiones categóricas (sí/no), que no cumplen con el principio de probabilidad, y las que, sin llegar a serlo, (probablemente es, parece que no es, etc.) no se circunscriben a una graduación que permita cuantificar dicha posibilidad. De igual modo, ofrecemos un listado de criterios —inspirados en los de McMenamin, aunque con matizaciones— para determinar los distintos niveles, tratando así de objetivar al máximo la escala propuesta (Tabla 6). Estos criterios tienen en cuenta las similitudes y disimilitudes derivadas del proceso de comparación textual entre el texto dubitado y los indubitados, pero, también, los posibles problemas derivados de las características de las muestras (calidad, extensión, datación, temática o tipología textual) o de la mayor o menor presencia de variables idiosincrásicas.

Escala de opinión verbal para los estudios de atribución de autoría literaria	
Se puede determinar que X sí es el autor de esta obra, con un grado de probabilidad	(5) muy alto (4) bastante alto (3) alto (2) bajo (1) bastante bajo (0) muy bajo
Se puede determinar que X no es el autor de esta obra, con un grado de probabilidad	(0) muy bajo (-1) bastante bajo (-2) bajo (-3) alto (-4) bastante alto (-5) muy alto
No se puede determinar que X sí es o no es el autor de esta obra	No concluyente

Tabla 5. Escala de opinión verbal para los estudios de atribución de autoría literaria.
Fuente: Elaboración propia.

Criterios de valoración		
Sí	<ol style="list-style-type: none"> 1. Hay similitudes sustanciales. 2. No hay disimilitudes significativas. 3. No hay limitaciones relacionadas con las características de las muestras textuales o con la no ocurrencia de variables idiosincrásicas. 	5
Sí	<ol style="list-style-type: none"> 1. Hay similitudes sustanciales. 2. No hay disimilitudes significativas. 3. Hay limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas. 	4
Sí	<ol style="list-style-type: none"> 1. Hay bastantes similitudes sustanciales. 2. No hay disimilitudes significativas. 3. Hay limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas. 	3
Sí	<ol style="list-style-type: none"> 1. Hay algunas similitudes sustanciales. 2. No hay disimilitudes significativas. 3. Hay limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas. 	2
Sí	<ol style="list-style-type: none"> 1. Hay pocas similitudes sustanciales. 2. No hay disimilitudes significativas. 3. Puede haber limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas. 	1
Sí	<ol style="list-style-type: none"> 1. Hay muy pocas similitudes sustanciales. 2. No hay disimilitudes significativas. 3. Puede haber limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas. 	0

NO	1. No hay similitudes sustanciales. 2. Hay muy pocas disimilitudes significativas. 3. Puede haber limitaciones relacionadas con las características de las muestras textuales o con la no ocurrencia de variables idiosincrásicas.	0
	1. No hay similitudes sustanciales. 2. Hay pocas disimilitudes significativas. 3. Puede haber limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas.	-1
	1. No hay similitudes sustanciales. 2. Hay algunas disimilitudes significativas. 3. Puede haber limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas.	-2
	1. No hay similitudes sustanciales. 2. Hay bastantes disimilitudes significativas. 3. Hay limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas.	-3
	1. No hay similitudes sustanciales. 2. Hay disimilitudes significativas. 3. Hay limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas.	-4
	1. No hay similitudes sustanciales. 2. Hay disimilitudes significativas. 3. No hay limitaciones relacionadas con las características de las muestras textuales o con la no ocurrencia de variables idiosincrásicas.	-5
¿?	1. Las similitudes sustanciales son insuficientes 2. Las disimilitudes sustanciales son insuficientes 3. Puede haber limitaciones relacionadas con las características de las muestras o con la no ocurrencia de variables idiosincrásicas.	No concluyente

Tabla 6. Criterios de valoración para cada uno de los niveles de la escala de opinión verbal.
Fuente: Elaboración propia.

