

Derecho y Econometría

Autor: Enrique A. Bour (Universidad de Buenos Aires, FIEL)

Resumen

Economía y Derecho alcanzó un nivel de desarrollo sustancial en los últimos años, lo que llevó a un creciente nivel de sofisticación de estudios jurídicos y a mayores exigencias científicas tanto por parte de demandados como de demandantes. La tesis del documento es que esta evolución exigirá la utilización de instrumentos estadísticos y econométricos. Luego de analizarse el analfabetismo matemático-estadístico existente en la justicia – un hecho que trasciende las fronteras de nuestro país – el autor ilustra en forma sencilla la teoría econométrica aplicable con ejemplos de casos prácticos de la justicia de Estados Unidos, mediante notas a pie de página.

Clasificación JEL: K0 – Derecho y Economía – General

Agosto 12, 2010

Derecho y Econometría¹

Los campos de la Economía y el Derecho están íntimamente ligados y mantienen una interacción constante entre sí. Conviene diferenciar al análisis económico del derecho de una disciplina que a veces puede confundir, el derecho económico. El *Derecho económico* es el conjunto de principios y de normas de diversas jerarquías, sustancialmente de Derecho público, que inscriptas en un orden público económico plasmado en la carta fundamental, facultan al Estado para planear indicativa o imperativamente el desarrollo económico y social de un país y regular la cooperación humana en las actividades de creación, distribución, intercambio y consumo de la riqueza generada por el sistema económico. Define el papel que tiene el Derecho (entendido en este caso como sistema jurídico) en la regulación de la actividad económica. Este marco legal establece "reglas del juego" neutrales para los actores económicos, abarcando las transacciones bursátiles, la auditoría de negocios, las leyes referentes a la economía (leyes monetarias, por ejemplo), y en general todas las actividades comerciales y de funcionamiento de los mercados. Asimismo, cabe notar que el hecho de ejercer influencia en la esfera económica le da al derecho un carácter multidisciplinario, amplía notablemente su campo de acción y produce un distanciamiento de la antigua tradición europea. Por su parte, el *Análisis Económico del Derecho* busca identificar los efectos que las reglas legales tienen sobre la conducta de los actores relevantes determinando de ese modo cuáles efectos son los deseables desde el punto de vista social (eficiencia). En general, la conducta de individuos y empresas es descripta basándose en el supuesto de que son previsores y racionales, y se adopta la estructura de la economía del bienestar para evaluar la deseabilidad social de los resultados. Entre ambos enfoques existe una relación de *dualidad*².

El *análisis de regresión múltiple* es un instrumento para apreciar la relación entre dos o más variables. Implica una variable explicada – la *variable dependiente* – y variables adicionales (*independientes*) que producen o están asociadas con los cambios de la variable dependiente³.

2

¹ Este documento es el capítulo IV de un libro *Derecho y Economía Científico e Introducción a la Estadística y la Econometría Básicas* (2010), usado en una Maestría en Derecho y Economía de la UBA. Se ha puesto énfasis, por consiguiente, en los aspectos didácticos para graduados sin formación previa en estadística.

² El teorema de dualidad de la programación es utilizado en diversos campos de la teoría económica. Es sabido que la optimización bajo condiciones juega un rol central en economía: por ejemplo, el problema de elección de un consumidor suele ser formulado como la maximización de una función de utilidad sujeta a una restricción de presupuesto; el multiplicador de Lagrange es interpretado como el "precio sombra" asociado a la restricción (en este caso se denomina la "utilidad marginal del ingreso"). El mismo problema puede ser interpretado como de minimización del gasto total bajo una restricción de utilidad dada. Al proponer al teorema de dualidad en semejante función de distinción entre el análisis económico del derecho y el derecho económico, trato de interpretar los términos de la comunicación del Prof. Julio H. G. Olivera, La Doble Intersección de la economía con el derecho, en la Jornada de Homenaje a Alfredo Juan Canavese, Univ. T. Di Tella, 16 de Abril de 2010. Dadas las "reglas del juego" fijadas por el Derecho Económico, el teorema de dualidad permite examinar el problema dual de minimizar las distorsiones a que da lugar, contribuyendo a maximizar la riqueza. En su prefacio al libro de E.D Nering y A.W. Tucker, 1993, *Linear Programming and Related Problems* (Academic Press, Boston, MA) George B. Dantzig dijo que este teorema fue una conjetura de John von Neumann que sólo fue demostrada más adelante por Albert W. Tucker y su grupo y, en forma independiente, por el propio Dantzig. Por otra parte, es sabido que Richard Posner ha sostenido enfáticamente que, si hay costos de transacción inevitables (es decir, no atribuibles al derecho) que impiden el logro de un resultado completamente eficiente mediante negociación privada, alguna asignación particular inicial de los derechos de propiedad puede conducir a un resultado más próximo a la eficiencia que otras. Implicancia: *Si se reconoce que existen costos de transacción inevitables, el derecho debe elegir la más eficiente asignación de derechos de propiedad.*

³ Por razones de sencillez, *en este ensayo se entenderá por técnicas econométricas a las técnicas de regresión múltiple.* Cabe mencionar que previamente a este capítulo, los alumnos de la maestría han estudiado en forma intensa conceptos estadísticos.

Por ejemplo, mediante un análisis de regresión múltiple es posible estimar el efecto que la cantidad de años trabajados ejerce sobre el salario. El salario sería la variable dependiente a ser explicada; los años de experiencia la variable explicativa. El análisis de regresión múltiple muchas veces es apropiado para analizar datos entre teorías competitivas entre sí, cuando hay varias explicaciones posibles de las relaciones entre cierto número de variables explicativas⁴. Es típico que el análisis de regresión múltiple use una única variable dependiente y varias variables independientes a fin de evaluar los datos estadísticos pertinentes. Por ejemplo, en un caso en el que se alega discriminación sexual en el salario, un análisis de regresión múltiple examinaría no sólo el sexo, sino también otras variables de interés, como la educación y la experiencia⁵. El empleador-defensor podría usar el análisis de regresión múltiple para sostener que el salario es función de la educación y experiencia del empleado – y el acusador podría sostener que el salario también depende del sexo del individuo.

El análisis de regresión múltiple es un instrumento que permite hacer estimaciones precisas y cuantitativas de los efectos de alguna variable interesante. Se trata de una nueva herramienta, cuyos orígenes se remontan 200 años atrás al matemático Carl Friedrich Gauss, pero que se ha desarrollado sobremanera en los últimos 55 años aproximadamente. Este crecimiento se ha debido al desarrollo de las técnicas estadísticas modernas, a la creciente disponibilidad de datos “decentes”, y por encima de todo, al desarrollo de la computación. Ha habido un uso creciente de regresión múltiple y de técnicas vinculadas en conexión con procesos legales de distinta índole, si bien los jueces y los abogados tuvieron una tendencia a ver a estos instrumentos con desconfianza general (y a veces con sana desconfianza).

Ejemplo Puede afirmarse que una de las primeras aplicaciones de la economía al derecho fue en el contexto de los casos antimonopolio. De interés especial para este trabajo es el artículo escrito por Franklin Fisher conjuntamente con Daniel Rubinfeld, *U.S. v. Microsoft – An Economic Analysis*. En ese proceso antimonopolístico, Fisher fue uno de los expertos por el gobierno, actuando en calidad de testigo, mientras que Rubinfeld actuó como economista jefe de la división antimonopolios; su posición consistió en que a) Microsoft alcanzó poder monopolístico en el mercado de sistemas operativos para computadoras personales compatibles con Intel; b) Microsoft anticipó la posibilidad de que su sistema operativo Windows fuera erosionado por los exploradores de Internet y por la plataforma




Franklin M. Fisher

⁴ El análisis de regresión múltiple sólo es un tipo de análisis que involucra a diversas variables. Otros son: el análisis de estratificación, el análisis de la varianza, los análisis probit y logit, el análisis discriminante y el análisis factorial.

⁵ Así se tiene que en [Ottaviani v. State University of New York, 875 F.2d 365, 367 \(2d Cir. 1989\)](#) (citations omitted), cert. denied, 493 U.S. 1021 (1990), la corte estableció que: “En casos dispares que involucran denuncias por discriminación de género, los demandantes usan típicamente el análisis de regresión múltiple para aislar la influencia del género sobre las decisiones de empleo relacionadas con una cierta ocupación o beneficio de dicha ocupación, como un salario. El primer paso del análisis de regresión consiste en especificar todos los factores “legítimos” (es decir, no discriminatorios) que es probable que afecten a la variable dependiente y que podrían dar cuenta de la disparidad en el tratamiento entre varones y mujeres. Al identificar estos criterios legítimos que afectan el proceso de decisión, los demandantes individuales pueden hacer predicciones acerca de qué trabajo o beneficios laborales recibirían empleados situados de forma similar, y entonces medir la diferencia entre el tratamiento predicho y el tratamiento real de esos empleados. Si existe una disparidad entre los resultados predichos y reales de las empleadas mujeres, las demandantes de un caso de trato dispar pueden argumentar que la diferencia neta “residual” representa el efecto ilegal de un intento discriminatorio de asignación del trabajo o de los beneficios laborales”.

de Java, ambos capaces de soportar aplicaciones de software independientes del sistema operativo; c) Microsoft adoptó acciones anticompetitivas (que resultaron exitosas) para impedir la competencia en exploradores de Internet con el fin de proteger su dominación de su sistema operativo Windows; d) también adoptó acciones anticompetitivas para restringir la disponibilidad de la plataforma tecnológica de Java con el fin de proteger su posición dominante de su sistema operativo Windows. Además, llevó adelante una campaña de avisos y solicitadas anticompetitivas con el objeto de convencer a otras empresas de que no compitieran con Microsoft en materia de software de plataforma; e) Microsoft utilizó su poder de monopolio en el segmento de los sistemas operativos de las computadoras personales (PCs) a fin de distorsionar la competencia en los exploradores de Internet; f) la conducta de Microsoft, que intentó mantener y aumentar las barreras a la entrada en el mercado de sistemas operativos de PCs, incluyó: 1) vincular su explorador con el sistema operativo (lo que significaba que los vendedores debían adquirir el sistema del explorador de internet de Microsoft como condición necesaria para adquirir el sistema operativo Windows de Microsoft), obstaculizando así en forma severa la competencia de Netscape y limitando la amenaza de que los desarrolladores de software terminaran preparando otro explorador fuera del control de Microsoft, y 2) excluir a sus competidores de utilizar los canales de distribución más eficientes. En resumen, se trató de una acción antimonopolística que, de no remediarse, daría lugar a un entorno en el cual las plataformas que no usaran un estándar Microsoft no prosperarían, perdiéndose una ‘oportunidad crítica’ de innovación que reduzca o elimine el poder de Microsoft.

Microsoft se defendió con energía argumentando que todos sus intentos de “innovación” estaban siendo atacados por las empresas rivales celosas de su éxito, y que el litigio gubernamental era meramente un títere. Una publicidad a plena página en The Washington Post y en The New York Times del 2 de junio de 1999 por el Independent Institute entregó una “Carta Abierta al presidente Clinton de 240 economistas sobre el proteccionismo antimonopolístico”. En una parte decía que *a los consumidores no les interesaban estas acciones antimonopolísticas – sino a las empresas rivales. Los consumidores de alta tecnología habían disfrutado de precios en baja, producción en alza, y de una impresionante colección de nuevos productos e innovaciones... Pero, crecientemente, algunas empresas estaban buscando imponer trabas a sus rivales tratando que el gobierno las protegiera. Muchos de estos casos están basados en daños vagamente especificados a los consumidores en algún momento no especificado futuro, y hay varias intervenciones gubernamentales que debilitarán a las empresas exitosas de Estados Unidos al impedir que sean competitivas en otras partes del mundo*” ([Open Letter on Antitrust Protectionism](#), por el Independent Institute, June 2, 1999). El juez Jackson estableció los hechos el 5 de noviembre de 1999, afirmando que la dominación por Microsoft del mercado de sistemas operativos basados en x86 de las PCs constituía un monopolio, y que Microsoft había encarado acciones destinadas a aplastar toda amenaza a ese monopolio, incluyendo a Apple, Java, Netscape, Lotus Notes, Real Networks, Linux, y otros. El 3 de abril de 2000 emitió una sentencia de dos partes: sus conclusiones legales eran que Microsoft era un monopolio, y que Microsoft así lo había intentado, en violación de las secciones 1 y 2 de la Sherman Act, por cuyo motivo el remedio era que Microsoft debía ser separada en dos unidades independientes, una para producir el sistema operativo, y la otra para producir otros componentes de software.



