

MARKETING RESEARCH IN THE 21ST CENTURY: OPPORTUNITIES AND CHALLENGES

Joe F. Hair, Jr.

University of South Alabama

Dana E. Harrison

East Tennessee State University

ORCID: 0000-0002-7250-9522

Jeffrey J. Risher

University of West Florida

ORCID: 0000-0002-0359-2668

Received on:

05/29/2018

Approved on:

08/30/2018

Responsible Editors:

Prof. Dr. Marcelo Luiz Dias da Silva Gabriel

Prof. Dr. Dirceu da Silva

Evaluation Process:

Guest Paper

Abstract

The role of marketing is evolving rapidly, and design and analysis methods used by marketing researchers are also changing. These changes are emerging from transformations in management skills, technological innovations, and continuously evolving customer behavior. But perhaps the most substantial driver of these changes is the emergence of big data and the analytical methods used to examine and understand the data. To continue being relevant, marketing research must remain as dynamic as the markets themselves and adapt accordingly to the following: data will continue increasing exponentially; data quality will improve; analytics will be more powerful, easier to use, and more widely used; management and customer decisions will increasingly be knowledge-based; privacy issues and challenges will be both a problem and an opportunity as organizations develop their analytics skills; data analytics will become firmly established as a competitive advantage, both in the marketing research industry and in academics; and for the foreseeable future, the demand for highly trained data scientists will exceed the supply.

Keywords: Big Data. Data Analytics. Data Quality. Marketing Analytics. Marketing Research.



Marketing Research in the 21st Century: Opportunities and Challenges

The role of marketing for consumers and businesses is rapidly evolving (Ferrell, Hair, Marshall & Tamilya 2015). Indeed, the marketing function is fundamentally changing as a result of the digital transformation, data, data analytics and most recently, personal mobile devices, such as infusion software, which track time as individuals work or play, can search for local businesses or customers while in a coffee shop, send an invoice or quote from a client's office, and much more (Shah et al 2014). Marketing research design and analysis methods are also changing rapidly (Hair, Black, Babin & Anderson 2019). These changes are emerging from transformations in management skills (Henke, Levine & McInerney 2018; Davenport 2018), technological innovation, particularly in the digital space (Davenport 2018), and continuously evolving customer behavior (needs and expectations) (Wedel & Kannan 2016). To continue being relevant, marketing research must remain as dynamic as the markets themselves.

At the same time, academic research is increasingly applying advanced analytic tools and algorithms (Erevelles, Fukawa & Swayne 2016; Syam & Sharma 2017, Wedel & Kannan 2016; Petrescu & Krishen, 2017), and even artificial intelligence in combination with neural networking (Ababukar et al. 2017). Just as advanced analytics is providing key competitive advantages in industry practices, it also is forcing rapid changes in social sciences academic research (Krishen & Petrescu 2018).

Directions for research, particularly marketing and related social sciences, include applications of advanced analytics techniques and technologies. Wedel and Kannan (2016), for example, suggest how machine learning methods and cognitive computing technologies can be applied to better understand marketing

problems and opportunities. Similarly, Erevelles, Fukawa and Swayne (2016) identify propositions that examine big data solutions to various marketing activities, as well as how these findings can be applied to develop sustainable competitive advantages. Syam and Sharma (2017) highlight the importance of understanding how machine learning (ML) and artificial intelligence (AI) can advance marketing research, and Abadular et al. 2017) propose ways to apply AI and neural networking. Thus, as these and other parallel developments are applied to expand our knowledge of marketing and consumer behavior trends, businesses can more effectively meet consumer needs and reduce information overload.

The purpose of this article is to suggest how emerging market trends, and particularly those in marketing, are likely to impact marketing research. First, we will explore the emerging role of the marketing function that is developing from new business models. Second, we will examine the implications of this change on academic marketing research. Finally, we will address transformations that are likely to continue evolving in the future.

Emerging Role of Marketing and Marketing Research

Numerous developments are influencing marketing, and thereby marketing research. Among the most important developments are the following:

Modern Markets

Perhaps one of the most important trends impacting marketing research is internet-based markets. Business models such as the sharing economy or digital matching firms have emerged from advanced technology platforms and become highly successful,

digitally connected marketplaces (Harrison & Hair 2017). Examples include internet-based companies such as Uber, Amazon, Airbnb, Salesforce and Netflix that have forged successful new business models, ultimately revolutionizing industries. While these developments have been gradually materializing over the last 20 years, their full impact is now becoming evident.

Customers and companies have collectively become less averse to risks often associated with online transactions, and this has fueled growth among these emerging business models. Furthermore, dynamic customer behavior and market changes have contributed to the need for greater convenience and more personalized experiences than initially offered through online markets. For example, faster moving trends in clothing fashions and fads is one of many market developments that can be attributed to the capabilities of internet-based products and services. But there are many other examples. In essence, innovative companies have developed and mastered value propositions that more effectively respond to market opportunities, and more closely fulfill customer wants and needs.

A critical component that has emerged along with these new value propositions is digital data, which has enabled both businesses and consumers to not only be more informed than ever before, but also to sell and seek almost all products and services completely online. For example, if you have a My Google account it is tracking your activities 24/7. One individual checked the number of items tracked over a period of time and found that on average, more than 200 activities were added to their My Google account per day, which is more than 73,000 per year. Who would have thought a few years ago that individuals would not only be sharing their personal data, but bicycles and cars instead of buying them, not to mention being willing to give organizations such as Google or Facebook access to huge amounts of

their personal data, or to use their mobile phone to search for and purchase groceries, or almost any other product or service they want.