Para que puedan entenderse la escala y los criterios propuestos, vamos a tomar como ejemplo el caso concreto del *Entremés famoso de los romances*, publicado por primera vez en la *Parte tercera de las comedias de Lope de Vega y otros autores* (Valencia, 1611) y atribuido tradicionalmente a Miguel de Cervantes por sus similitudes temático-argumentales con los primeros capítulos del *Quijote*. El estudio de autoría realizado, basado en el análisis cualitativo y cuantitativo de diferentes variables lingüísticas, que afectan a distintos planos de la lengua, nos lleva a establecer que no hay similitudes sustanciales ni disimilitudes significativas entre el idiolecto de esta pieza y el cervantino, especialmente en las obras de su mismo género; no obstante, a la hora de establecer el grado de probabilidad de esa *desatribución*, debemos tener en consideración que se trata de una pieza de corta extensión —más aún al eliminar todos los romances de autoría ajena que plagan el texto— cuya calidad, muy probablemente, se haya visto afectada por el complejo proceso de transmisión y fijación textual del teatro del Siglo de Oro español. Por eso, teniendo en cuenta tanto los resultados del estudio como las limitaciones del texto, podemos concluir, en base a la escala y los criterios propuestos, que Cervantes no

es el autor de esta obra, con un grado de probabilidad bastante alto (nivel -4, dentro de una escala de *desatribución* que va del 0 al -5) (Ruiz Urbón, 2023).

4. CONCLUSIONES

Aunque la lingüística forense ha dado pasos de gigante en el establecimiento de unos principios atributivos eficaces y fiables, los estudios literarios no parecen avanzar al mismo ritmo, a pesar de que su preocupación por el anonimato sea la misma. Por eso, en este trabajo, defendemos la necesidad de aplicar los principios rectores (teóricos, metodológicos y conclusivos) del llamado *lenguaje evidencial* de la lingüística forense a los estudios de atribución de autoría literaria, con el objetivo de dotarlos de mayor precisión, objetividad y fiabilidad.

El principio teórico fundamental que sustenta los estudios de autoría en el ámbito forense es la existencia del idiolecto, es decir, una versión personal, marcada y distintiva de la lengua, que nos define y diferencia de los demás. Dicha versión, conformada por multitud de rasgos lingüísticos, puede cambiar ligeramente a lo largo del tiempo y adaptarse a las diferentes circunstancias comunicativas, pero, aun así, la variación intrapersonal será menor que la interpersonal. Es por ello por lo que el idiolecto puede usarse como evidencia lingüística para discriminar autorías, pero también para datar la obra de un determinado autor o descubrir diferentes momentos de escritura.

La metodología desarrollada por la lingüística forense, basada en el principio de certeza, comprende el análisis comparado de las distintas muestras lingüísticas, teniendo en consideración las posibles limitaciones derivadas de su calidad, extensión, datación, temática o tipología textual. Esta metodología, que abarca los distintos niveles de la lengua, recomienda la combinación de técnicas cualitativas y cuantitativas, para poder ofrecer resultados objetivos y replicables sin renunciar por ello a la riqueza interpretativa y la profundidad de significados que aporta la observación directa (metodología mixta). Nunca la coincidencia o disimilitud de un solo rasgo lingüístico podrá usarse como prueba irrefutable para atribuir o *desatribuir* una obra a un determinado autor.

La expresión de las conclusiones es otro de los elementos clave de la lingüística forense (del que, hasta el momento, adolecían los estudios literarios). Todo esfuerzo teórico y metodológico es insuficiente si el investigador no es capaz de ofrecer unos resultados ecuanímenes, que todos los receptores sean capaces de interpretar de igual modo, en base al principio de probabilidad de la criminalística moderna. En el ámbito forense de la atribución de autoría se trabaja con escalas de opinión verbal, en las que se recogen los distintos niveles de probabilidad dentro de los que puede enmarcarse el resultado global; además, de un tiempo a esta parte, se están empezando a desarrollar escalas bayesianas, aunque la falta de estudios poblacionales, indispensables para el cálculo de la razón de verosimilitud, hace aún muy difícil su aplicación práctica. Por este motivo, proponemos una escala de opinión verbal para los estudios de atribución de autoría literaria, que represente los seis grados de probabilidad de las dos hipótesis posibles

(sí/no), así como la imposibilidad de llegar a alguna de ellas (resultado no concluyente) (Tabla 5); y un listado de criterios que permitan objetivar dichos niveles, para imposibilitar que dos investigadores diferentes pudieran adjudicar distintas probabilidades ante unos mismos resultados (Tabla 6).