Richard L. Schmalensee

El juicio también fue notorio porque tanto la procuraduría y la defensa utilizaron como testigos expertos a profesores del MIT a fin de sostener sus casos. Richard L. Schmalensee, un notable economista y decano de la Escuela Sloan de Administración del MIT, testificó como experto a favor de Microsoft, mientras que por la otra parte, como hemos visto, Franklin Fisher, que había sido consejero de tesis doctoral de Schmalensee en el MIT, testificó a favor del Departamento de Justicia, conjuntamente con Daniel L. Rubinfeld. Este fallo fue apelado, y finalmente el DOJ anunció el 6 de setiembre de 2001 que ya no se buscaría la separación de Microsoft, y que, en su lugar, se aplicaría una penalidad antimonopolio de menor envergadura. El 2 de noviembre de 2001 el DOJ alcanzó un acuerdo con Microsoft. El acuerdo propuesto requería que Microsoft compartiera sus interfaces de programación aplicada con terceras empresas y que designara un panel de tres personas con pleno acceso a los sistemas, registros y códigos fuente de Microsoft por el término de 5 años a fin de asegurar su cumplimiento. Empero, el DOJ no le exigió a Microsoft cambiar ningún código ni le impidió que atara otro software con Windows en el futuro. El 5 de agosto de 2002 Microsoft anunció que haría ciertas concesiones en pro del acuerdo final, a la espera del veredicto del juez. El 1º de noviembre de 2002 el juez Kollar-Kotelly emitió una sentencia aceptando una parte sustancial del acuerdo propuesto por el DOJ. Hubo 9 estados y el distrito de Columbia que no aceptaron el acuerdo, sosteniendo que no era lo suficientemente severo como para frenar las prácticas comerciales anticompetitivas de Microsoft. Sin embargo, el 30 de junio de 2004 la corte de apelaciones de USA aprobó en forma unánime el acuerdo con el Departamento de Justicia, rechazando las objeciones de que las sanciones eran inadecuadas. Los estados en disenso vieron al acuerdo como un mero tirón de orejas. El experto industrial Robert X. Cringely no cree que sea posible una separación, y que “ahora la única forma en que Microsoft podría morir es si se suicida”. Andrew Chin, un profesor de derecho antimonopolio de la universidad de North Carolina en Chapel Hill, que asistió al juez Jackson en preparar el borrador de los hechos, escribió que el acuerdo le otorgaba a Microsoft “una inmunidad especial en sus licencias de Windows y otras ‘plataformas de software’ bajo términos contractuales que destruyen la libertad de competencia”.

Las obligaciones de Microsoft dentro del acuerdo como fue escrito originalmente, expiraron el 12 de noviembre de 2007. Empero, más tarde Microsoft admitió “una extensión adicional de dos años en los Juicios Finales” referidos a las licencias de protocolos de comunicaciones, y que no plantearía objeciones si los demandantes quisieran extender estos aspectos del acuerdo hasta 2012. Los demandantes dejaron en claro que la extensión pretendía servir sólo para otorgar a la parte relevante del acuerdo “la oportunidad de tener éxito durante el tiempo que cubría ese período”, antes que dar lugar a un “patrón de violaciones intencionadas y sistemáticas”. La crítica a las tácticas de Microsoft, descritas como *abrazar*, *extender* y *ahogar*, implican que Microsoft se apodera de un estándar o producto competitivo, a continuación lo extiende a fin de producir su propia versión que resulta incompatible con el estándar, lo que termina extinguiendo con el correr del tiempo la competencia que no usa o no puede usar la nueva versión de Microsoft. Son estas tácticas las que dieron lugar a juicios llevados adelante por empresas y gobiernos, y miles de millones de dólares en fallos en su contra. David Meyer apuntó que “Microsoft tiene una larga historia de pedir y que se le concedan patentes por inventos que, según mucha gente que a veces puede demostrarlo, estaban basados en ideas comunes y evidentes.” Esto lo dijo en respuesta al pedido de 2008 de patentar una aplicación que permite



Daniel L. Rubinfeld

subir o bajar un incremento de página oprimiendo una sola tecla – que ha sido un método incisivo durante décadas.”⁶

Críticas El premio Nobel de economía Milton Friedman creía que el caso anti-monopolístico en contra de Microsoft establecía un peligroso precedente que presagiaba una creciente regulación gubernamental de una industria que otrora estuvo libre de intrusiones del gobierno y que, en consecuencia, el progreso tecnológico de la industria podría verse trabado⁷. Jean-Louis Gassée, CEO de Be Inc., dijo que en realidad Microsoft no ganaba dinero con el Internet Explorer, y que su incorporación al sistema operativo se debió a las expectativas de los consumidores de tener un navegador presentado dentro de su sistema operativo. Por ejemplo, BeOs viene presentado con su propio navegador, NetPositive, y Mac OS X con Safari. Argumentó que, en cambio, la verdadera influencia anticompeticitiva residía en los descuentos que ofrecía a los fabricantes de equipo original impidiendo a otros sistemas operativos que pudieran afianzarse en el mercado⁸.

Otros casos Volviendo a los usos de la regresión múltiple, ésta también puede ser útil (1) en determinar si está presente un efecto determinado; (2) en medir la magnitud de un efecto determinado; y (3) en proyectar cuál sería el efecto particular ante una intervención dada. En un caso de infracción de patentes, por ejemplo, un análisis de regresión múltiple se podría utilizar para determinar (1) si la conducta del presunto infractor ha afectado el precio del producto patentado, (2) el tamaño del efecto, y (3) lo que el precio del producto hubiera sido si la supuesta infracción no hubiese ocurrido.

Durante las últimas décadas el uso del análisis de regresión múltiple en las cortes de USA ha crecido considerablemente. Aunque el análisis de regresión se ha utilizado con mayor frecuencia en casos de discriminación de sexo y raza y violación de defensa de la competencia, otros casos han sido el estudio de las subestimaciones censales, los derechos de voto, el estudio disuasivo de la pena de muerte, la regulación tarifaria, y la propiedad intelectual. El análisis de regresión múltiple puede ser fuente de un valiosísimo testimonio científico en el ámbito judicial. Pero hay que tener cuidado, ya que el análisis de regresión puede confundir cuestiones importantes que carezcan de valor probatorio. En el caso [EEOC v. Sears, Roebuck & Co.](#), en que Sears era acusado de discriminación sexual en sus prácticas de contratación, el Séptimo Circuito⁹ reconoció que “los análisis de regresión múltiple, que están diseñados a efectos de determinar el efecto de diversas variables independientes sobre una variable dependiente, que es lo que sucede con un contrato, constituyen un método común y aceptado de tratar denuncias dispares”. Pero en este caso, lo que encontró el tribunal fue que “los análisis de regresión de E.E.O.C. no reflejaban el complejo proceso de toma de decisión no discriminatorio de Sears” y que sus análisis eran “tan defectuosos que no eran convincentes”¹⁰. También el análisis de regresión múltiple ha sido cuestionado en cuestiones censales y en casos de pena de muerte. Es importante, al interpretar los resultados de un análisis de regresión múltiple, hacer una distinción entre correlación y causalidad. Cuando dos variables están correlacionadas, los eventos asociados con esas variables suceden más frecuentemente conjuntamente que lo que se puede esperar si la asociación fuera al azar. Pongamos que salarios más altos estén asociados con más años de experiencia, y menores salarios con menos años de experiencia. Pero si los salarios más altos

⁶ David Meyer, “[Microsoft has been granted a patent on 'Page Up' and 'Page Down' keystrokes](#)”, Aug, 2008.

⁷ Milton Friedman, “[The Business Community's Suicidal Impulse](#)”, Cato Policy Report, March/April 1999, Vol. 21, No. 2.

⁸ “[Jean-Louis Gassée on why PC manufacturers don't sell non MS products](#)”, 26 Feb 1999.

⁹ Se trata de uno de los trece circuitos de cortes de apelación de USA, con jurisdicción sobre los distritos de Illinois, Indiana y Wisconsin. Es famoso por tener entre sus miembros a los jueces Easterbrook y Posner.

¹⁰ El tribunal del distrito comentó específicamente “los severos límites del análisis de regresión en evaluar los procesos complejos de decisión”.

están asociados con menos experiencia – y a la inversa, menores salarios lo están con una mayor experiencia – existirá una correlación *negativa* entre ambas variables.

Para decirlo claramente, que dos variables guarden correlación entre sí no implica que una de ellas sea causa de la otra. Por consiguiente, al hacer una *inferencia causal*, es importante evitar las correlaciones *espurias*. Éstas surgen cuando hay dos variables estrechamente vinculadas pero no existe ninguna relación causal entre ambas, porque las dos están causadas por una tercera variable que no ha sido examinada. Un ejemplo popular es el de las estadísticas holandesas que muestran una correlación positiva entre el número de nidos de cigüeñas en distintas primaveras y la cantidad de niños que nacieron en ese momento. Por supuesto, no se trata de una conexión causal; sólo existe correlación entre ambas series porque estaban correlacionadas con la temperatura de los nueve meses previos a las observaciones¹¹. Otro ejemplo: podría haber una correlación negativa entre la edad de algunos empleados cualificados de una empresa de computación y sus salarios. De esta correlación no debería extraerse la conclusión de que el empleador discriminó necesariamente en contra de sus empleados en base a su edad. Existe una tercera variable no examinada, que es la capacidad tecnológica de sus empleados, que podría estar explicando las diferencias de productividad y, por lo tanto, las diferencias de salarios¹². O consideremos un caso de infracción a la ley de patentes en el que las ventas acrecentadas del producto que supuestamente se encuentra en infracción están asociadas con precios más bajos del producto patentado. Esta correlación sería espuria si ambos productos tuvieran nichos de mercado no-competitivos y el menor precio se debiera a una baja del costo de producción del producto patentado. La falacia ha dado lugar a una conocida locución latina, *cum hoc ergo propter hoc* (“con esto, por lo tanto a causa de esto”).

Puntualizar la posibilidad de una correlación espuria no es suficiente para dejar de lado un argumento estadístico, por otra parte. Es apropiado no prestar demasiada atención a un argumento que exhibe una supuesta correlación espuria cualitativa o cuantitativamente sustancial. Por ejemplo, puede ser necesario estimar una relación entre la aptitud tecnológica y la productividad laboral requerida en el ejemplo de discriminación por edad de más arriba¹³. Un punto importante: *la causalidad no solamente puede ser inferida a partir de un análisis de los datos; en realidad, se necesita una teoría que explique la relación entre ambas variables para inferir que existe una relación causal*. Recíprocamente, que dos variables estén correlacionadas entre sí no garantiza que exista una relación; podría ser que el modelo – que representa la teoría causal subyacente – no refleje en forma apropiada el juego conjunto de las variables explicativas. De hecho, hay que recordar que *el que no exista correlación no garantiza que no exista una relación causal*. La falta de correlación podría ocurrir si (1) hay datos insuficientes; (2) los datos están medidos de forma inadecuada; (3) los datos no permiten extraer múltiples relaciones

¹¹ Roger Sapsford, Victor Jupp, ed (2006). Data Collection and Analysis. Sage.

¹² Ver p.ej. [Sheehan v. Daily Racing Form Inc.](#), 104 F.3d 940, 942 (7th Cir.) (en el cual se rechaza la demanda ya que la denuncia de discriminación usando un estudio estadístico correlacionó la edad con la retención ignoró la “remota posibilidad de que la edad esté correlacionada con una calificación legítima del cargo”), denegado, 521 U.S. 1104 (1997).

¹³ Ver, p.ej., [Allen v. Seidman](#), 881 F.2d 375 (7th Cir. 1989) (Se generó escepticismo jurídico cuando el abogado defensor no incorporó una regresión logística que detalló una variable omitida – tener o no un grado superior de educación especial; el ataque del abogado defensor a las comparaciones estadísticas también debe incluir un análisis que demuestre que las comparaciones son engañosas). Los requisitos apropiados para que el abogado defensor exhiba una correlación espuria podrían depender, en general, del proceso de descubrimiento. P.ej., ver [Boykin v. Georgia Pac. Co.](#), 706 F.2d 1384 (1983) (crítica del análisis del demandante por no incluir factores omitidos, cuando el demandante consideraba que toda la información de un formulario era inadecuada).

causales; o (4) el modelo ha sido incorrectamente especificado a causa de que fue omitida una o más variables vinculadas con la variable de interés.

Siempre hay tensión entre cualquier intento de alcanzar conclusiones de gran nitidez y la naturaleza inherentemente probabilística de un análisis de regresión múltiple. En general, el análisis estadístico implica la expresión formal de la incertidumbre en términos de probabilidades. La realidad de que el análisis estadístico genera probabilidades que son en sí relaciones, no debería considerarse como un argumento en contra de la evidencia estadística. La única alternativa que quedaría a mano sería la menos confiable evidencia anecdótica.

Sumario En este trabajo, luego de revisar el estado del saber matemático-estadístico en el ámbito de los tribunales de USA – que es donde creció *Law & Economics* --, introduciremos el problema estadístico del ajuste de funciones a observaciones dadas, y analizaremos ciertos temas de procedimiento y cuestiones metodológicas que tienen que ver con la admisibilidad y la ponderación que debería acordarse a los resultados obtenidos mediante análisis de regresión múltiple. También se revisarán algunos estándares de información y análisis que un experto en esa materia debería seguir, y se pasará revista al diseño de investigación – esto es, de qué manera el análisis de regresión múltiple puede ser utilizado para elegir entre teorías alternativas de un caso dado. Luego nos concentraremos en la cuestión de cómo interpretar los resultados, tanto desde un punto de vista estadístico como práctico. Se discutirá brevemente la calificación de los expertos. A continuación nos dedicaremos a los aspectos que están vinculados con el uso de los datos. Un libro de base es la obra de Robert S. Pindyck y Daniel L. Rubinfeld, *Econometric Models and Economic Forecasts*, McGraw-Hill International Edition, 4thed., 1998. Para el abogado interesado, es importante la lectura del Reference Manual on Scientific Evidence, 2nd ed., del Federal Judicial Center (2000)

1. El analfabetismo matemático-estadístico en la justicia

Pero antes vamos a tratar un problema desarrollado por Meyerson. Uno se pregunta porqué un abogado tendría que entrar en vericuetos matemático-estadísticos, que son aparentemente parte de una disciplina completamente separada del derecho. Ahora bien, cabe preguntarse también: ¿cuál es la causa por la que un juez permite a un fiscal enfatizar la raza de un acusado criminal si no hay ninguna indicación de que la raza tenga algo que ver con el caso? ¿Por qué motivo una corte podría pedirle a un jurado que considere a un sospechoso probablemente tan culpable como inocente, aún cuando no haya otra evidencia que la acusación? ¿Y qué puede inducir a un juez para que una mujer reciba una menor compensación por daños y perjuicios que un hombre idénticamente situado, con la expectativa tácita de que el sexismo continuará en el futuro?