Emergence of Big Data

Companies and customers are producing large amounts of data from various touchpoints. On the customer side data is captured through heavily promoted omnichannel experiences. As examples, consider Target's buy online and immediate pickup in store, Amazon's prime membership and associated sales and shipping relationships, or FedEx's use of blockchain methodology for managing customer dispute data and as an efficient method for tracking packages, all are producing mountains of useful information for both business and consumer sides of transactions. Perhaps the most pervasive data collector is Google, which has trackers on almost 80 percent of all websites (except China, where Google withdrew because they refused to permit censoring of information). Similarly, on the B-to-B side General Electric and Boeing are installing sensors in jet engines, robots are being coordinated to manufacture many products, such as autos and airplanes, sensors are enabling vehicle brands such as Volvo, Tesla, Mercedes, BMW, and others to market self-driving cars, and many other distribution and manufacturing innovations, all of which are also collecting data across the entire manufacturing and distribution ecosystem to generate actionable and valuable insights. As a result, companies can better manage production, understand and respond to customer requirements, and add value. With this emerging resource of data, they can more intelligently manage their businesses, improve response times, promote innovation, reduce costs, and boost revenues and profits.

Data changes power within the organization. Today only about five percent of the U.S. economy is the data economy – small

now but the percent is expanding exponentially. In the past, data was the responsibility of the Chief Information Officer (CIO), a staff position. Last year (2017) in the U.S., for the first time more of the information technology budget was spent by line managers than CIOs. For CIOs, the security of data systems is a priority. In contrast, CMOs and CFOs care about business execution. The Equifax data breach of 2017 was likely a result of this transition in responsibility for data security. At the same time, for individuals trained in the business college it is likely surprising that over 15 percent of CEOs are now data scientists – they do not have an MBA degree!

Data and data analytics have the potential to change the economic order of the world in ways that will be disturbing to many companies and people. Moreover, knowledge-based data will likely become a source of power that is difficult to challenge for countries and companies lacking this knowledge and these skills. In short, data and analytics have become to the 21st century economies what oil was to the 20th – a valuable asset essential to a better economic life. It appears, therefore, that we are on the brink of a new data world, and this will definitely change both marketing and marketing research.

On the data analysis side, advanced technology and lower costs are now capable of storing and processing the large amounts of data from these various interactions. Storage costs of one megabyte of information, for example, have dropped from \$15.00 U.S. in 1992, to less than 10 cents U.S. for one megabyte in 2017. But, as more data is produced and stored, there is a greater need to apply advanced marketing analytics methods to gain a more sophisticated understanding of the data, not only related to what is selling and through which channels, but to produce improved measures of return on marketing investments,

customer lifetime value, drivers of customer loyalty, and so forth.

Transformative Marketing

As the amount, type (structured and unstructured), and complexity of data changes, so do the methods of research necessary to support these developments. The variety, velocity and volume of data stems from changing marketing environments, emerging technology, and the lower cost of collecting and storing data (Erevelles, Fukawa & Swayne 2015; Kumar 2018; Varadarajan 2018; Davenport 2018). Examples of drivers of data creation include evolving customer purchase behavior, the internet of things, digital wearables, the rise of artificial intelligence, enhanced supply chain technology, and the ability to embed analytics into sales, distribution, and production systems, to mention a few (Kumar 2018). Facebook alone has over 200 billion photos stored in the Cloud, and more than 350 million new photos are uploaded every day. In response to these drivers, marketing strategies, organizational decisions and performance are being revolutionized by information assets, analysis capabilities, and increased customer knowledge.

Changing Role of Marketing Research

There is value in both traditional research approaches that examine, for example, hypotheses derived from practice and theory, as well as predictive analytics that commonly emphasize solving business problems with data (Babin, Griffin & Hair 2015; Delen & Zolbanin 2018). Indeed, tools and techniques are increasingly available that inform different levels of sophisticated intelligence (Davenport & Harris 2017). These tools and techniques range from simple spreadsheet analyses used by companies to understand how many, how often or why something occurred, to predictive

tools that help to explain and forecast what is likely to happen, and automated machine learning tools that are applied to obtain insights from data. In short, all levels of sophistication offer the potential for competitive advantages (Davenport & Harris, 2017). But increasingly companies must adopt and rely on the more sophisticated tools available. What is often overlooked, however, is that machine learning, increasingly coupled with artificial intelligence, often requires human intervention to execute and complete the analyses. Thus, the role of marketing researchers will both expand as well as increase in complexity, requiring much more advanced training.

The following paragraphs provide an overview of how three marketing research approaches – descriptive, predictive and prescriptive analytics – are evolving and changing.

Traditional Descriptive Analytics

Traditional research often uses descriptive and diagnostic methods. This type of research is more explanatory and confirmatory in nature (Sivarajah, Kamal, Irani & Weerakkody 2017). For example, key performance indicators (KPIs) provide real-time dashboard visualizations for understanding how effective and efficient the company is in achieving business objectives such as sales performance, inventory control management or supply chain responsiveness. Although valuable as historical metrics, this confirmatory feedback offers only limited predictive insights as to whether future results will be similar. But it will continue to be very useful for marketers as a means of monitoring day-to-day operations, and marketing researchers will need to provide support for better understanding and explaining market developments, as well as suggesting innovative ways to apply this information.