REFERENCIAS BIBLIOGRÁFICAS

- ABBASI, A. & CHEN, H. (2008). "Writeprints: A Atylometric Approach to Identity-Level Identification and Aimilarity Detection in Cyberspace". *ACM Transactions on Information Systems* 26.2, 1-29.
- ARGAMON, S. & LEVITAN, S. (2005). "Measuring the Usefulness of Function Words for Authorship Attribution". En *Proceedings of ACH / ALLC 2005*, Association for Computing and the Humanities (ed.), 1-3. Victoria, CB: University of Victoria.
- BAAYEN, R. H.; VAN HALTEREN, H. & TWEEDIE, F. J. (1996). "Outside the Cave of Shadows: Using Syntactic Annotation to Enhance Authorship Attribution". *Literary and Linguistic Computing* 11.3, 121-131.
- BALDWIN, J. (1979). "Phonetics and Speaker Identification". *Medicine, Science and the Law* 19, 231-232.
- BARTHES, R. (1977). *Elements of Semiology*. New York: Hill & Wang.
- BLASCO, J. (2022). "La 'boutade' de la muerte del autor: el caso de Carmen Mola". *Anales de la Literatura Española Contemporánea* 3, 249-266.
- BLASCO, J. Y RUIZ URBÓN, C. (2009). "Evaluación y cuantificación de algunas técnicas de 'Atribución de autoría' en textos españoles". *Castilla. Estudios de Literatura* 0, 27-47.
- BROEDERS, A. P. A. (1999). "Some Observations on the Use of Probability Scales in Forensic Identification". *Forensic Linguistics* 6.2, 228-41.
- BROWN, R. (1982). "What is Speaker Recognition". *Journal of the International Phonetics Association* 12.1, 13-24.
- BURRIDGE, K. & MULDER, J. (1988). *English in Australia and New Zealand: An Introduction to its Structure, History and Use*. Melbourne: Oxford University Press.
- BURROWS, J. F. (1989). "'An Ocean Where Each Kind': Statistical Analysis and Some Major Determinants of Literary Style". *Computers and the Humanities* 23.4/5, 309-21.
- ____ (2002). "'Delta': A Measure of Stylistic Difference and a Guide to Likely Authorship". *Literary and Linguistic Computing* 17.3, 267-287.
- ____ (2003). "Questions of Authorship: Attribution and Beyond". *Computers and the Humanities* 37.1, 5-32.

- CELMA VALERO, M.^a P. Y RUIZ URBÓN, C. (2022). “Una aproximación a la escritura de Miguel Delibes desde la estilometría”. *Tonos Digital. Revista de Estudios Filológicos* 41, 1-13.
- CHAMPOD, C. & EVETT, I. W. (2000). “Commentary on A. P. A. Broeders (1999) ‘Some Observations on the Use of Probability Scales in Forensic Identification’”. *Forensic Linguistics* 6.2, 228-41”. *Forensic Linguistics* 7.2, 238-234.
- CICRES, J. & GAVALDÀ, N. (2014). “La Lingüística Forense: La Llengua com a Evidència”. *Revista de Llengua i Dret* 61, 60-71.
- COULTHARD, M. (1998). “Identifying the Author”. *Cahiers de Linguistique Française* 20, 139-161.
- ____ (2005a). “The Linguistic as Expert Witness”. *Linguistics and the Human Sciences* 1.1, 39-58.
- ____ (2005b). “Some forensic applications of descriptive linguistics”. *Veredas* 9, 9-28.
- COULTHARD, M. & JOHNSON, A. (2010). *The Routledge Handbook of Forensic Linguistics*. Oxford: Routledge.
- COULTHARD, M.; JOHNSON, A. & WRIGHT, D. (2017). *An Introduction to Forensic Linguistics: Language in Evidence*. London / New York: Routledge.
- CRYSTAL, D. (2008). *“Think on my Words”: Exploring Shakespeare’s Language*. Cambridge: Cambridge University Press.
- CUÉLLAR, Á. (2023). “Cronología y estilometría: datación automática de comedias de Lope de Vega”. *Anuario Lope de Vega: Texto, Literatura, Cultura* 29, 97-130.
- DELGADO ROMERO, C. (2005). “Comentarios sobre el contexto actual de la identificación forense de locutores”. En *Lingüística forense. Lengua y derecho. Conceptos, métodos y aplicaciones*, M. Teresa Turell (ed.), 113-129. Barcelona: Institut Universitari de Lingüística Aplicada.
- EADES, D. (1994). “Forensic linguistics in Australia: an overview”. *Forensic Linguistics* 1.2, 113-32.
- EVETT, I. W. & WEIR, B. S. (1998). *Interpreting DNA Evidence. Statistical Genetics for Forensic Scientists*. Sunderland: Sinauer Associates.
- FEIGUINA, O. & HIRST, G. (2007). “Authorship Attribution for Small Texts: Literary and Forensic Experiments”. *International Workshop on Plagiarism Analysis, Authorship Identification, and Near-Duplicate Detection, 30th Annual Internacional ACM SIGIR Conference (SIGIR '07)*. Disponible en línea: <http://ceur-ws.org/Vol-276/paper3.pdf> [21/12/2023].
- FERNÁNDEZ TRILLO, J. J. (2015). *La problemática autoría de Carlos Castaneda. Un estudio estilométrico de “candidato único”*. Tesis doctoral: Universidad Autónoma de Madrid. Disponible en línea en: <https://repositorio.uam.es/handle/10486/666725> [20/12/2023].
- FOSTER, D. (2000). *Author Unknown. On the Trail of Anonymous*. New York: Henry Holt and Company.