Todo esto tiene que ver con un defecto muy grande del derecho, y es que aún no constituye una ciencia. No sorprende que muchos jueces sufran de distanciamiento, resistencia, e incapacidad en cuestiones matemáticas. Éstas son perversiones de la justicia, resultantes del analfabetismo matemático. Esto afecta a la mayoría de los abogados, así como a la mayoría de los norteamericanos¹⁴. El analfabetismo matemático es especialmente preocupante porque el análisis numérico se ha convertido en una parte importante del sistema legal, en particular en la utilización de testimonios estadísticos en el juicio, “que ha crecido dramáticamente”¹⁵. En nuestros días la evidencia estadística es un elemento esencial que abarca todo el universo legal. Las estadísticas son usadas en forma regular para probar o rechazar cuestiones tan disímiles como los perjuicios

¹⁴ Así lo señala Marilyn Burns, *Math: Facing an American Phobia* (1998).

¹⁵ Jeremy A. Blumenthal, “[Law and Social Science in the Twenty-First Century](#)”, *Southern California Interdisciplinary Law Journal*, Vol. 12; SSRN, December, 2004.

causados en casos de juicios por el uso de tóxicos, la violación de contratos, la discriminación en el trabajo y de carácter político, la identificación por medio de ADN en casos criminales o familiares, violaciones a las leyes de marcas y patentes, el daño al medio ambiente, el fraude financiero y las pérdidas de ingresos futuros¹⁶. La Corte Suprema de USA ha declarado que en tales casos, las cortes federales cumplen con una “obligación general de ‘guardianes’”. Comenzando con su decisión de 1993 en el caso *Daubert v. Merrell Dow Pharmaceuticals, Inc.* el Tribunal Supremo declaró que las Reglas Federales de Evidencia asignan al juez la tarea de asegurar que el testimonio de un experto tenga fundamentos fiables como así también que sea relevante para la tarea en cuestión.

En lugar de ello, a los expertos no legales se les ha ido permitiendo ampliar su rol hasta el punto de que en la actualidad están adoptando decisiones políticas normativas. A veces esto ocurre porque los tribunales confunden validez científica con relevancia lógica; puede que no esté en disputa la ciencia y la matemática, pero la cuestión real es hasta qué punto hay una conexión lógica y legal de los números expuestos con el punto legal que se busca demostrar. Como dice el informe de la Comisión Carnegie sobre Ciencia y Tecnología en Decisiones Judiciales, “en los tribunales, el conocimiento científico debe informar sobre qué elección cabe hacer, pero abdicar a favor del hombre de ciencia es incompatible con la responsabilidad del juez de decidir sobre la ley aplicable”¹⁷. El déficit judicial crítico no es, empero, respecto de las ciencias en general, sino de las matemáticas. Hay demasiados jueces que no “hablan en términos matemáticos” ni entienden lo que esos números comunican. También fallan en apreciar el significado de que los resultados matemáticos no son una necesidad científica, sino consecuencia de juicios de valor específicos. Al ignorar que estos juicios son inherentes a elecciones matemáticas, los jueces terminan aceptando valores que pueden hallarse en las antípodas de un sistema judicial.

Naturalmente, siempre hay errores. No existe una “máquina de la verdad” que diga con precisión absoluta el resultado correcto de una prueba médica, de una predicción económica, o de un juicio. De lo que se trata es de reducir la frecuencia y el grado de los resultados incorrectos, pero la condición humana es inevitablemente imperfecta. Los estadísticos, que se manejan con el “arte de lo probable”, han imaginado un ingenioso sistema para conducirse con este error inevitable. Supongan, p.ej. que hay una prueba médica para determinar si los pacientes tienen una enfermedad determinada, y que, en general, un puntaje más alto está correlacionado con una mayor probabilidad de tener esa enfermedad. Los pacientes están dentro de un rango de esta prueba, y se requiere un punto de corte de manera que podamos decir que, por encima de ese puntaje, el paciente será diagnosticado como enfermo.

Hay dos situaciones posibles en que la prueba podría estar errada. En primer término, con un “falso positivo”, habrá pacientes sanos que serán diagnosticados como enfermos. Alternativamente, con un “falso negativo”, habrá pacientes enfermos que erróneamente serán considerados sanos. Estos errores son llamados de “Tipo I” y de “Tipo II” respectivamente.

Luego, el punto de corte habrá que elegirlo basándose en qué tipo de error es peor. Si subimos el punto de corte, tendremos más falsos negativos (más pacientes afectados declarados sanos) pero menos falsos positivos (menos pacientes sanos declarados enfermos). Si se reduce el punto de corte se tendrá el efecto inverso (con menos falsos negativos pero falsos positivos adicionales). De cualquier forma que ustedes elijan cometerán errores; no existe un “punto perfecto” para elegir.

¹⁶ Jonathan J. Koehler, “[The Probity-Policy Distinction in the Statistical Evidence Debate](#)”, SSRN and Tulane Law Review, Vol. 66, p. 141, 1991.

¹⁷ Carnegie Commission on Science, Technology and Government, Science and Technology in Judicial Decision Making: Creating Opportunities and Meeting Challenges, 24 (1993).

Como ambos errores siempre tendrán lugar¹⁸ el punto de corte para determinar la presencia de una enfermedad reflejará el juicio de valor sobre qué tipo de error es más serio. Puede que se prefiera tener menos falsos positivos – un error de Tipo I más bajo – para emplear una prueba de medicación, así se reduce el número de empleados erróneamente acusados. Para enfermedades con graves consecuencias que podrían evitarse sólo si hay una acción inmediata (p.ej. si se trata de un cambio de la dieta que evita un retraso mental durante el desarrollo del feto) se podría desear tener un menor número de falsos negativos, un error de Tipo II más bajo, a fin de minimizar la posibilidad de que algún enfermo no sea diagnosticado. La elección de un estándar de prueba legal refleja un cálculo similar. Como sucede con una prueba médica inevitablemente imperfecta, siempre existe la posibilidad de que el veredicto de un juicio no sea adecuado a los hechos reales. En un contexto criminal, si se declara culpable a un inocente, hemos cometido un error de Tipo II. Si exoneramos a un culpable, tenemos un error de Tipo II. Lo mismo sucede en el contexto civil. Y bien sabemos que serán cometidos errores.

¿Cuánto riesgo estamos dispuestos a aceptar basándonos en los valores del sistema legal? A diferencia de una investigación científica, “el derecho está orientado a la resolución ‘justa’ de casos en lugar de la búsqueda de la verdad”¹⁹. Pero mientras que admitir la “verdad” es un valor profundo de todo sistema legal, con frecuencia es inalcanzable porque los “los veredictos deben ser emitidos bajo condiciones de información incompleta”. Por ejemplo, en muchos casos los tribunales hacen recaer el peso de la prueba de causalidad sobre un demandante inocente ante un demandado negligente, al requerir que el demandante pruebe la causa, lo que “sería injusto y destructivo de los propósitos disuasivos involucrados en el concepto de deber ser diligente”.

A guisa de conclusiones de esta sección, cabe recordar que hace más de 40 años el Tribunal Supremo de USA advirtió lo siguiente: “La matemática, un verdadero brujo de nuestra sociedad computadorizada, al mismo tiempo que es de ayuda para el juez o el jurado responsable de decidir cuáles son las cuestiones de hecho en el juicio en la búsqueda de la verdad, no debe proyectar un hechizo sobre ellos”²⁰. En nombre del rigor matemático incorrectamente aplicado, los tribunales de USA permitieron que cuestiones raciales entren en los juicios criminales, y que los prejuicios reduzcan los subsidios por los delitos cometidos. Si se la acepta judicialmente, información que se reconoce universalmente como incorrecta y carente de base puede ser utilizada para calcular, p.ej., las probabilidades de paternidad. Y conocidos malhechores han podido rehuir a sus obligaciones con jueces que renunciaron a su responsabilidad de balancear riesgos de error que forman parte inevitable de todo juicio. Resulta que, al fin de cuentas, las matemáticas mal usadas no son meramente un hechicero sino un matón que se apropia del poder de emitir juicios de valor que pertenece a los tribunales. No es necesario que jueces y abogados se vuelvan “aficionados a las matemáticas” para que reclamen desempeñar un papel apropiado²¹. Pero deben ser conscientes de que la aparente objetividad de las matemáticas a veces

¹⁸ Sólo se podrá evitar cometer estos errores si en el 100% de las pruebas fracasan o en el 100% pasan.

¹⁹ Lucinda Finley, [Guarding the Gate to the Courthouse: How Trial Judges Are Using Their Evidentiary Screening Role to Remake Tort Causation Rules](#), SSRN; DePaul Law Review, Vol. 49, P. 335, 1999 (donde se afirma que “el sistema de agravios no debería esclavizarse con los valores de la epidemiología porque sus propósitos y funciones sociales siempre tuvieron en cuenta un rol ‘justiciero’ de alcance más amplio que cuando los científicos llegan a una conclusión, o lo que suceda con el consenso verdadero ‘científico’ en un momento”).

²⁰ V. [People v. Collins, 438 P.2d 33, 33](#) (1968).

²¹ En Daubert, el por entonces Jefe de Justicia Rehnquist se quejó de que la necesidad de que los jueces “evalúen la validez científica” les imponía la obligación de convertirse en “científicos aficionados”. Daubert, 509 U.S. at 600-01 (Rehnquist, C.J., concurring in part and dissenting in part). V. nota (183) de Ann C. Hodges and Porcher L. Taylor, III, [The Business Fallout from the rapid Obsolescence and planned Obsolescence of High-Tech Products: Downsizing of Noncompetition Agreements](#).

enmascara un juicio subjetivo, y no deben dejarse llevar cuando los números “duros” están basados en poco más que intuición y conjeturas²². Los números pueden comunicar información importante. Es necesario que los jueces sean capaces de comprender lo que los números tratan de decir.

2. Ajuste de curvas


Los datos, provenientes de medir variables, pueden venir dados por una gran cantidad de fuentes y presentados de distintas maneras. Los datos que describen el movimiento de una variable a través del tiempo son datos de series de tiempo, y pueden ser diarios, semanales, mensuales, trimestrales, o anuales. Los datos que describen las actividades de personas individuales, empresas, u otras unidades en cierto momento del tiempo son datos de sección cruzada. Es probable que un estudio de mercado realizado sobre presupuestos de las familias en un momento del tiempo utilice datos de sección cruzada. Este tipo de datos también se usa para examinar un grupo de estados contables de un grupo comercial con el propósito de estimar el patrón de conducta entre firmas individuales de la industria. Supongan que estoy interesado en la relación entre dos variables X e Y . A efectos de describirla estadísticamente, necesito un conjunto de observaciones para cada variable y una hipótesis que plantee una forma matemática explícita de esa relación. El conjunto de observaciones es llamado una *muestra*²³. En primer término, analizaremos el caso en que la relación entre X e Y es lineal, o sea que viene representada por una línea recta. Dado el carácter lineal, mi objetivo es especificar una regla mediante la cual pueda determinar la “mejor” relación lineal que vincula a X con Y .

Edad (Años)	Diámetro
97	12.5
93	12.5
88	8
81	9.5
75	16.5
57	11
52	10.5
45	9
28	6
15	1.5
12	1
11	1

Los pares de observaciones serán indicados $\{y_i, x_i\}_{i=1}^n$. Estos datos están constituidos por una respuesta *escalar* y y un conjunto de *variables explicativas* x , que se reducen en nuestro caso a una única variable explicativa. El modelo lineal será escrito:

$$[1] \quad y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

y representa un modelo estadístico si agregamos los supuestos siguientes: (a) los coeficientes β_0 y β_1 son constantes que el análisis debe determinar (denominadas coeficientes de regresión); (b) la variable independiente x_i es una variable observada sin error (hay modelos más complejos que levantan este supuesto); (c) se debe incorporar un término aleatorio no observable ε_i que constituye una variable aleatoria cuya esperanza matemática es nula²⁴.



²² Se recomienda la lectura de David H. Kaye, [Is Proof of Statistical Significance Relevant?](#), SSRN y Washington Law Review, Vol. 61, 1986.

²³ Los datos muestrales son observaciones elegidas de una *población* subyacente que representa la verdadera relación estudiada.

²⁴ Luego, si $E(\cdot)$ es la esperanza matemática de la expresión, $E(y_i | x_i) = \beta_0 + \beta_1 x_i$. Esta expresión se lee “esperanza matemática de y_i dada x_i ”.

Vayamos a un ejemplo. En la tabla adjunta están los datos de diámetro (en pulgadas) medido en robles al S.E. de Wisconsin y la edad de esos árboles (en años). Ustedes sabrán probablemente que la edad de un árbol puede computarse contando el número de aros anuales concéntricos en el tronco del árbol. (No es necesario convertir en un muñón al árbol para efectuar este cálculo. Pueden sacar una muestra que vaya de la corteza hasta el núcleo muerto usando un taladro). Hay una medida usual de tamaño, conocida como “diámetro a la altura del pecho” (DAP). “Altura del pecho” se define como 4 veces y media por arriba del lado cuesta arriba del árbol. Como un tronco no es un círculo perfecto, el “diámetro” es definido como la longitud de la circunferencia dividida por π . Nuestros datos de edad y diámetro son los de la tabla anterior.