Data used in descriptive analytics can be found within and external to the organization. Companies often collect data on a regular basis regarding customers and competitors, but also use data from external sources such as data.com. Although the amount of internal data is much easier to collect at this point, it is likely that the future will bring advanced technology resources that permit organizations to more efficiently collect data from external sources.

Predictive Analytics

Advanced technology combined with complex algorithms facilitates predictive analytics approaches. These emerging techniques examine mountains of data to promote narratives for more effectively assessing opportunities as well as predicting future developments. In short, predictive analytics applies modeling tools to data to predict future market developments and trends (Davenport & Harris 2017). Researchers have categorized predictive analytics into two categories: regression techniques and machine learning techniques (Gandomi & Haider 2015), both of which are increasingly core elements of marketing research programs.

While predictive analytics typically requires some level of human intervention, there is often flexibility in the level of involvement (e.g., selecting target variables, developing theoretically derived models, permitting the data to tell a story). Big data obtained from many sources, potentially containing thousands and even millions of driver variables, is analyzed using hundreds of analytical models. But this type of modeling presents substantial challenges compared to traditional methods (Davenport & Harris 2017), and requires more knowledgeable data analysts than in the past. For example, with many sources and types of data (both structured and unstructured) integrated into a single database,

it is virtually impossible to hypothesize every possible relationship. According to Peter Norvig (2009), Google's Research Director, the large amount of data and resulting complexity of the relationships often make it advantageous for computers to derive models from the data, versus having humans initially spend time using scientific approaches to identify possible models. Computers, therefore, explore the data to locate hidden relationships that otherwise often would not be identified, and then develop predictive models that support tentative conclusions and facilitate strategic decision-making.

Predictive analytics is increasingly being applied in the corporate sector as well. Not only by the largest companies but now some middle sized ones are using predictive analytics, But to do so still involves considerable human intervention from marketing and data analysts. Competent individuals must be able to select the appropriate analytical method, and when solutions are identified someone has to interpret them in terms of logic, relevance to business problems, and ultimately strategic value. The problem is there are not enough qualified data scientists to make these decisions. McKinsey estimates the U.S. alone faces a shortage of 140,000 to 190,000 people with analytical expertise, and 1.5 million managers and analysts with the skills to understand and make decisions based on the analysis of big data. In response to this need, U.S. universities have added more than 100 data analytics bachelor's degree programs in the past five years, with more being added every year.

Prescriptive Analytics

Prescriptive analytics is an advanced level of analytics that examines what should be done or what can be done to make something happen. Prescriptive analytics enables

marketing researchers to determine optimal behaviors and evaluate the eventual business impact (Davenport & Harris 2017; Sivarajah et al. 2017). To accomplish this, prescriptive analytics experiments with and optimizes various scenarios at an accelerated rate, and is at less risk for subjective human interpretation (Davenport & Harris 2017). This may be good if the analytics work well, but may not be so good otherwise. Thus, prescriptive analytics while not completely autonomous at this point can produce implications and generate recommendations. As one example, FleetPride, a provider of truck and trailer parts for customers across many industries, found success in implementing prescriptive analytics. Using solutions offered by IBM, results provided supply chain managers with insights to operate seamlessly; allowing the company to optimize distribution networks, increase the speed of inventory flow and reduce warehouse packing errors. Although the number of organizations using prescriptive analytics is growing, it is difficult to know the level of adoption. Unfortunately, it isn't uncommon where adoption has occurred in departmental or unit silos, that others throughout the organization are often unaware that prescriptive analytics has been implemented (Rossi 2015). Of course, the key to successful prescriptive analytics relies, as with predictive analytics, on the skills of the data scientists executing it, and there is a global shortage of trained individuals in this area as well.

Where does Marketing Research go from here?

Sophisticated tools and techniques are being readily adopted in market research practice, with budgets increasingly dedicated to the purchase of advanced analytics solutions (Mela & Moorman 2018). With the constantly evolving data inputs (e.g., technologies), data types (e.g., unstructured data) and changing

customer behavior, it's important for marketing research to remain managerial relevant and timely. Several relevant questions are to what extent should marketing researchers and data scientists allow these new analytical tools to develop models and outputs without first developing theoretically derived hypotheses? Where is the place in marketing research for the integration of predictive and prescriptive tools? How could this method develop new theories and add value to the field? How can marketing research apply software such as SAS/STAT for predictive modeling, LIWK for text analysis, social media network analysis tools such as NodeXL or machine learning tools such as DataRobot? How are artificial intelligence (AI) solutions be applied, such as Salesforce Einstein that not only offers predictions but also makes recommendations on how to respond to customers, impacting salesforce capabilities? Marketing research must remain cognizant of the evolution in big data and analytics, understand how and when to use these methods in research, and maintain pace with managerial priorities in practice.

Changes in Methodology and Research Design

Parallel to the evolution in advanced techniques and tools, we are also witnessing changes in research designs and methodologies.