- FRENCH, P. & HARRISON, P. (2007). "Position Statement Concerning Use of Impressionistic Likelihood Terms in Forensic Speaker Comparison Cases". *The International Journal of Speech, Language and the Law* 14. 1, 137-144.
- GAINS, J. (1999). "Electronic Mail. A New Style of Communication or Just a New Medium? An Investigation into the Text Features of e-mail". *English for Specific Purposes* 18.1, 81-101.
- GARAYZÁBAL HEINZE, E; QUERALT, S. Y REIGOSA RIVEIROS, M. (2019). *Fundamentos de la Lingüística Forense*. Madrid: Síntesis.
- GARCÍA REIDY, A. (2019). "Deconstructing the Authorship of *Siempre ayuda la verdad: A Play by Lope de Vega?*". *Neophilologus* 103, 493-510.
- GIBBONS, J. & TURELL, M. T. (2008). *Dimensions of Forensic Linguistics*. Amsterdam / Philadelphia: John Benjamins Publishing Company.
- GOLD, E. & FRENCH, P. (2011). "International Practices in Forensic Speaker Comparison". *The International Journal of Speech, Language and the Law*, 18.2, 293-307.
- GRIEVE, J. (2007). "Quantitative Authorship Attribution: An Evaluation of Techniques". *Literary and Linguistic Computing* 22.3, 251-270.
- HOLMES, D. I. (1998). "The Evolution of Stylometry in Humanities Scholarship". *Literary and Linguistic Computing* 13.3, 111-117.
- HOLMES, D. I. & FORSYTH, R. S. (1995). "The Federalist Revisited: New Directions in Authorship Attribution". *Literary and Linguistic Computing* 10.2, 111-127.
- HOOVER, D. L. (2004a). "Frequent Collocations and Authorial Style". *Literary and Linguistic Computing* 18.3, 261-228.
- ____ (2004b). "Testing Burrows's Delta". *Literary and Linguistic Computing* 19.4, 453-475.
- JAKOBSON, R. (1975). *Ensayos de Lingüística General*. Barcelona: Seix Barral.
- JEFFRIES, L. & MCINTYRE, D. (2010). *Stylistics*. Cambridge: Cambridge University Press.
- JOCKERS, M. & WITTEN, D. M. (2010). "A Comparative Study of Machine Learning Methods for Authorship Attribution". *Literary and Linguistic Computing* 25.2, 215-523.
- JOHNSTONE, B. (1996). *The Linguistic Individual. Self-Expression in Language and Linguistics*. New York: Oxford University Press.
- JUOLA, P. (2006). "Authorship Attribution". *Information Retrieval* 1.3, 233-334.
- ____ (2008). *Authorship Attribution*. Hanover: Now Publishers.
- KOPPEL, M.; SCHLER, J & BONCHEK-DOKOW, E. (2007). "Measuring Differentiability: Unmasking Pseudonymous authors". *Journal of Machine Learning Research* 8, 1261-1276.
- KOPPEL, M.; SCHLER, J. & ARGAMON, S. (2009). "Computational Methods in Authorship Attribution". *Journal of the American Society for Information Science and Technology* 60.1, 9-26.