La decisión siguiente es graficar estos datos en un diagrama de dispersión, en el cual debemos decidir cuál será la variable X (independiente) y la variable Y (dependiente). Hay una regla que dice que conviene colocar a la variable medida con menor precisión en el eje de las Y . Cuantificar la cantidad de anillos anuales debería dar un resultado preciso; naturalmente, los árboles serán un poco más viejos que la cuenta porque les llevó algunos años crecer hasta la altura en que fue tomado el núcleo. El DAP podría medirse con bastante precisión. Los errores de edad (una subestimación sistemática de algunos años) y de DAP (error de redondeo, si lo hay) son difíciles de comparar ya que están expresados en unidades diferentes y tienen una naturaleza distinta. Otra regla sería: colocar a la variable de “control” en el eje de las X y a la variable dependiente en el eje de las Y . Si pienso que la edad es la causa del crecimiento, más que a la inversa, pondré a la edad en el eje de las X . Por otra parte, si el objetivo es terminar con una fórmula que permita predecir la edad basándose en el DAP, entonces pondré a la edad en el eje de las Y . La elección que haga no es sólo una cuestión de gráfico: se tendrán distintas “líneas de tendencia” haciendo uso de distintas opciones. Por otra parte, el coeficiente de correlación r y el p -valor asociado no dependerán de la elección que se haga. La figura 1 muestra la elección que hice. Resulta claro que hay una tendencia a que los robles más viejos sean también los más grandes. Por otro lado, hay bastante variabilidad, por ejemplo el roble más grande no es el más viejo. Espero que quede claro que la relación entre edad y DAP no viene dada mediante una mera “conexión entre los puntos” (¡siempre es incorrecto obtener un gráfico “conectando los puntos entre sí!”).

Por otra parte, la relación entre la edad y el DAP podría dar lugar a una curva suave que le yerra a los datos individuales (algunos quedan arriba y otros abajo), pero en cambio se obtiene una especie de promedio entre los puntos como en la Figura 2. Hay diversos programas de computación que permiten estimar la recta de mejor ajuste, por ejemplo el EVIEWS, del cual transcribo una salida simplificada:

Tabla 1. Resultados de regresión

Dependent Variable: DIAMETRO
 Method: Least Squares
 Included observations: 12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.285354	1.702259	0.755087	0.4676
EDAD	0.127792	0.027131	4.710220	0.0008
R-squared	0.689308	Mean dependent var		8.250000
Adjusted R-squared	0.658238	S.D. dependent var		4.997727
p value of F	.0008290	Durbin-Watson stat		1.1787630

La ecuación de regresión de la Tabla 1 se escribe (redondeando al decimal más próximo):

[2] $DIAMETRO = 1.29 + 0.13 \times EDAD$

Esta información es rutinariamente provista por los programas de cómputo: el coeficiente $\beta_0 = 1,29$ (la “ordenada al origen”) y el coeficiente $\beta_1 = 0,13$ (la “pendiente de la línea” o “coeficiente angular”). Hay que prestar atención, además, a los errores estándar de ambos coeficientes: $\sigma_{\beta_0} = 1.70$, y $\sigma_{\beta_1} = 0,03^{25}$. Los estadísticos t ensayan si el verdadero valor de cada coeficiente podría ser 0. Son calculados como el cociente entre el estimador de β_i y el correspondiente estimador de su error estándar σ_i . Un valor elevado de t indica que la hipótesis debe rechazarse y que el coeficiente correspondiente no es cero. La última columna expresa el p -valor. Por convención, un p -valor inferior a 0,05 se interpreta como evidencia de que el correspondiente valor poblacional es distinto de cero. El estadístico t de $EDAD$ es muy elevado para los estándares usuales: 4,71 que tiene un p -valor de prácticamente *cero*. Lo cual indica que al ser tan reducido (al nivel de aproximación decimal usado) es muy improbable que la relación aparente entre la edad del árbol y el diámetro del mismo pueda ser producto del azar. El coeficiente de correlación es $r = 0,83$. Este coeficiente de correlación elevado al cuadrado, que termina siendo $R^2 = 0,69$, es llamado el coeficiente de determinación o de explicación (o de Pearson). Cuando a este coeficiente se lo “penaliza” por la incorporación de variables explicativas adicionales (la constante β_0), se obtiene el coeficiente $R^2_{aj} = 0,66$ (en cuyo caso hablamos de coeficiente de determinación ajustado)²⁶.

Hay otros dos estadísticos descriptivos muy simples: uno es la *media de la variable dependiente* y otro es el *error estándar de la misma*. Nos quedan finalmente dos: el p -valor del estadístico F y el contraste de Durbin y Watson. Un F-test es todo test estadístico que tiene una distribución F bajo la hipótesis nula (aquí aparece otro tipo de distribución que no es la normal). Es utilizado para identificar al modelo que mejor ajusta los datos muestrales de una población. El término es debido a George W. Snedecor, en honor a Sir Ronald A. Fisher, quien fue el que desarrolló en los

años 1920s este estadístico como una relación entre dos tipos de varianzas. En esta función se identifica un área del gráfico que indica la región de rechazo al nivel de significación. Como se trata de un test unilateral (a una cola), se tiene la probabilidad en la cola superior de que se exceda el valor crítico y cero en la cola inferior. Como la distribución F es asimétrica, un test a dos colas requeriría dos tablas que contengan las regiones de rechazo, tanto para las colas inferior y superior. Este estadístico busca contrastar la hipótesis de que todos los coeficientes (excepto la




Figura 2

²⁵ Mediante estos errores estándar se pueden obtener intervalos de confianza de los coeficientes de regresión. Por ejemplo, para β_0 un intervalo de confianza al 95% vendrá dado por $1,29 \pm t_c \cdot 0,76$ donde t_c es un cierto valor tabulado de la distribución t -Student, que resulta igual a 2,12 para una dódima bilateral al 95% (En un Apéndice no incluido aquí se presentan las tablas estadísticas) con 11 grados de libertad. Esto resulta en un intervalo de confianza muy impreciso, comprendido entre -0,32 y 2,90. En cambio, β_1 tiene una estimación muy precisa ($p = 0,0008$).

²⁶ Este estadístico siempre es inferior a R^2 , puede disminuir al agregarse nuevas variables independientes, y hasta puede llegar a ser negativo para ecuaciones con un ajuste muy pobre: $R^2_{aj} = 1 - [(n-1)/(n-p)] (1 - R^2)$.

ordenada al origen, con lo cual estamos probando β_1) son iguales a cero. Este estadístico tiene que calcularse teniendo en cuenta el número de observaciones (n) y de variables explicativas²⁷ en número igual a p . Su p -valor indica la probabilidad de que la hipótesis sea corroborada, ya que su reducido valor indica que es muy improbable que la relación aparente entre edad y DAP sea resultado del mero azar.

A pesar de su nombre, modelo clásico de regresión lineal, éste no se limita a relaciones lineales entre la variable dependiente y (una o más) variables independientes. En realidad es *potencialmente no lineal* en las variables independientes, pero *siempre es lineal en los parámetros β* y el término aleatorio o de error entra en forma aditiva y separable de los restantes.

La Figura 3 representa por ejemplo funciones logarítmicas expresadas en bases distintas. Recuérdese que el logaritmo de un número en una base determinada es el exponente al cual hay que elevar la base para obtener aquel número. Es la función matemática inversa de la función exponencial. Luego,

$$[3] \quad \log_b N = x \text{ siempre que } N = b^x.$$

No me detendré más en distintas formas funcionales que pueden aparecer en el análisis. Sugiero leer el artículo de Kurt Schmidheiny a tal efecto.

A veces se dice que R^2 es igual a la fracción de la varianza de Y explicada por su relación con X . Lo que esto significa es que el error estándar de los *residuos* de la línea de tendencia de la Figura 2 (las líneas de color azul de la Figura 4) dividido por el error estándar de Y es igual a $1-R^2$. Obviamente, si R está próximo a $+1$ o -1 , los desvíos con relación a la línea de tendencia deben ser “pequeños”. Pero tomen en cuenta que muchas veces se presentan situaciones de correlaciones “estadísticamente significativas” (o sea, reducidos p -valores) que explican una reducida variación de los datos (o sea, con bajos coeficientes R^2_{aj}).

El nombre de “mínimos cuadrados” proviene del proceso de definir una línea de tendencia. Se ajusta una línea hasta que la suma de los cuadrados de los desvíos de las Y respecto de la línea (coloreados de azul en la Figura 4) sea la más reducida posible. Pero cabe notar que hay otras formas de obtener líneas de tendencia.



Sir Ronald A. Fisher (1890-1962)




Figura 3. Representación gráfica de logaritmos en diversas bases. En color rojo el logaritmo en base e , el verde corresponde a la base 10, en tanto que el azul al de base 1,76

²⁷ Más precisamente, este estadístico tiene una distribución $F(p-1, n-p)$ bajo la hipótesis nula y el supuesto de normalidad.

En la Figura 5 la línea sólida cumple con un buen desempeño pero deja 4 puntos bien lejos de la línea, y se basa en minimizar la distancia de los desvíos *horizontales* a partir de esa línea (graficados en color rojo). Tiene una mayor pendiente que la línea de mínimos cuadrados de la Figura 4. La curva punteada, que yerra apenas 3 puntos, es una parábola elegida para minimizar el cuadrado de los desvíos de las Y. No hay una sola manera de elegir la “mejor” línea de tendencia entre todas las líneas de tendencia. Uno se puede guiar a) por lo que sugiere una teoría conocida, b) por lo que requiere un docente en particular, c) por la práctica usual (que es habitualmente una línea de mínimos cuadrados), d) conociendo qué puntos es probable que sean anómalos, o d) (lamentablemente) por la necesidad de conseguir un resultado determinado.

Las líneas de tendencia son utilizadas a menudo para “guiar el ojo”, desplegando una tendencia promedio. También pueden servir para realizar predicciones cuantitativas. Por ejemplo, “¿cuán grande será mi roble dentro de 20 años?” o “¿cuán viejo puede ser este árbol que tiene 10 pulgadas de diámetro?”. Siempre es más seguro hacer predicciones dentro del rango de datos que definen a la línea de tendencia (lo cual sería básicamente una interpolación). Cuando son hechas fuera del rango probado (extrapolación) las líneas de tendencia pueden dar lugar a respuestas erróneas, incluso disparatadas. Por ejemplo, la línea sólida de la Figura 5 (con desvíos horizontales minimizados) sugiere que un roble más joven que 1 año tiene un diámetro negativo. La línea de tendencia parabólica sugiere que los árboles comienzan a contraerse a partir de los 80 años y que tendrán un diámetro negativo si tienen más que 150 años.

Otra idea básica fundamental del modelo de mínimos cuadrados es que toda la estructura está incorporada en la expresión $\beta_0 + \beta_1 x_i$ y que lo que queda es comportamiento puramente aleatorio (esta hipótesis es levantada en modelos más sofisticados). En particular, no debe ser posible poder predecir el residuo de un año conociendo los residuos de años anteriores. ¿Cómo diagnosticar si los residuos tienen esta propiedad? En la Figura 6 se incluyen los residuos de la ecuación de regresión de la Figura 2. Obsérvese que en la zona del centro existe una tendencia a que residuos positivos sigan a residuos positivos, lo que no ocurre en las dos zonas de los extremos. Lo que esto significa es que, en la zona central por ejemplo, hay una similitud entre observaciones como una función del tiempo que las separa. A esta propiedad se la denomina *autocorrelación*. La idea de autocorrelación de una serie






Figura 6



de tiempo es que se puede encontrar un patrón repetitivo, como ser la presencia de una señal periódica que, de existir, violaría el supuesto del modelo de mínimos cuadrados. Pero los econométricos están preparados para enfrentar este tipo de situaciones. Antes que nada, distinguen entre autocorrelación positiva (algo así como la que se verifica en la región central y en ambos extremos de la Figura 6) de los casos de autocorrelación negativa, que se presenta cuando es posible predecir a partir de un residuo *positivo* que el residuo siguiente será *negativo*. Para ello, se construye un estadístico que en la Tabla 1 es llamado de Durbin-Watson (ya que fue descubierto por James Durbin y Geoffrey Watson), que es igual aproximadamente a $d=2.(1-r)$ en cuya fórmula r es el *coeficiente de autocorrelación muestral de los residuos* (es decir, que si $r>0$ habrá una tendencia a que residuos positivos sean seguidos por residuos positivos, y residuos negativos por residuos negativos; mientras que si $r<0$ la tendencia será que residuos con un signo serán seguidos por residuos de otro signo). Este estadístico d siempre está comprendido entre 0 ($r=+1$) y 4 ($r=-1$). Luego, valores reducidos de d están indicando que es probable que exista autocorrelación positiva, y valores elevados de d que sea negativa. Para probar la autocorrelación positiva al nivel de significación del 95%, el valor d debe ser comparado con dos valores críticos, uno inferior d_L y otro superior d_U ; se compara d con estos dos valores tabulados (no incluidos en este documento) de tal forma que, si $d<d_L$ existe evidencia estadística de que los errores están positivamente auto-correlacionados; si $d>d_U$ la evidencia estadística indica que los errores no están positivamente auto-correlacionados; pero si $d_L<d<d_U$, el contraste es inconclusivo²⁸. En nuestro ejemplo, el estadístico $d=1,18$. Con 12 observaciones y 2 variables (incluyendo la ordenada al origen como otra variable), al 95% de confianza, el estadístico queda comprendido entre los dos valores límites que proporciona la tabla (0.97076 y 1.33137) de lo cual obtenemos que el contraste es inconclusivo.