The Use of Survey Data

In the 1980s more than 2/3 of scholarly published papers were survey or interview based. But by 2013, the number of survey-based published papers in the three top marketing journals [Journal of the Academy of Marketing Science (JAMS), Journal of Marketing (JM), and Journal of Marketing Research (JMR)] was only about 1/3 (Hulland, Baumgartner & Smith 2018). To collect data, researchers increasingly

have relied on do it yourself, online survey methods such as Qualtrics, Google Survey, Mechanical Turk, and Survey Monkey (Hulland & Miller 2018). Companies and researchers alike are capitalizing on the digital transformation to reach survey participants via online platforms. Online platforms have provided convenient access to business and consumer samples that were difficult, costly and often impossible to reach. Unfortunately, populations are being over surveyed resulting in refusals to respond, and the proportion of survey-based papers has started to decline (Hulland, Baumgartner & Smith 2018). Another issue noted by numerous social sciences disciplines, and particularly management and supply chain groups, is single respondent survey designs. In this type of design, the same survey respondent answers questions related to both the independent and dependent variables, producing what is referred to a common methods bias (Krause, Luzzini & Lawson 2018; Kull, Kotlar & Spring 2018; Flynn, Pagell & Fugate 2018; Roh, Whippe & Boyer 2013). Other disciplines, including marketing, have raised similar concerns and are suggesting designs that combine secondary data with primary data as a solution. Unfortunately, to date no method of precisely measuring the extent of common methods bias in survey designs has been developed.

Shift Towards Objective Data

With the emergence of digital data, and lots of it, researchers have shifted toward collecting objective, secondary data. Archival or proprietary information, such as historical data, is readily available to researchers (Verma, Agarwal, Kachroo & Krishen 2017). Using historical data, event studies (Sorescu, Warren & Ertekin 2017) can examine the long-term impact of a particular decision on the firm. Businesses and researchers alike are focused on predictive and prescriptive strategies,

enhanced by artificial intelligence (Huang & Rust 2018) and machine learning (Antons & Breidbach 2018). To some extent, these techniques are capable of producing self-correcting analyses, while others such as mathematical optimization, “determine the best solution to mathematically defined problems” (Snyman 2005). In consumer markets, for example, digitalization has facilitated the availability of physiological data. In fact, across the board more technical research methods include biometric and neurological focused data (Chan, Boksem & Smidts 2018; Harris, Ciorciara & Gountas 2017). These techniques, initially emerging in economics, finance, computer science and medical research, are now becoming more prevalent and infused in marketing research, and the social sciences in general. As we look to the future, these evolving research methods will become a critical resource in the dynamic and ever changing business-to-business and consumer markets.

The Rise of Unstructured Data

Digital marketing through areas such as social media has produced substantial unstructured content (Balducci & Marinova 2018) that can be submitted to text analysis (Humphreys & Wang 2017), and increasingly coded for quantitative modeling. In fact, the conversion of unstructured data for quantitative analysis is expanding rapidly since 90 percent of all data is unstructured. Unstructured data includes tweets, photos, service call logs, blogs, customer complaint and comment data, customer purchase behavior, and so forth, all of which has to be analyzed and coded before being submitted to quantitative data analytics software. Programs such as NodeXL an LIWC are used to enhance quantitative modelling (Harrison, Ajjan & Coughlan 2018). Through the collection and analysis of unstructured data, such as digital text or comments, companies and researchers

extend their expertise in segmentation, customers’ level of engagement and experience, social networking and sentiment analysis, which also creates expanded opportunities for market researchers.

Greater Focus on Relevance and Rigor

As data and analytical methods become more complex, marketing research is also experiencing a shift toward more rigorous techniques. Researchers should use every reasonable approach to disprove their hypotheses versus feeling it necessary to statistically support hypotheses to make a contribution (Babin, Griffin & Hair 2015). For example, endogeneity, statistical power (effect size), external validity and predictive relevance play an important role in the accurate assessment of relationships between exogenous (independent) and endogenous (dependent) variables.

For many years, marketing researchers have examined observed heterogeneity. Observed heterogeneity is based on the knowledge that subgroups of populations likely exhibit differences, and also that these differences are known when the research is designed and conducted. For example, male and female consumers often exhibit different search and shopping patterns, and ultimately purchase behavior. For consumers, observed heterogeneity typically has been based on demographics. For organizations, observed heterogeneity has been based on company size, product or service offerings, convenience, and so forth. More recently, technology has enabled data analysts to examine the possibility of unobserved heterogeneity, or that populations consist of subgroups of the population that are not easily observable. Knowledge regarding the presence of unobserved heterogeneity is critical in today’s empirical studies, and if not explored it potentially threatens the validity of measurement and structural models examined

when applying both descriptive and predictive analytics (Becker, Rai, Ringle & Volckner 2013; Sarstedt & Ringle 2010; Hair, Matthews, Matthews & Sarstedt 2017). Both industry and academic researchers are rapidly making strides to develop advanced statistical analyses that effectively address potential reliability and validity issues.

Although these issues have long been a concern in marketing research, enhanced statistical methods enable researchers to address them more rigorously (Hult, Hair et al. 2018; Worm, Bharadwaj, Ulaga & Reinartz 2017). Regression based analyses function on the assumption of minimal multicollinearity. At the same time, however, moderation occurs when two or more factors covary enough to alter the impact on the outcome. If the moderation is known or suspected, it can be tested with either continuous or categorical variables. This is particularly useful for identifying hygiene variables or boundary conditions.