- LABOV, W. (1966). *The Social Stratification of English in New York City*. Washington D.C.: Center for Applied Linguistics.
- ____ (1972). *Sociolinguistic Patterns*. Philadelphia. Pennsylvania: Pennsylvania University Press.
- LEONARD, R. A. (2006). "Forensic Linguistics: Applying the Scientific Principles of Language Analysis to Issues of the Law". *International Journal of the Humanities* 3.7, 65-70.
- LEVI, J. N. (1994). "Language as Evidence: The Linguist as Expert Witness in North American Courts". *The International Journal of Speech, Language and the Law* 1.1, 1-26.
- LOVE, H. (2002). *Attributing Authorship: An Introduction*. Cambridge: Cambridge University Press.
- LUYCKX, K. (2010). *Scalability Issues in Authorship Attribution*. Brussels: University Press Antwerp.
- MANNION, D. & DIXON, P. (1997). "Authorship Attribution: The Case of Oliver Goldsmith". *The Statistician* 46.1, 1-18.
- MCMENAMIN, G. R. (2002). *Forensic Linguistics: Advances in Forensic Stylistics*. London / New York: CRC Press.
- ____ (2017). *Introducción a la Lingüística Forense. Un libro de curso*. Fresno: The Press at California State University.
- MOSTELLER, F. & WALLACE, D. L. (1964). *Inference and Disputed Authorship: The Federalist*. New York: Springer-Verlag.
- PHILBRICK, F. A. (1949). *Language and the Law. The Semantics of Forensic English*. New York: The MacMillan Company.
- ROSE, P. & MORRISON, G. S. (2009). "A Response to the UK Position Statement on Forensic Speaker Comparison". *The International Journal of Speech, Language and the Law* 16.1, 139-163.
- RUDMAN, J. (1998). "The State of Authorship Attribution Studies: Some Problems and Solutions". *Computers and the Humanities* 31, 351-365.
- RUIZ URBÓN, C. (2023). "Nuevas pruebas estilométricas para negar la autoría cervantina del *Entremés de los romances*". *Studia Aurea. Revista de Literatura Española y Teoría Literaria del Renacimiento y Siglo de Oro* 17, 545-583.
- SANDERSON, C. & GUENTER, S. (2006). "Short Text Authorship Attribution via Sequence Kernels, Markov Chains and Author Unmasking: An Investigation". *Proceedings of the 2006 Conference on Empirical Methods in Natural Language Processing (EMNLP 2006)*, 482-491.
- SAVOY, J. (2020). *Machine Learning Methods for Stylometry. Authorship Attribution and Author Profiling*. Cham: Springer.
- SHUY, R. W. (1993). *Language Crimes: The Use and Abuse of Language Evidence in the Courtroom*. Cambridge, MA: Blackwell.

- SPASSOVA, M. (2009). *El potencial discriminatorio de las secuencias de categorías gramaticales en la atribución forense de autoría de textos en español*. Tesis doctoral: Universitat Pompeu Fabra. Disponible en línea: <https://repositori.upf.edu/handle/10230/12285> [20/12/2023].
- STAMATATOS, E. (2009). "A Survey of Modern Authorship Attribution Methods". *Journal of the American Society for Information Science and Technology* 60, 538-556.
- STAMATATOS, E.; FAKOTAKIS, N. & KOKKINAKIS, G. (2001). "Computer-Based Authorship Attribution Without Lexical Measures". *Computers and the Humanities* 35.2, 193-214.
- SVARTVIK, J. (1968). *The Evans Statements: A Case for Forensic Linguistics*. Göteborg: University of Gothenburg Press.
- TURELL, M. T. (2011). "La tasca del lingüista detectiu en casos de detecció de plagi i determinació d'autoria de textos escrits". *Llengua, Societat i Comunicació* 9, 67-83.
- WOOLLS, D. (2003). "Better Tools for the Trade and How to Use Them". *The International Journal of Speech, Language and Law* 10.1, 102-112.
- WOOLLS, D. & COULTHARD, M. (1998). "Tools for the Trade". *The International Journal of Speech, Language and Law* 5.1, 33-57.
- WRIGHT, D. (2013). "Stylistic Variation Within Genre Conventions in the Enron Email Corpus". *The International Journal of Speech, Language and the Law* 20.1, 45-75.



This work is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND).

Fecha de recepción: 15/01/2024

Fecha de aceptación: 24/05/2024