3. Especificación del Modelo

Volviendo al derecho, el análisis de regresión múltiple le permite al economista que brinda el testimonio o a otros expertos elegir entre teorías o hipótesis alternativas y lo ayuda a distinguir aquellas correlaciones que son claramente espurias de las que reflejan relaciones válidas. En este punto es mejor tener un diseño de investigación bien armado.

La cuestión específica investigada Una investigación debe comenzar formulando una pregunta clara. Los datos a ser recolectados deben estar directamente vinculados con la cuestión, ya que en caso contrario no podrán sacarse las inferencias adecuadas a partir del análisis estadístico. Por ejemplo, si la cuestión que se presenta en un caso de infracción a una patente es qué precio hubiera alcanzado el producto del demandante de no ser por la venta del producto en infracción, debe haber suficientes datos como para permitir que el experto tome nota en forma estadística de los factores que determinaron el precio del producto.

El modelo a elegir La especificación de un modelo involucra distintas etapas, cada una fundamental para que tenga éxito el esfuerzo de investigación. Idealmente, un análisis de regresión múltiple se elabora en base a una teoría que describe las variables a ser incluidas en el estudio. Por ejemplo, la teoría de los mercados laborales puede conducirnos a esperar que los salarios de una industria estén vinculados con la experiencia y la productividad de los

²⁸ La prueba de autocorrelación negativa sigue un enfoque similar, pero en lugar de d se usa $(4-d)$. Si $(4-d)<d_L$, la evidencia indica que los errores están negativamente auto-correlacionados, mientras que si $(4-d)>d_U$ esa evidencia está indicando que no están negativamente auto-correlacionados. El test es inconclusivo si $(4-d)$ está comprendido entre ambos valores. Cabe tener en cuenta que si la distribución de los errores no sigue una distribución normal, o hay otras alteraciones del modelo canónico [1], los econométricos usan en forma complementaria el test llamado de Breusch-Godfrey.

trabajadores. Si se cree que hay discriminación laboral deberían agregarse una o más variables que reflejen semejante discriminación.

Usualmente a los modelos se los caracteriza mediante parámetros, es decir características numéricas del modelo. En el ejemplo del mercado laboral, un parámetro podría reflejar el incremento salarial asociado con cada año de experiencia laboral. La regresión múltiple utiliza una muestra, o selección de datos, de la población a fin de obtener estimadores de los valores de los parámetros del modelo. Un estimador asociado con una variable explicativa determinada es el coeficiente de regresión estimado.

¿Por qué es importante disponer de una teoría apropiada, elegir bien las variables apropiadas, o elegir bien la forma correcta del modelo? Porque si uno no hace todo esto, los resultados estadísticos pueden estar *sesgados*, lo que significa que se genera una tendencia sistemática a que el parámetro del modelo sea demasiado alto o bajo.

Elección de la variable dependiente La variable elegida como “dependiente” debe ser la que corresponde²⁹. Por ejemplo, supongan que existe una discriminación de pagos a trabajadores por hora. Una elección de variable dependiente es la tasa salarial por hora de los empleados; otra es el salario anual. La diferencia es importante, porque las diferencias de salarios anuales pueden deberse en parte a diferencias en horas trabajadas. Si la cantidad de horas trabajadas resulta de las preferencias del trabajador y no de la discriminación, el salario por hora es una elección correcta. Si la cantidad de horas está vinculada con la discriminación alegada, en ese caso será más adecuado elegir al salario anual³⁰.

Elección de la variable explicativa relevante Debe elegirse en forma adecuada la variable explicativa que permita la evaluación de hipótesis alternativas. Por ejemplo, en un caso de discriminación, la variable de interés podría ser el sexo o el origen geográfico del individuo. En un caso antimonopolístico, puede tratarse de una variable que tome el valor 1 si refleja la presencia de la conducta anticompetitiva alegada y 0 en los demás casos.

Elección de variables explicativas adicionales Debería intentarse identificar variables explicativas adicionales, conocidas o hipotéticas, algunas medibles y que puedan sustentar hipótesis sustanciales tomadas en cuenta por el análisis de regresión. Así, en un caso de discriminación, una medida de la aptitud de los trabajadores puede brindar una explicación alternativa – los salarios más reducidos pueden deberse a capacidades inadecuadas³¹.

²⁹ En el análisis de regresión múltiple, usualmente la variable dependiente es una variable continua que adopta valores dentro de un cierto rango. Si la variable es *categorica*, es decir que adopta sólo dos o tres valores, hay formas modificadas del análisis de regresión múltiple que son apropiadas (como los análisis probit y tobit). Como ejemplo de uso de este último, ver [EEOC v. Sears, Roebuck & Co., 839 F.2d 302, 325 \(7th Cir.1988\)](#) (EEOC utilizó el análisis logit para medir el impacto de variables tales como la edad, la educación, la experiencia en el trabajo y en las líneas de producción, sobre el porcentaje de comisiones cobradas por las mujeres).

³⁰ En los sistemas laborales en que los salarios anuales están atados al grado del escalafón, podría resultar más apropiado utilizar el salario anual correspondiente a la posición laboral.

³¹ En [Ottaviani v. State University of New York, 679 F. Supp. 288, 306–08 \(S.D.N.Y. 1988\), aff'd, 875 F.2d 365 \(2d Cir. 1989\), cert. denied, 493 U.S. 1021 \(1990\)](#), el tribunal dictaminó en la fase de responsabilidad civil, que no existió discriminación ni en la ubicación en rangos ni en la promoción entre rangos, de modo que el rango era la variable adecuada en un análisis de regresión múltiple para determinar si las profesoras eran tratadas en forma distinta que los profesores. Sin embargo, en [Trout v. Garrett, 780 F. Supp. 1396, 1414 \(D.D.C. 1991\)](#) el tribunal dictaminó, en la etapa de daños del juicio, que la duración de la experiencia laboral previa a su contratación no constituía una variable adecuada en un análisis de regresión a fin de

No siempre es posible incluir todas las variables que pueden ejercer influencia sobre la variable dependiente para que el análisis sea exitoso; algunas pueden ser medidas, y otras pueden ser de poca importancia³². Si un análisis preliminar muestra que la porción no explicada de la regresión múltiple es inaceptablemente alta, el experto debe tratar de descubrir si hay alguna variable que no detectó y omitió en el análisis³³. Si se comete el error de excluir una variable explicativa importante correlacionada con la variable que resulta de interés en un modelo de regresión puede ocasionar que a una variable incluida se le adjudique un efecto que en realidad está causado por la variable omitida³⁴. Por regla general, las variables omitidas correlacionadas con la variable dependiente reducen el valor probatorio del análisis de regresión³⁵. Lo cual puede conducir a inferencias hechas con el análisis de regresión que no resulten útiles para el juez de los hechos³⁶.

computar los salarios atrasados en materia de discriminación de empleo. Según el tribunal, incluir los sueldos atrasados resultaría en que no se hallaría discriminación sexual, pese a las conclusiones en contrario de la etapa de daños del juicio. Id. ver también [Stuart v. Roache, 951 F.2d 446 \(1st Cir. 1991\)](#) (que admitía sólo 3 años de antigüedad a ser considerados como resultados de la discriminación previa, cert. denied, 504 U.S. 913 (1992)). Que haya o no variables determinadas que reflejan consideraciones “legítimas” o que incorporan sesgos ilegítimos es un tema recurrente de la discriminación. Ver p.ej. [Smith v. Virginia Commonwealth Univ., 84 F.3d 672, 677 \(4th Cir. 1996\) \(en banc\)](#); id. at 681–82 (Luttig, J., concurr. in part) (sugirió que el análisis de regresión falló en incluir los “factores de rendimiento” al punto de tornarlo incompleto e inadmisibles); id. at 690–91 (Michael, J., dissenting) (sugiere que el análisis de regresión excluyó en forma correcta los “factores de rendimiento”); ver también [Diehl v. Xerox Corp., 933 F. Supp. 1157, 1168 \(W.D.N.Y. 1996\)](#).

³² El efecto combinado de las variables excluidas aparece dentro del término aleatorio en el modelo de regresión, así como cualquier error de modelización. En un apéndice (no incluido aquí) se proporcionan más detalles. Pero David W. Peterson, en su ensayo crítico sobre la Reference Guide on Multiple Regression, 36 *Jurimetrics J.* 213, 214 n.2 (1996) sostiene que “el supuesto de que el efecto combinado de las variables explicativas omitidas del modelo no guardan correlación con las variables explicativas incluidas” constituye una condición de “filo de la navaja... que resulta poco verosímil”.

³³ Un R^2 demasiado bajo indica que la porción no explicada del modelo de regresión múltiple es demasiado elevada. Pero esta conclusión dependerá del contexto y de los datos, pues como se verá en el Apéndice (no incluido aquí), un R^2 bajo no necesariamente implica un modelo pobre (y *viceversa*).

³⁴ En otros términos, esta omisión genera sesgos de los parámetros estimados.

³⁵ Este efecto puede llegar a ser importante si hay una fuerte relación entre la variable omitida y la variable dependiente, y una fuerte correlación entre la primera variable y las variables explicativas interesantes.

³⁶ [Bazemore v. Friday, 751 F.2d 662, 671–72 \(4th Cir. 1984\)](#) (que ratificó el rechazo de la corte distrital a aceptar un análisis de regresión múltiple como prueba de discriminación por preponderancia de la evidencia, la corte de apelaciones afirmó que, si bien la regresión utilizó cuatro factores variables (raza, educación, ejercicio de la ocupación y título del empleo), no usar otros factores (entre ellos los incrementos de paga que variaban según el condado) impedía su consideración como evidencia, *aff'd in part, vacated in part*, 478 U.S. 385 (1986). No obstante, en [Sobel v. Yeshiva University, 839 F.2d 18, 33, 34 \(2d Cir. 1988\)](#), cert. denied, 490 U.S. 1105 (1989), el tribunal dejó aclaró que “un demandado [Title VII] que cuestiona la validez de un análisis de regresión múltiple tiene que exhibir que los factores que sostiene deberían haber sido incluidos debilitaría exhibir una disparidad salarial producida en el análisis”, realizando un ataque específico y una “exhibición de la relevancia de todas las variables particulares que sostiene ... que deberían haber sido incluidas” en el análisis, en lugar de cuestionar simplemente los resultados de la demostración del demandante por la carencia de determinada variable. Ver también [Smith v. Virginia Commonwealth Univ., 84 F.3d 672 \(4th Cir. 1996\) \(en banc\)](#) (halló que si ciertas variables deberían haber sido incluidas en un análisis de regresión es una cuestión de hecho que impide un juicio sumario). También en [Bazemore v. Friday](#), la Corte, al declarar que el punto de vista del Cuarto Circuito del valor de evidencia de los análisis de regresión era claramente incorrecto, afirmó que “normalmente, la falla de incluir variables afectan el valor probatorio del análisis, no su admisibilidad. Es importante destacar que un análisis de regresión que incluya algo menos que ‘todas las variables medibles’ puede ser de utilidad para demostrar el caso de un demandante”. 478 U.S.385, 400 (1986) (footnote omitted).

La omisión de variables no correlacionadas con la variable interesante, en general, no representa tanto un problema, porque el parámetro que mide el efecto de la variable interesante sobre la variable dependiente es estimado sin sesgo. Por ejemplo, supóngase que el efecto de una política introducida por las cortes para alentar a los maridos a que costeen el sostenimiento de sus hijos ha sido probado eligiendo en forma aleatoria algunos casos manejados según políticas actuales de los tribunales y otros manejados con arreglo a una nueva política más estricta. El efecto de la nueva política podría medirse mediante una regresión múltiple que use el éxito del pago como variable dependiente y 0 o 1 como variable explicativa (1 si se aplicó el nuevo programa; 0 si no lo fue). Si no se puede incluir una variable explicativa que refleje la edad del marido involucrado en el programa no sería afectada la evaluación del tribunal de la nueva política, porque es probable que gente de todas las edades sea afectada tanto por la antigua política como por la nueva. La elección al azar de la política de los tribunales a ser aplicada en cada caso asegura que la variable edad omitida no está correlacionada con la variable de política.

El sesgo ocasionado por la omisión de una variable importante vinculada con la variable interesante puede constituir un problema serio. Sin embargo, es posible que el experto tenga en cuenta este sesgo en forma cualitativa si dispone de conocimiento (aunque no sea cuantificable) sobre la relación entre la variable omitida y la variable explicativa. Por ejemplo, supóngase que al experto del demandante de un caso de salarios discriminados por sexo le resulta imposible hallar datos cuantificables que reflejen las aptitudes necesarias para una tarea, y además que, en promedio, las mujeres son más aptas que los hombres. Supóngase también que hay un análisis de regresión del salario de los empleados (variable dependiente) con respecto a los años de experiencia y a una variable que refleja el sexo de cada empleado (variables explicativas) que sugiere que a los hombres se les paga más que a las mujeres que tienen la misma experiencia. Dado que las diferencias de aptitud no han sido tomadas en cuenta, el experto puede concluir en forma razonable que la diferencia salarial medida por la regresión es un estimador conservador de la verdadera diferencia salarial discriminatoria.