Academicians and practitioners are increasingly using sophisticated software to execute predictive analytics. One example, the SmartPLS software (www.SmartPLS.de) is cutting edge in terms of analytics, and a preferred option for many scholars and practitioners because it is very user friendly. The software executes multi-group analysis in SmartPLS and can be used to examine observed heterogeneity, in which known groups are proposed to behave differently (e.g., female/male comparisons; large/small businesses), as well as unobserved heterogeneity (Sarstedt et al., 2017; Hair et al., 2016; Matthews et al. 2016). Multi-group analyses (MGA) assist researchers in discovering if differences exist in the parameter estimates (e.g., outer weights, outer loadings and parameter estimates) of pre-defined data groups (Matthews, Hair & Matthews 2018). In PLS-SEM, MGA is beneficial in efficiently examining moderation across multiple

relationships (Hair, Sarstedt, Ringle & Mena 2012). Another increasingly popular software is R, which is widely used among statisticians and data scientists to execute data analysis. Unfortunately, it is not very user friendly but is open source and free.

If moderators are unknown ahead of time, this type of analysis becomes more difficult. Often, clusters appear which have similar values for certain variables. These types of groups cannot be accurately defined by any particular demographic or descriptive data variable. This type of moderation can be difficult to predict or even identify. In these cases, prediction-based techniques should be used to identify segments that may be creating unexplained heterogeneity. In addition, several statistical software packages offer researchers the opportunity to further verify external validity and predictive relevance (www.smartpls.de, www.r-project.org; Schmueeli, Ray et al. 2016).

Focusing on PLS-SEM, researchers have proposed the methodological application of prediction-oriented segmentation (PLS-POS) and finite mixture partial least squares (FIMIX-PLS) segmentation as methods to overcome prior limitations of identifying unobserved heterogeneity. Other heuristic techniques should be used when the heterogeneity found in these effects is sequential. This goes far beyond longitudinal analysis, and often this type of variance results from nested effects, due to the order of effects, seasonality, grouping, etc. Traditionally, HLM has been used to identify these in econometrics. In machine learning, Bayes theorem is used to overcome the cross sectional nature of these situations. Bayes theorem assumes that error terms vary depending on the situation or order of the effects. Bayesian modeling uses what is known to predict the unknown. Furthermore, Markov Chain Monte Carlo (MCMC) modeling, such as Bayesian techniques, consists of algorithms focused on probability distributions for large

multi-dimensional, hierarchical models and unknown parameters. The method is advantageous when a high level of uncertainty exists and historical information is scarce, and can be used to investigate information across multiple sources of data (Rossi & Allenby 2003). The use of Bayesian methods has increased in parallel with the digital transformation driven by internet use.

Marketing research, particularly academic, has welcomed the adoption of Bayesian techniques and applied the method to address many aspects of marketing (Rossi & Allenby 2003) such as advertising (Agarwal, Hosanager & Smith 2011), customer choice (Chung, Rust & Wedel 2009) and customer relationships (Netzer, Lattin & Srinivasan 2008). Although data is plentiful, digitalization has magnified the unknown in consistently evolving, dynamic environments.

Concluding Observations

As should be evident, much has changed in marketing and marketing research in the past few years. Many more changes are anticipated in the next few years. The following summarizes our thoughts about future developments. Predictions of the future are clearly risky. Many intelligent individuals have attempted to forecast the future – and often been proven wrong. Our thoughts are based on what we believe is sound reasoning, but like others in the past it is unlikely that our thinking will be entirely as it appears to us today. We do believe that we are mostly correct and ask that you view our thoughts as at least directional – as we are confident about the direction but not necessarily the specifics.

Data Will Continue Increasing Exponentially

The first discussions of the rapid expansion of data began at least 70 years ago, well before the current widespread interest in

big data and its impact. It was then when the first attempts to quantify the growth rate in data began, and for the next 50 or so years this trend was referred to as the “information explosion”. At about the same time (1941), the Oxford English Dictionary for the first time included the term information explosion in its list, and many other data terms have been added since.

Among the first business authors to write about this phenomenon was Tom Peters in his 1991 book titled *Thriving on Chaos*. While his book predicted many broad economic changes occurring at that time, the phrase most relevant to big data was *We are drowning in information and starved for knowledge*. He went on to note that the difference in information and knowledge is that information consists of only words and numbers that may be interesting, but they are not useful for decision-making. Moreover, the thinking in that day was that perhaps only five percent of all information was knowledge and the challenge was to convert more of the available information to knowledge. Peters and others believed that would be possible if they created awareness of this problem, but they did not foresee the impact of the internet and particularly the emergence of digital data.

In the late 1990s the book titled *How much information is there in the world?*, by Michael Lesk (1997), concluded that “There may be a few thousand petabytes of information all told; and . . . in only a few years . . . we will be able [to] save everything—no information will have to be thrown out, and . . . the typical piece of information will never be looked at by a human being.” By this time scholars and practitioners were clearly aware not only of the huge amounts of data being produced, but also the importance of data analytics, and particularly the role of machine learning in analyzing the available data. Of course, the data scientists were also developing new terms in an effort to clarify how one could measure the large amounts of data, and began

using words like terabyte, petabyte, exabyte, zettabyte, and finally yottabyte – with each succeeding term referring to an amount 1,000 times larger. According to a Forbes report, the total amount of information in 2013 was 4.4 zettabytes, and by 2020 the amount of data will reach 44 zettabytes (Kanellos, 2016). For the layman, 44 zettabytes means little, but for the data scientist it clearly indicates a huge amount of data. Of course, this and other estimates are just informed predictions but the direction and amount of increase in data accumulation and storage is unquestionably correct.

As noted, we believe data will continue to increase exponentially, and this clearly will impact both market research practitioners and scholars. Practitioners must help organizations to understand and respond effectively to this glut of data. They must advise marketers on which data is relevant and which can be dismissed. Beyond that, marketing researchers will need to be more effective in informing marketing managers on how the data can be used, and what data will be most helpful. The bulk of data available now and in the future will be secondary and digital. This is in stark contrast to the past, in which marketing researchers collected primary data and controlled what type of data would be collected in hopes that it would be directly and immediately applicable to problems confronting their customers. With the increase in secondary data, marketing researchers must help organizations sift through the mountains of data and determine what is relevant and what is of little or no value. Moreover, going forward longitudinal data will be available to conduct retrospective analyses, as well as prepare more effective forecasts.

Marketing scholars must follow a similar path – determining and gaining access to secondary data that is relevant to their research and will enable them to publish in quality peer-reviewed journals. Academicians have thus far accessed and applied secondary

and digital data in only a few instances. But there are increasingly substantial opportunities to access this type of data, particularly in marketing, and as data increases exponentially so will opportunities for academicians to pursue these opportunities. At the same time, marketing research texts must also undergo major revisions since most include only limited material on data analytics, or even on the explosion of secondary and digital data.

Data Quality Will Improve

All aspects of both academic and practitioner research are being impacted by the availability of data and the advances in data analytics. One area impacted is data examination, and as data examination is implemented in organizations it will improve data quality and ultimately the success or failure of the research effort. While many researchers continue to operate with primary data, both qualitative and quantitative, many others increasingly are dealing with widely disparate data sources (e.g., customer-level data within multiple divisions of firms, social media and other digital data, locational data, etc.) that have different data structures and formats. Expanded data examination, often referred to as data cleaning, is necessary and will improve data quality and thus results.

Another evolving area, and one that is likely the most challenging of the big data era, is data management – organizing, cleaning and coding the data from multiple sources and in multiple formats to prepare for analysis. Many researchers think the primary question is which technique to use, and do not realize that the type of data often dictates the selection of the technology and analysis technique. In most instances, what precedes and dictates the appropriate analysis technique is the management of data from multiple sources, which can easily take 50 percent or more of the

total time for completing a data analytics project.

Combining and managing data from multiple sources becomes complex very quickly. What may seem like a simple merging of data can be very difficult when the analyst has to extract the data from multiple databases, matching formats and timeframes and many other required adjustments. And since 90 percent of data is often unstructured, this task is clearly daunting. Therefore, academic and practitioner researchers in all fields will have to become “data managers” along with being data analysts.

Data Analytics Will Improve

A primary force behind the widespread application of data analytics is the potential improvement in decision-making. Improved data analytics will benefit practitioners and academics, as well as governments and for-profit or non-for-profit organizations. But to realize these benefits analysts will need to be more involved in providing critical inputs on what data to collect, in what format, how to manage and combine the data, and ultimately selecting the best analytic technique.

Unfortunately, to date academicians have been slower in adopting and applying big data and data analytics into their research. Some disciplines in the sciences (biology, biomedicine, and neuroscience) are moving faster in adopting data analytics, but the social sciences are beginning to recognize the potential of more complex analytical methods. These enhanced analytics methods make it possible for additional types of research questions to be examined and new challenges to be overcome. As marketing research academics and practitioners become more aware of these opportunities, in both data and techniques, their utilization will increase, hopefully sooner rather than later.

Decisions will Be More Knowledgeable

Both management and customer decisions will increasingly be knowledge-based. The era of big data has provided new and varied sources of data, and has placed additional requirements on the analytical techniques that must handle these data sources. There are, therefore, unique challenges facing today’s analyst with the many issues in big data and analytics. We believe with an expanded focus on data challenges and data analytics, data scientists will be able to create awareness and motivate management to invest in these promising developments. If this happens, marketing research and business decisions in general will be based on better data and more effective analytical techniques, and thus be more knowledge based. Clearly, the organizations and individuals that move the quickest in these emerging areas will acquire and establish true competitive advantages in the marketplaces of tomorrow.

Privacy Issues and Challenges

In his book *The Assault on Privacy*, Arthur Miller (1971) noted that “Too many information handlers seem to measure [an individual by] the number of bits of storage capacity [their] dossier will occupy.” Today, in advanced economies data exists on everyone and has grown in exponential size due to digital records. Increasingly, however, government implemented policy changes are impacting the way we collect, access, store and use data. On the heels of the Cambridge Analytica’s information security issues involving Facebook, two consumer privacy laws have been or are in the process of being adopted – the General Data Protection Regulation (GDPR) and the California Consumer Privacy Act, A.B. 375 were developed to provide greater control to customers of data that was collected on them. As a result, companies must now increase

controls and transparency of how data is collected, what data is collected, why data is being collected, who has access to the data and how companies are using the collected data. Marketing researchers are also required to comply with these regulations as they face the same rules in collecting, securing and distributing identifiable data.

Data Analytics Capabilities Are An Important Competitive Advantage

Data is only as good as the intelligence we can glean from it, and that entails effective data analytics and a whole lot of computing power to cope with the exponential increase in the volume and type of data. Most all organizations (large, medium, and even small) can apply data analytics to improve manufacturing, supply chain, management and marketing activities, and to be more efficient and effective in achieving organizational goals. While the application of data analytics is producing useful findings in the fields of agriculture, healthcare, urban design, crime reduction, and energy, along with business in general, much remains to be done. The field of analytics is evolving quickly and more opportunities are emerging to apply the new sources of data and the additional, more sophisticated methods of analysis. The speed of adoption and application to decision-making will clearly influence the acquisition of competitive advantages, but the leaders in this field will accrue the advantages, and their advantages could become insurmountable for the laggards.