También resulta importante la precisión con que es medido el efecto de una variable de interés sobre la variable dependiente³⁷. En general, cuanto más completa sea la relación explicada entre las variables explicativas incluidas y la variable dependiente, tanto más precisos serán los resultados. Hay que tener en cuenta, sin embargo, que la inclusión de variables explicativas irrelevantes (que no guardan correlación con la variable dependiente) *reduce la precisión de los resultados de la regresión*. Esto puede ser fuente de preocupación con muestras pequeñas, pero no es probable que lo sea en caso de muestras grandes.

Elección de la Forma Funcional del Modelo de Regresión Múltiple La selección del conjunto de variables a incluir en un modelo de regresión múltiple no da término al ejercicio de modelización, porque el experto también debe elegir una forma funcional apropiada. La que se elige con mayor frecuencia es el modelo de regresión lineal (introducido en la Sección 2). En este modelo, *la magnitud en que cambia la variable dependiente asociada con el cambio de cualquier variable explicativa no depende del nivel de la variable explicativa*. Supóngase que 1 año más de experiencia añade \$20,000 anuales a los salarios recibidos, sin tener en cuenta la experiencia previa del empleado. Empero, en ciertos casos puede haber motivos para pensar que cambios de la variable explicativa tienen un efecto diferencial sobre la variable dependiente a medida que cambian las variables explicativas. En tales casos, el experto debería utilizar un modelo *no lineal*. Si no se toman en cuenta las no linealidades, se podría estar sobre- o sub-estimando el efecto de un cambio del valor de una variable explicativa sobre la variable dependiente.

³⁷ Un estimador más preciso de un parámetro es un estimador que tiene un error estándar más reducido. Los detalles son tratados en un Apéndice, no incluido aquí.

Hay un tipo especial de no linealidad que implica la interacción entre diversas variables. Una variable de interacción es el *producto* de otras dos variables incluidas en el modelo de regresión múltiple. La variable de interacción contemplada por el experto le permite tomar en cuenta la posibilidad de que el efecto del cambio de una variable sobre la variable dependiente cambie cuando cambia el nivel de otra variable explicativa. Por ejemplo, en un caso de discriminación salarial, la inclusión de un término de interacción entre una variable que mide el sexo del empleado (1 si es mujer, 0 si es hombre) le permite al experto dictaminar si el diferencial por sexo varía con el nivel de experiencia. Un estimador significativo del parámetro asociado con la variable sexo sugiere que existe discriminación en contra de las mujeres, mientras que un estimador negativo significativo del parámetro de interacción sugiere que la magnitud de la discriminación aumenta con la experiencia³⁸.

Hay que notar que los coeficientes no significativos de un modelo con interacciones pueden sugerir falta de discriminación, mientras que un modelo sin interacciones puede sugerir todo lo contrario. Resulta de interés especial tener en cuenta el tipo de interacción de la discriminación; si no se lo hace bien, se puede llegar a conclusiones falsas.

Regresión Múltiple como Método de Análisis Hay diversas técnicas estadísticas multivariadas, además de la regresión múltiple, que son útiles en el ámbito legal. Hay algunos métodos estadísticos útiles cuando se presentan no linealidades importantes³⁹. Otros son aplicables en modelos en los que la variable dependiente es discreta, en lugar de continua (modelos de elección cualitativa, como los modelos *logit* y *probit*). Incluso hay otros que han sido aplicados especialmente a cuestiones metodológicas que surgen en el contexto de los pleitos discriminatorios⁴⁰.

Resulta esencial aplicar un método estadístico válido para asistir al análisis de cada caso legal. Luego, el experto debe prepararse para explicar por qué el método elegido, incluida la regresión múltiple, fue más adecuado que las alternativas.

4. Interpretación de los Resultados de una Regresión Múltiple

³⁸ Detalles adicionales respecto del efecto de interacción son tratados en el Apéndice, no incluido aquí. En el caso *Ottaviani v. State University of New York*, 875 F.2d 365, 367 (2d Cir. 1989), cert. denied, 493 U.S. 1021 (1990), la parte demandada se apoyó en un modelo de regresión con una variable dummy que reflejaba el género como variable explicativa. La mujer demandante, por el contrario, utilizó un enfoque alternativo con un modelo de regresión que sólo había sido desarrollado para los hombres (el supuesto grupo protegido). Los salarios femeninos predichos por esta ecuación fueron comparados luego con los salarios reales; según la demandante, una diferencia positiva implicaría una evidencia de discriminación. Para evaluar las ventajas y desventajas de este enfoque, véase Joseph L. Gastwirth, [A Clarification of Some Statistical Issues in *Watson v. Fort Worth Bank and Trust*](#), 29 *Jurimetrics J.* 267 (1989).

³⁹ Estas técnicas incluyen, entre otras, la [regresión lineal por trozos](#), la [regresión polinómica](#), la [estimación por máxima verosimilitud](#) de modelos con relaciones funciones no lineales, y los [modelos auto-regresivos y de promedios móviles](#) de series de tiempo. Ver Robert S. Pindyck & Daniel L. Rubinfeld, *Econometric Models and Economic Forecasts*, pp. 117–21, 136–37, 273–84, 463–601 (4th ed. 1998).

⁴⁰ Entre los economistas se debate cuál es el modelo mejor modelo en cuestiones de discriminación salarial. Se han comenzado a evaluar enfoques alternativos, incluyendo a los modelos de urna (Bruce Levin & Herbert Robbins, [Urn Models for Regression Analysis, with Applications to Employment Discrimination Studies](#), *Law & Contemp. Probs.*, Autumn 1983, at 247) y, como una forma de corregir los errores de medición, la regresión invertida (Delores A. Conway & Harry V. Roberts, [Reverse Regression, Fairness, and Employment Discrimination](#), 1 *J. Bus. & Econ. Stat.* 75 (1983)). También Arthur S. Goldberger, [Redirecting Reverse Regressions](#), 2 *J. Bus. & Econ. Stat.* 114 (1984); Arlene S. Ash, *The Perverse Logic of Reverse Regression*, in [Statistical Methods in Discrimination Litigation](#) 85 (D.H. Kaye & Mikel Aickin eds., 1986).

Los resultados de una regresión múltiple pueden ser interpretados en términos puramente estadísticos, usando test de significación, o en forma más práctica y menos estadística. Si bien una evaluación del significado práctico de los resultados de regresión casi siempre resulta relevante para un tribunal, los test de significación estadística son adecuados sólo en determinadas circunstancias.

Significación Práctica (no Estadística) de los Resultados de Regresión El significado práctico implica que la magnitud del efecto estudiado no es *de minimis* – es lo suficientemente importante, en términos sustanciales, como para que el tribunal se ocupe del mismo. Verbigracia, si el salario horario promedio es \$40,00/hora, un diferencial salarial de \$0,40/hora entre hombres y mujeres será prácticamente insignificante porque representa sólo un 1% del salario promedio⁴¹. Esa misma diferencia podría ser estadísticamente significativa si fuera estudiada una muestra grande de hombres y mujeres⁴². El motivo es que la significación estadística viene dada, parcialmente, por el número de observaciones en el conjunto de datos. *Caeteris paribus*, la significación estadística de un coeficiente de regresión aumentará a medida que crezca el tamaño de la muestra. Luego, un diferencial de \$10 entre los salarios horarios de hombres y mujeres que sería no significativamente distinto de 0 en una muestra de 20 individuos podría ser muy significativo si la muestra se incrementara hasta 200.

Hay veces en que resultados significativos desde el punto de vista práctico también lo son desde el estadístico⁴³. Sin embargo, también es posible hallar coeficientes estadísticamente significativos con grandes conjuntos de datos que no lo son desde el punto de vista práctico. Y también es posible (especialmente en muestras pequeñas) tener resultados prácticamente significativos pero no significativos estadísticamente. Por ejemplo, supóngase que un experto encara un estudio por daños en un caso de infracción a la ley de patentes y predice “lo que hubieran sido las ventas si no hubiera tenido lugar la infracción” usando datos que van a lo largo del período de infracción. Si sólo hay datos conocidos durante 3 o 4 años del período previo a la infracción, la diferencia entre “las ventas que hubieran sido” y las ventas reales durante el período de la infracción que se alega podría ser significativa desde el punto de vista práctico pero no desde el punto de vista estadístico.

⁴¹ No existe un % de umbral que indique si un resultado es significativo desde el punto de vista práctico.

⁴² El significado práctico también puede aplicarse a la credibilidad global de los resultados de regresión. Así, en [McCleskey v. Kemp](#), 481 U.S. 279 (1987), los coeficientes de las variables raciales eran estadísticamente significativos, pero la Corte se inclinó por no considerarlos legal o constitucionalmente significativos.

⁴³ En [Melani v. Board of Higher Education](#), 561 F. Supp. 769, 774 (S.D.N.Y. 1983). [Ver Robert C. Anderson, “[An Alternative Approach to Higher Education](#)”, en donde se menciona la decisión adoptada por el Juez Gagliardi] Una causa por el Título VII fue llevada contra la Universidad de la Ciudad de New York (CUNY) por haber discriminado supuestamente en contra del plantel de instrucción femenino en el pago de sus haberes. Un enfoque del experto de la parte demandante fue utilizar análisis de regresión múltiple. El coeficiente que reflejaba al sexo del empleado fue aproximadamente de \$1,800 cuando todos los años eran incluidos. Prácticamente (en términos de salarios promedio de esa época) y estadísticamente (al 5% de significación) el resultado fue significativo. Por consiguiente, el tribunal dictaminó que la demandante “había producido evidencia estadísticamente significativa de que las mujeres contratadas como plantel de instrucción a partir de 1972 recibieron salarios sustancialmente más reducidos que hombres de calificación similar”. Id. at 781. Para otro análisis vinculado que involucró comparaciones múltiples, ver [Csicseri v. Bowsheer](#), 862 F. Supp. 547, 572 (D.D.C. 1994) (donde se señala que el experto de la parte demandante halló “instancias estadísticamente significativas de discriminación” en 2 de 37 comparaciones, pero sugirió que “2 de 37 representa groseramente un 5% y escasamente puede ser considerado un patrón discriminatorio”), *aff'd*, 67 F.3d 972 (D.C. Cir. 1995).

Contrastes Estadísticos Un contraste en un pleito específico, un test de hipótesis, ayuda frecuentemente al tribunal a determinar si se produjo una violación de la ley en áreas donde la evidencia directa es inaccesible o inconcluyente. Por ejemplo, un experto puede usar un contraste de hipótesis en casos de discriminación regional o sexual para determinar la presencia de un efecto discriminatorio. La evidencia estadística sola nunca puede demostrar con certeza absoluta la validez de una teoría. Empero, al proveer evidencia *contraria* al punto de vista de que no tuvo lugar una forma particular de discriminación, por ejemplo, el análisis de regresión múltiple puede ser de ayuda al juez de los hechos a fin de evaluar la probabilidad de que se haya producido discriminación⁴⁴. Los test de hipótesis son útiles en análisis de sección cruzada, donde los datos del estudio de regresión han sido elegidos como una muestra de una población en un momento dado del tiempo, y en un análisis de series temporales, donde los datos evaluados cubren un cierto número de períodos. En cualquiera de ambos análisis, el experto puede desear evaluar una hipótesis específica, vinculada habitualmente a una cuestión de responsabilidad o a determinar si existe un impacto medible de una supuesta violación. Por caso, en una cuestión de discriminación sexual, al experto le puede interesar evaluar una hipótesis nula de ausencia de discriminación contra la hipótesis alternativa de que existió discriminación en determinado sentido. Un ejemplo alternativo es un juicio por daños antimonopolístico, donde el experto puede desear probar la hipótesis nula de que no existió impacto legal en contra de la hipótesis alternativa de que ese impacto existió. En todo caso, es importante reflexionar acerca de que el rechazo de la hipótesis nula no es prueba en sí misma de responsabilidad legal. Es posible que se rechace la hipótesis nula y creer que hay que tener en cuenta para los resultados una explicación alternativa distinta de la que implica responsabilidad legal.

Es frecuente que la hipótesis nula se plantee en términos de que cierto coeficiente de regresión es igual a 0. Por ejemplo, en el caso de discriminación salarial, la hipótesis nula sería que no hay discriminación salarial entre sexos. Si se observa una diferencia negativa (que implicaría que las mujeres ganan menos que los hombres, luego de que el experto practicó el control de otras explicaciones legítimas alternativas), la diferencia debe ser evaluada en cuanto a su significación estadística utilizando el *t*-test⁴⁵. El *t*-test utiliza al estadístico *t* para evaluar la hipótesis de que un parámetro del modelo toma un valor particular, habitualmente 0.

Nivel de significación estadística Por convención, en la mayoría de los trabajos científicos el nivel de significación requerido para rechazar la hipótesis nula – es decir, obtener un resultado estadísticamente significativo – es de .05 o 5%. El nivel de significación mide la probabilidad de que la hipótesis nula sea incorrectamente rechazada, en caso de que sea verdadera. Generalmente, cuanto más bajo sea el porcentaje requerido de significación estadística, tanto más difícil resultará rechazar la hipótesis nula; luego a menor probabilidad menos yerros se cometerán al hacerlo. Aunque el criterio del 5% es típico, también provee información útil informar las pruebas de significación más restrictivas al 1% o menos, al 10%.

Al practicarse un contraste estadístico, resulta útil computar un nivel de significación observado, o *p*-valor. El *p*-valor asociado con la hipótesis nula de que un coeficiente de regresión es 0 es la probabilidad de que un coeficiente de tal magnitud, o mayor, haya ocurrido al azar si la hipótesis nula fuera verdadera. Si el *p*-valor fuera menor o igual que 5%, el experto rechazaría la hipótesis

⁴⁴ Ver [International Bhd. of Teamsters v. United States, 431 U.S. 324 \(1977\)](#) (la Corte infirió discriminación a partir de una aplastante evidencia estadística por preponderancia de la evidencia).

⁴⁵ El *t*-test es estrictamente válido sólo si se cumple un número de importantes condiciones. Empero, en muchos modelos de regresión, el test es aproximadamente válido si el tamaño de la muestra es lo suficientemente grande.

nula a favor de la hipótesis alternativa; si el p -valor fuera mayor que 5%, el experto no podría rechazar la hipótesis nula⁴⁶.

Test a una o a dos colas Cuando el experto evalúa la hipótesis nula de que una variable de interés no guarda asociación con una variable dependiente, en contra de la hipótesis alternativa de que existe una asociación, lo adecuado es utilizar un test a dos colas, que permita que el efecto sea tanto positivo como negativo. Un test a una sola cola sería habitualmente utilizado si el experto cree, tal vez basándose sobre otro tipo de evidencia presentada en el juicio, que la hipótesis alternativa es positiva o negativa, pero no ambas. Por ejemplo, un experto podría utilizar un contraste a una sola cola en una cuestión de un alegato de infracción al precio de un producto infractor si cree que la infracción fue cero o negativa. (Las ventas del producto infractor competían con las ventas del producto que fue la víctima, bajando así el precio).

Como al usarse un test a una cola se obtienen p -valores que son la mitad de los p -valores de un test a dos colas, elegir un test a una cola le hace más fácil al experto rechazar una hipótesis nula. Por tal motivo, al usarse un test a dos colas el rechazo de la hipótesis es menos probable. Como elegir una hipótesis alternativa es algo arbitrario, Rubinfeld sostiene que “los tribunales deberían evitar descansar únicamente en un test estadístico definido nítidamente”⁴⁷. “Debería alentarse a informar el p -valor o un intervalo de confianza, ya que brinda información útil al tribunal, sea o no rechazada una hipótesis nula”.

Robustez La idea de robustez – saber si los resultados de regresión son sensibles a pequeñas variaciones de los supuestos (p.ej., que los datos están medidos en forma precisa) – tiene una importancia vital. Si los supuestos del modelo de regresión son válidos, los test estándar de los modelos pueden aplicarse. Empero, cuando se violan los supuestos del modelo, los test estándar pueden sobre- o subestimar la significación de los resultados. Observen que *la violación de un supuesto no necesariamente implica que el análisis de regresión pierda su validez*. Hay algunos casos en los cuales los supuestos del análisis de regresión múltiple no están presentes, pero entonces habrá que utilizar otros métodos estadísticos.

23

Por consiguiente, a los expertos debería alentárselos a que faciliten información adicional más allá de que los resultados de la regresión sean válidos, y si no lo son, en qué medida son robustos. A continuación veremos algunos de los supuestos más importantes del análisis de regresión.

Evidencia de que los Cambios de la Variable Explicativa originan Cambios de la Variable Dependiente En un contexto de regresión múltiple, el experto supone que a menudo los cambios

⁴⁶ Usar 1%, 5%, y a veces, 10% como niveles para determinar la significación estadística sigue siendo un tema controvertido. Se puede decir, por ejemplo, que cuando se utiliza análisis de regresión para fijar precios en un caso antimonopolístico con el fin de contrastar una alternativa relativamente específica de la hipótesis nula (es decir, fijación de precios) un nivel de confianza algo más reducido (un mayor nivel de significación, como 10%) podría ser adecuado. En caso contrario, cuando la alternativa de la hipótesis nula es menos específica, p.ej. la alternativa bastante vaga de “efecto” (p.ej., el aumento de precios está causado por el aumento del costo de producción, la demanda incrementada, un fuerte aumento de la publicidad, o la fijación de precios), un nivel de confianza elevado (asociado con un menor nivel de significación, como por ejemplo 1%) puede ser más apropiado. V. Ramona L. Paetzold, [Problems with Statistical Significance in Employment Discrimination Litigation](#), New England Law Review, Winter, 1991.

⁴⁷ Aparentemente, los tribunales han manifestado su preferencia por pruebas a dos colas. Por ejemplo, ver [Palmer v. Shultz](#), 815 F.2d 84, 95–96 (D.C. Cir. 1987), en cuyo juicio el tribunal encontró que, como algunos recurrentes solicitaban una selección excesiva en determinados empleos, un contraste a dos colas era más adecuado en los casos del Title VII. También [Csicseri v. Bowsher](#), 862 F. Supp. 547, 565 (D.D.C. 1994) (donde se sostuvo que si bien un test a una cola “no carece de mérito”, es preferible un test a dos colas).

de las variables explicativas influyen sobre la variable dependiente, y que los cambios de la variable dependiente no afectan a las variables explicativas – en otras palabras, que no hay *feedback*⁴⁸. A partir de este supuesto, el experto saca la conclusión de que la correlación entre una variable explicativa y la variable dependiente se debe al efecto de la primera sobre la segunda y no a la inversa. Si el supuesto no fuera válido, la correlación espuria podría llevar al experto y al juez de los hechos a una conclusión errónea⁴⁹.

La Figura 7 ilustra la cuestión. En la parte (a), la variable dependiente, Precio, es explicada mediante una estructura de regresión múltiple por tres variables explicativas, Demanda, Costo y Publicidad, sin feedback. En la parte (b), hay un feedback, ya que Precio incide sobre Demanda, y la Demanda, el Costo y la Publicidad tienen efecto sobre el Precio. Pero el Costo y la Publicidad no están afectados por el Precio. Por regla general, no existe un contraste estadístico directo para determinar la relación de causalidad; en su lugar, cuando se le pregunta al experto, debería estar preparado para defender su supuesto basándose en una comprensión de cuál es la conducta subyacente de las empresas o individuos involucrados.

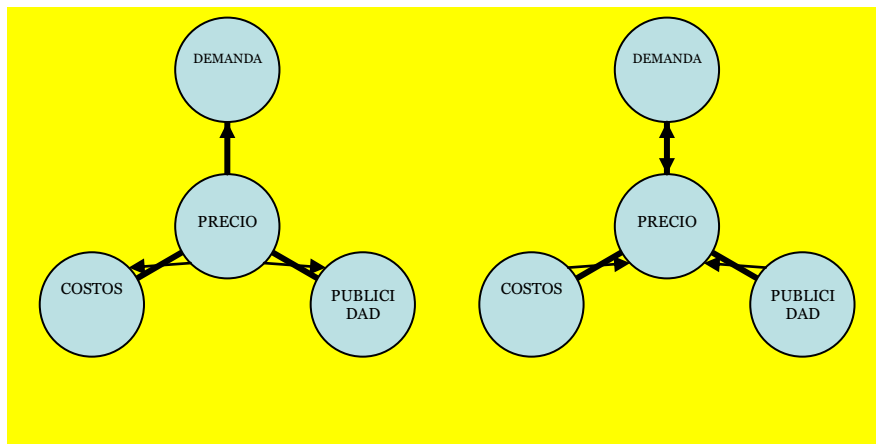


Figura 7 (a)

Figura 7(b)

Aunque no exista un único enfoque que sea completamente aplicable para estimar modelos en los cuales la variable dependiente afecta a una o más variables explicativas, una posibilidad es que el experto omita de la regresión a la variable cuestionada a fin de apreciar si su exclusión implica alguna diferencia. Si no lo hace, la cuestión se torna debatible. Otro enfoque es expandir el modelo de regresión múltiple agregando una o más ecuaciones que expliquen la relación entre la variable explicativa en cuestión y la variable dependiente.

Supóngase, a título de ejemplo, que en un juicio por discriminación sexual en materia salarial el experto del demandado considera que los valores de las pruebas del empleador son una variable explicativa del salario (la variable dependiente). Si el demandante proveyera información de que el empleador ajustó las evaluaciones a fin de penalizar a las mujeres, entonces lo que podría invalidarse es el supuesto de que los salarios se determinan mediante evaluaciones y no que las evaluaciones fueron afectadas por los salarios. Si resulta inapropiada, la variable evaluación de las pruebas debería ser excluida de toda consideración. En forma alternativa, la información sobre el uso que hace el empleador de las evaluaciones podría traducirse en una segunda ecuación con

⁴⁸ Si ambos efectos tienen lugar al mismo tiempo se habla de “simultaneidad”.

⁴⁹ El supuesto de que no existe un feedback es particularmente importante en los pleitos, porque es posible que el defensor (si es responsable, por ejemplo, de la fijación de precios o de la discriminación) afecte a las variables explicativas y termine así sesgando los contrastes usuales en regresión múltiple.

una nueva variable dependiente, la evaluación de la prueba, explicada por el sexo y el salario del trabajador. Un test de hipótesis de que el salario y el sexo afectan las evaluaciones constituiría una prueba adecuada de ausencia de feedback.

Intercorrelación de las Variables Explicativas Resulta esencial en el análisis de regresión múltiple que *las diversas variables explicativas de interés no estén perfectamente correlacionadas con una o más de una de las demás variables explicativas*. Si existiera correlación perfecta entre dos variables, el experto no podría separar el efecto de la variable de interés sobre la variable dependiente del efecto de la otra variable. Supóngase por ejemplo que en un juicio por discriminación sexual se requiere un cierto tipo de experiencia laboral para que tener un salario más elevado. Si todos los hombres tuvieran la experiencia laboral requerida y ése no fuera el caso de las mujeres, resultaría imposible decir si los diferenciales salariales se deben a discriminación sexual o a diferencias de experiencia. Si dos o más variables están perfectamente correlacionadas – o sea, que existe una colinealidad perfecta – la regresión puede estimarse, pero con problemas. A mayor multicolinealidad entre dos variables, tanto menos precisos serán los estimadores de los parámetros de regresión individuales (aún si no existe ningún problema en estimar la influencia *conjunta* de ambas variables y de los restantes parámetros de regresión).

Por fortuna, los estadísticos de regresión informados toman en cuenta si existe alguna multicolinealidad⁵⁰. Como corolario, es importante tener en cuenta que la falla de encontrar una relación estrecha entre una variable de interés y una variable dependiente no implica que no exista ninguna relación⁵¹. Una muestra relativamente pequeña, o una muestra grande con un grado sustancial de multicolinealidad, pueden no facilitarle al experto suficiente información como para determinar si existe alguna relación.

Errores Individuales Independientes del Modelo de Regresión Si el experto calculó los parámetros de un modelo de regresión múltiple usando datos de toda la población es posible que los estimadores midan sus parámetros con errores. Los errores pueden surgir por diversas razones, entre ellas: (1) fallas del modelo al no incorporar las variables explicativas apropiadas; (2) fallas del modelo que no refleja fallas de linealidad que podrían presentarse; (3) inclusión de variables inadecuadas en el modelo. (Naturalmente, otra fuente de error podría surgir porque se usa una muestra o subconjunto de la población para estimar los parámetros de regresión). Resulta útil visualizar el efecto acumulado de todas estas fuentes de errores de modelización como representado mediante un término adicional, el *término de error*. Hay un supuesto importante del análisis de regresión múltiple, que es el siguiente: *el término de error de cada variable explicativa es independiente de los demás*, lo que implica que no están correlacionados entre sí. Si esto es cierto, el experto puede estimar los parámetros del modelo sin incurrir en sesgos; la magnitud del término de error tendrá efecto sobre la precisión con que es estimado el modelo, pero no será una causa de que este estimador sea demasiado alto o bajo. El supuesto de independencia de los errores puede resultar inapropiado en diversas circunstancias. En algunos casos, la falla del supuesto convierte al análisis de regresión múltiple en una técnica estadística inútil; en otros, hay modificaciones o ajustes que permiten que la estructura de regresión se acomode a la falla. El supuesto de independencia puede fallar, por ejemplo, en un estudio de la conducta de los

⁵⁰ V. [Denny v. Westfield State College, 669 F. Supp. 1146, 1149 \(D. Mass. 1987\)](#) (El tribunal aceptó el testimonio de un experto de que “la presencia de multicolinealidad llevaría a sobreestimar el error asociado con el estimador... En otros términos, los p -valores serán artificialmente más elevados que lo que serían si no hubiera un problema de multicolinealidad”).

⁵¹ Si una variable explicativa preocupante y otra variable explicativa están muy correlacionadas, eliminar a la segunda variable de la regresión puede resultar instructivo. Si el coeficiente de la variable explicativa preocupante se torna significativo, se sugiere que existe una relación entre la variable dependiente y la variable preocupante.

individuos a través del tiempo, cuando un error demasiado elevado en un período es seguido por un error demasiado alto en el siguiente. Por ejemplo, si pronostico el PIB de este año muy por debajo del nivel real, lo más probable es que también lo haga el año próximo; el factor causante del error de predicción (p.ej. un supuesto incorrecto sobre el riesgo país) es probable que siga siendo una fuente de error en el futuro.

También es probable que el supuesto de independencia falle en un estudio de un grupo de empresas en un momento determinado del tiempo, cuando el error producido en las empresas grandes sea sistemáticamente mayor que el de las pequeñas. Por ejemplo, un análisis de rentabilidad de las empresas puede que no tome en cuenta en forma apropiada a la publicidad como fuente de incremento de las ventas y los beneficios. Si las firmas más grandes hacen más inversión en publicidad que las pequeñas, los errores de regresión serán más amplios para las grandes empresas y menores para las más pequeñas.