Demand for Trained Data Scientists Will Exceed Supply

More universities need to become involved in training new data scientists. Training and awareness of big data and data analytics will encourage analysts to define not

only their research questions more broadly, but also the scope of their responsibility in leading the way to more effectively use data to solve business problems. The successful utilization of data analytics will be influenced substantially by the analysts and the decisions they make not only in informing senior managers of the potential of data analytics, but also in the selection and application of the techniques to use moving forward.

According to the Study Portals website, in the U.S. there are slightly more than 100 bachelor's degree programs with a concentration in data analytics. This number needs to be five and perhaps ten times that many – and similar changes must follow globally. But an even greater need exists for master's degrees in data analytics (only about 40 are offered in the U.S.) since being a data scientist requires substantial training. Universities globally need to move quickly to train these data scientists to meet not only the current demand, but to continue producing what will be a substantial and expanding need for data scientists in the future, particularly in the field of marketing research.

References

- Abubakar, A.M., Namin, B.H., Harazneh, I., Arasli, H., & Tunç, T. (2017). Does gender moderate the relationship between favoritism/nepotism, supervisor incivility, cynicism and workplace withdrawal: A neural network and SEM approach. *Tourism Management Perspectives*, 23, 129-139.
- Antons, D., & Breidbach, C. F. (2018). Big data, big insights? Advancing service innovation and design with machine learning. *Journal of Service Research*, 21(1), 17-39.
- Agarwal, A., Hosanagar, K., & Smith, M. D. (2011). Location, location, location: An analysis of profitability of position in online advertising

markets. *Journal of marketing research*, 48(6), 1057-1073.

Bachelor's Degrees in Data Science & Big Data in the United States, <https://www.bachelorsportal.com/study-options/269779226/data-science-big-data-united-states.html>, accessed August 2018.

Balducci, B., & Marinova, D. (2018). Unstructured data in marketing. *Journal of the Academy of Marketing Science*, 46(4), 1-34.

Becker, J. M., Rai, A., Ringle, C. M., & Völckner, F. (2013). Discovering unobserved heterogeneity in structural equation models to avert validity threats. *MIS Quarterly*, 37(3), 665-694.

Chan, H. Y., Boksem, M., & Smidts, A. (2018). Neural profiling of brands: Mapping brand image in consumers' brains with visual templates. *Journal of Marketing Research*. 55(4), 600-615.

Chung, T. S., Rust, R. T., & Wedel, M. (2009). My mobile music: An adaptive personalization system for digital audio players. *Marketing Science*, 28(1), 52-68.

Davenport (2018) Will data scientist continue to be the sexiest job? Downloaded June 2018 at <https://iianalytics.com/research/will-data-scientist-continue-to-be-the-sexiest-job>.

Davenport, T., & Harris, J. (2017). *Competing on Analytics: Updated, with a New Introduction: The New Science of Winning*. Harvard Business Press.

Delen, D., & Zolbanin, H. M. (2018). The analytics paradigm in business research. *Journal of Business Research*, 90, 186-195.

Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), 897-904.

Flynn, B., Pagell, M., & Fugate, B. (2018). Survey Research Design in Supply Chain Management: The Need for Evolution in Our Expectations. *Journal of Supply Chain Management*, 54(1), 1-15.

Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137-144.

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate Data Analysis* (8th ed.). Cengage Learning, U.K.

Hair, J.H., Matthews, L., Matthews, R., & Sarstedt, M. (2017). PLS-SEM or CB-SEM: Updated Guidelines on Which Method To Use," (2017), *International Journal of Multivariate Data Analysis*, Vol. 1 (2), pp 107-123.

Hair, J.H., Matthews, L., Ringle, C., & Sarstedt, M. (2016). Identifying and Treating Unobserved Heterogeneity with FIMIX-PLS: Part I – Method, *European Business Review*, 28(1), 63-76.

Hair, J. F., Sarstedt, M., Ringle, C. M., & Mena, J. A. (2012). An Assessment of the use of Partial Least Squares Structural Equation Modeling in Marketing Research. *Journal of the Academy of Marketing Science*, 40(3), 414-433.

Harris, J. M., Ciorciari, J., & Gountas, J. (2018). Consumer neuroscience for marketing researchers. *Journal of Consumer Behaviour*, 17(3), 239-252.

Harrison, D.E., Ajjan, H. and Coughlan, A. (2018). Working paper: Understanding social