Hay casos en que se dispone de pruebas estadísticas adecuadas para evaluar la hipótesis de independencia⁵². Si falla el supuesto, lo primero que debería hacer el experto es preguntarse si la fuente de la falla de independencia podría deberse a la omisión de alguna importante variable explicativa de la regresión. Si es así, cuando sea posible la variable debería ser incluida, o estimarse el efecto potencial de su omisión en caso que no pueda ser incluida. Si no hubiera ninguna variable explicativa faltante, el experto deberá aplicar uno de los procedimientos que modifican la técnica de regresión múltiple estándar para obtener estimadores más precisos de los parámetros de regresión⁵³.

Sensibilidad de los Resultados de Regresión Los coeficientes de regresión pueden ser muy sensibles a datos puntuales particulares. Supóngase, p.ej., que un dato puntual se desvía en gran medida de su valor esperado, indicado por la ecuación de regresión, en tanto que los puntos restantes no ostentan grandes desvíos. En esta situación no sería de extrañar que los coeficientes de una regresión múltiple cambien sustancialmente si ese dato fuera excluido de la muestra.

Evaluar cuán robustos son los resultados de regresión múltiple es un cometido complejo. Por consiguiente, no existe ningún conjunto de pruebas de robustez que conciten el interés de los econométricos. En general resulta importante explorar los motivos por los cuales hay puntos atípicos. Si la fuente es un error en la captación de datos, será posible hacer correcciones adecuadas. Si todos los datos atípicos tienen ciertas características en común, p.ej. todos están asociados con un supervisor que siempre otorga un puntaje más elevado en un caso de igualdad de haberes, el modelo de regresión debería ser modificado en forma apropiada. Una técnica generalmente útil es determinar en qué medida el parámetro estimado cambia cuando cada punto del análisis de regresión es eliminado de la muestra. Un dato puntual influyente – que causa que el parámetro estimado cambie sustancialmente- debería ser entonces estudiado ulteriormente con

⁵² En los análisis de series temporales, los valores de la correlación de los errores a lo largo del tiempo, o correlación serial, pueden ser contrastados (en la mayor parte de los casos) usando un test de Durbin-Watson. También puede ser contrastada la hipótesis de que algunos términos de error sean elevados en forma consistente, y otros sistemáticamente bajos, problema denominado de *heterocedasticidad*.

⁵³ Si hay presente correlación serial, hay métodos estadísticos estrechamente vinculados que resultan apropiados, como una diferenciación generalizada (que es un método de mínimos cuadrados generalizados) y la estimación mediante máxima verosimilitud. Si el problema es la heterocedasticidad, los mínimos cuadrados ponderados y los estimadores de máxima verosimilitud son apropiados. Todas estas técnicas están disponibles en los programas de cómputo usuales. Estos programas permiten realizar test estadísticos de significación de los coeficientes de regresión.

el fin de determinar si se cometieron errores con el uso de los datos o si fueron omitidas variables explicativas importantes⁵⁴.

Error de Medición de los Datos En el análisis de regresión múltiple se supone que las variables están correctamente medidas⁵⁵. Si hay errores de medición de la variable dependiente, los estimadores de los parámetros de regresión serán menos precisos, aunque no estarán necesariamente sesgados. Empero, si una o más variables independientes vienen medidas con error, los estimadores paramétricos correspondientes estarán probablemente sesgados, muy probablemente hacia cero (y probablemente haya otros coeficientes estimados sesgados).

Para entender por qué, supóngase que la variable dependiente (salario) es medida sin margen de error, y que la variable independiente (experiencia) está sujeta a un error de medición. (La antigüedad en la empresa o los años de experiencia deberían ser exactos, pero el tipo de experiencia está sujeto a error, ya que los postulantes pueden exagerar sus responsabilidades laborales previas). A medida que crece el error de medición, los parámetros estimados asociados con la variable experiencia tenderán a 0, es decir que eventualmente no existirá relación alguna entre salario y experiencia.

Resulta importante que toda fuente de error de medición sea cuidadosamente evaluada. En algunos casos, poco podrá hacerse para corregir el problema de error de medición; los resultados de regresión deben ser interpretados a la luz de este hecho. En otros casos, el experto podrá corregir el error de medición buscando nuevas fuentes de datos más confiables. Finalmente, hay técnicas de estimación alternativas (que usan variables relacionadas medidas sin error) que pueden ser aplicadas a fin de remediar el problema del error de medición en ciertas situaciones⁵⁶.

5. Expertos

El análisis de regresión múltiple es dictado a estudiantes en campos tan diversos como la estadística, la economía, las ciencias políticas, la sociología, la psicología, la antropología, la salud pública y la historia. En consecuencia, un individuo con entrenamiento sustancial y experiencia en regresión múltiple y otros métodos estadísticos puede ser calificado de experto. Un grado doctoral en una disciplina que dicta estadística teórica o aplicada, como la economía, la historia y la psicología, significa habitualmente para otros científicos que el experto propuesto satisface las pruebas preliminares del proceso de calificación.

La decisión de calificar a un experto en análisis de regresión pertenece al tribunal. Obviamente, el experto propuesto debería ser capaz de demostrar que entiende de lo que se trata. Indicadores de la experiencia profesional serían las publicaciones realizadas vinculadas con análisis de regresión en *journals* calificados por sus pares, la pertenencia activa a organizaciones profesionales vinculadas, cursos dictados sobre métodos de regresión, y su experiencia práctica con el análisis econométrico. La capacidad y experiencia con respecto a las cuestiones aplicables en cuestiones

⁵⁴ Para un tratamiento más completo y formal del problema del carácter robusto de una regresión ver David A. Belsley et al., *Regression Diagnostics: Identifying Influential Data and Sources of Collinearity* 229–44 (1980). Una útil discusión de los valores atípicos y la evaluación de los conjuntos de puntos con influencia está en R.D. Cook & S. Weisberg, [Residuals and Influence in Regression](#), in *Monographs on Statistics and Applied Probability* (1982).

⁵⁵ La imprecisión puede darse no solamente con respecto a la variable particular medida, sino también a la precisión con que la variable medida corresponde al constructo teórico apropiado especificado por el modelo de regresión.

⁵⁶ V. Robert S. Pindyck y Daniel L. Rubinfeld, *Econometric Models and Economic Forecasts*, McGraw-Hill International Edition, 4th edition, 1998, pp. 178-98 (discusión de la técnica de variables instrumentales).

específicas e instrumentos aplicables a un caso particular también deberían ser consideradas durante el proceso de calificación.

6. Presentación de la Evidencia Estadística

Los costos de evaluar la evidencia estadística pueden reducirse, y aumentarse la precisión de esa evidencia, si el proceso de descubrimiento se usa de manera efectiva. Cuando se evalúa cuán admisible es la evidencia estadística, un tribunal debería prestar atención a las dos cuestiones siguientes:

- ¿Acercó el experto información suficiente como para replicar el análisis de regresión múltiple?
- ¿Son razonables las decisiones metodológicas hechas por el experto, o resultan arbitrarias e injustificadas?

En general, realizar una presentación clara y comprensiva de la metodología de investigación subyacente forma parte integral del proceso de descubrimiento. Al experto debería alentársele a que revele tanto la naturaleza de los experimentos llevados a cabo como la sensibilidad de los resultados a los datos y a la metodología. Las sugerencias son:

- En la medida posible, a las partes se las debería alentar a que usen una base de datos común. Aunque haya desacuerdo sobre lo que esos datos significan, un acuerdo oportuno sobre una base de datos común ayuda a concentrar el esfuerzo de descubrimiento sobre las cuestiones importantes del caso.
- Una parte que ofrece datos a ser utilizados en el trabajo estadístico, incluyendo tareas de regresión múltiple, debería ser alentada a proveer lo siguiente a las otras partes: (a) si está disponible y es de tamaño manejable, un *hard-copy* de los datos con sus fuentes subyacentes; (b) soportes magnéticos de computación de los datos grabados; (c) documentación completa de los discos, cintas, etc.; (d) los programas de computación usados para generar los datos (*hard-copy*, los discos o cinta, o ambos); y (e) la documentación de esos programas de computación.
- La parte que ofrece los datos debería poner a disposición de las otras partes al personal involucrado en la compilación de datos para responder a preguntas técnicas sobre los datos y los métodos de recopilación o de compilación.
- Una parte que ofrece una regresión de un experto en un juicio debería pedirle al experto que informe plenamente sobre: (a) la base de datos y sus fuentes⁵⁷; (b) el método de recolección de datos; y (c) los métodos de analizarlos. Si es posible, esta información debería ser proporcionada con bastante antelación al juicio, de tal manera que la parte oponente pueda consultar a sus expertos y preparar un examen cruzado. El tribunal debe decidir caso por caso dónde debe establecerse la línea de revelación de los datos.
- A la parte oponente debe dársele la oportunidad de objetar la base de datos o el método de análisis de la base de datos ofrecida en el juicio. Las objeciones pueden ir desde errores cometidos por los oficinistas a cuestiones más complejas vinculadas con la selección de

⁵⁷ Estas fuentes incluyen todas las variables utilizadas en los análisis estadísticos realizados por el experto, no solamente las variables utilizadas en el análisis final sobre el que los expertos esperan fundamentarse.

datos, la construcción de variables, y a veces la forma particular del método estadístico utilizado. Si es posible, estas cuestiones deberían ser resueltas antes del juicio.

- A las partes se las debe alentar a que resuelvan sus diferencias en cuanto al carácter apropiado y precisión de los datos, en la medida que sea posible mediante una conversación informal. El tribunal debería hacer un esfuerzo en resolver las diferencias con anterioridad al juicio.

Las siguientes pautas⁵⁸ son sugeridas para que los expertos presenten sus bases de datos y procedimientos analíticos. Seguir las puede ser de gran utilidad para resolver disputas en cuestiones estadísticas.

- El experto debe establecer claramente los objetivos del estudio, así como el período de tiempo al que es aplicable y la población estadística cuyos resultados son proyectados.
- El experto debe informar las unidades observadas (es decir, consumidores, empresas, o empleados).
- El experto debe medir cada variable en forma clara.
- El experto debe identificar claramente la muestra a partir de la cual fueron estudiados los datos⁵⁹, como así también el método mediante el cual dicha muestra fue extraída.
- El experto debe revelar si hay datos faltantes, ya sea causados por su indisponibilidad (p.ej. datos comerciales) o ausencia de respuesta (p.ej., en datos censales) y el método que fue seguido para su tratamiento (p.ej., supresión de observaciones).
- El experto debe informar las investigaciones realizadas con respecto a los errores asociados a la elección de variables y de supuestos que subyacen en el modelo de regresión.
- Si las muestras fueron seleccionadas al azar en una población (es decir, que se siguió un muestreo probabilístico)⁶⁰, el experto debe hacer un esfuerzo de buena fe para proporcionar una estimación del error muestral, la medición de la diferencia entre el estimador muestral de un parámetro (como la media de la variable dependiente estudiada) y el parámetro poblacional (desconocido) – la media poblacional de la variable⁶¹.
- Si fueron utilizados procedimientos no probabilísticos, el experto debe informar acerca del conjunto de procedimientos utilizados para minimizar los errores muestrales.

⁵⁸ Una discusión más completa de estos requerimientos será hallada en Lirieka Meintjes-Van der Valt, [The Proof of the Pudding: The Presentation and Proof of Expert Evidence in South Africa](#), *Journal of African Law*, 47, 1 (2003), 88–106; School of Oriental and African Studies.

⁵⁹ Esto es importante porque le permitirá realizar inferencias sobre la población relevante.

⁶⁰ En un muestreo probabilístico, cada representante de la población tiene una probabilidad conocida dentro de la muestra. El muestreo probabilístico es ideal porque está muy estructurado, y en principio puede ser replicado. Los muestreos no-probabilísticos son menos deseables porque con frecuencia son subjetivos, y descansan en gran medida en el juicio del experto.

⁶¹ Los errores muestrales son frecuentemente informados en términos de errores estándar o intervalos de confianza.

Bibliografía complementaria

- American Bar Association Section of Antitrust Law Economics Committee, Selected Readings in Antitrust Economics: Applied Econometrics (July 2008).
- Fisher, Franklin M. "Multiple Regression in Legal Proceedings", 80 Colum. L. Rev. 702, 1980.
- Fisher, Franklin M. and Daniel L. Rubinfeld, U.S. v. Microsoft - An Economic Analysis, The Antitrust Bulletin, Spring 2001.
- Jonathan B. Baker and Daniel L. Rubinfeld, Empirical Methods in Antitrust: Review and Critique, American Law and Economics Review, Fall 1999, pp. 386-435.
- Lichtman, Allan J. Passing the test - Ecological Regression Analysis in the Los Angeles County Case and Beyond, Evaluation Review (ER), Vol.15, N° 6, Dec. 1991.
- Meyerson, Michael I. Significant Statistics: The Unwitting Policy Making of Mathematically Ignorant Judges, Pepperdine Law Review and SSRN, 2010.
- Rubinfeld, Daniel L. Econometrics in the Courtroom, Columbia Law Review, June 1985, pp. 1048-1097.
- Rubinfeld, Daniel L. Reference Guide on Multiple Regression, in Reference Manual on Scientific Evidence, 2nd ed., Federal Judicial Center (2000), pp. 179-227.
- Schmidheiny, Kurt Functional Form in the Linear Model, Universitat Pompeu Fabra, Fall 2009.
- Sykes, Alan O. An Introduction to Regression Analysis, Chicago Working Paper in Law & Economics.