- media sentiment, positioning and engagement: the impact on direct selling sales performance. *Informs Society of Marketing Science Proceedings*.
- Harrison, D. E., & Hair, J. F. (2017). The Use of Technology in Direct-Selling Marketing Channels: Digital Avenues for Dynamic Growth. *Journal of Marketing Channels*, 24(1-2), 39-50.
- Henke, N., Levine, J., McInerney, P. (2018). You don't have to be a data scientist to fill this must have analytics role. *Harvard Business Review*. February 05.
- Huang, M. H., & Rust, R. T. (2018). Artificial intelligence in service. *Journal of Service Research*, 21(2), 155-172.
- Hulland, J., Baumgartner, H., & Smith, K. M. (2018). Marketing survey research best practices: evidence and recommendations from a review of JAMS articles. *Journal of the Academy of Marketing Science*, 46(1), 92-108.
- Hulland, J., & Miller, J. (2018). "Keep on Turkin"? *Journal of the Academy of Marketing Science*, 46(5), 789-794.
- Hult, T., Hair, J. F., Sarstedt, M., Ringle, C., Proksch, D., and Pinkwart, A. (2018). Addressing Endogeneity in International Marketing Applications of Partial Least Squares Structural Equation Modeling. *Journal of International Marketing*, forthcoming.
- Humphreys, A., & Wang, R. J. H. (2017). Automated text analysis for consumer research. *Journal of Consumer Research*, 44(6), 1274-1306.
- Kanellos, M. (2016). 152,000 smart devices every minute in 2025: IDC outlines the future of smart things. March 2016, retrieved from <https://www.forbes.com/sites/michaelkanell>os/2016/03/03/152000-smart-devices-every-minute-in-2025-idc-outlines-the-future-of-smart-things/.
- Krause, D., Luzzini, D., & Lawson, B. (2018). Building the Case for A Single Key Informant in Supply Chain Management Survey Research. *Journal of Supply Chain Management*, 54(1), 42-50.
- Kull, T. J., Kotlar, J., & Spring, M. (2018). Small and Medium Enterprise Research in Supply Chain Management: The Case for Single-Respondent Research Designs. *Journal of Supply Chain Management*, 54(1), 23-34.
- Kumar, V. (2018). Transformative Marketing: The Next 20 Years. *Journal of Marketing*. 82(4), 1-12.
- Matthews, L., Hair, J., Matthews, R. (2018). PLS-SEM: The holy grail for advanced analysis. *Marketing Management Journal*, 28(1), 1-13.
- Matthews, L., Hair, J.H., Sarstedt, M., and Ringle, C. (2016). Identifying and Treating Unobserved Heterogeneity with FIMIX-PLS: Part II – Case Study, *European Business Review*, 28(2).
- Mela, C.F. & Moorman, C. (2018). Why Marketing Analytics hasn't lived up to its promise. May 30, retrieved from <https://hbr.org/2018/05/why-marketing-analytics-hasnt-lived-up-to-its-promise>.
- Netzer, O., Lattin, J. M., & Srinivasan, V. (2008). A hidden Markov model of customer relationship dynamics. *Marketing science*, 27(2), 185-204.
- Roh, J. A., Whipple, J. M., & Boyer, K. K. (2013). The effect of single rater bias in multi-stakeholder research: A methodological

evaluation of buyer-supplier relationships. *Production and Operations Management*, 22(3), 711-725.

Rossi, B. (2015), From insight to action: why prescriptive analytics is the next big step for data. February 2015, retrieved from <https://www.information-age.com/insight-action-why-prescriptive-analytics-next-big-step-big-data-123458977/>.

Rossi, P. E., & Allenby, G. M. (2003). Bayesian statistics and marketing. *Marketing Science*, 22(3), 304-328.

Sarstedt, M., & Ringle, C. M. (2010). Treating unobserved heterogeneity in PLS path modeling: a comparison of FIMIX-PLS with different data analysis strategies. *Journal of Applied Statistics*, 37(8), 1299-1318.

Sarstedt, M., Ringle, C., & Hair, J. (2017). Identifying and Treating Unobserved Heterogeneity in PLS: A State of the Art Review," chapter in *Recent Developments on Partial Least Squares Structural Equation Modeling: Basic Concepts, Methodological Issues and Applications*, H. Latan, and Richard Noonan, Editors, Springer International Publishing AG, Switzerland.

Shmueli, G., Ray, S., Velasquez Estrada, J. M., & Chatla, S. B. (2016). The elephant in the room: Predictive performance of PLS models, *Journal of business Research*, 69, 4552-4564.

Sivarajah, U., Kamal, M. M., Irani, Z., & Weerakkody, V. (2017). Critical analysis of Big Data challenges and analytical methods. *Journal of Business Research*, 70, 263-286.

Sorescu, A., Warren, N. L., & Ertekin, L. (2017). Event study methodology in the marketing

literature: an overview. *Journal of the Academy of Marketing Science*, 45(2), 186-207.

Snyman, J. A. and Wilke, D. N. (2005). Practical mathematical optimization: basic optimization theory and gradient-based algorithms. Springer.


Varadarajan, R. (2018). A Commentary on "Transformative Marketing: The Next 20 Years". *Journal of Marketing*. 82(4), 15-18.

Verma, P., Agarwal, S., Kachroo, P., & Krishen, A. (2017). Declining transportation funding and need for analytical solutions: dynamics and control of VMT tax. *Journal of Marketing Analytics*, 5(3-4), 131-140.

Wedel, M., & Kannan, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(6), 97-121.

White, S., (2017). What is a data scientist? A key data analytics role and a lucrative career. <https://www.cio.com/article/3217026/data-science/what-is-a-data-scientist-a-key-data-analytics-role-and-a-lucrative-career.html>, accessed August, 2018.

Worm, S., Bharadwaj, S. G., Ulaga, W., & Reinartz, W. J. (2017). When and why do customer solutions pay off in business markets? *Journal of the Academy of Marketing Science*, 45(4), 490-512.



PESQUISA EM MARKETING
NO SÉCULO XXI:
OPORTUNIDADES E DESAFIOS

Joe F. Hair, Jr.

University of South Alabama

Dana E. Harrison

East Tennessee State University

ORCID: 0000-0002-7250-9522

Jeffrey J. Risher

University of West Florida

ORCID: 0000-0002-0359-2668

Recebido em:

29/05/2018

Aceito em:

30/08/2018

Editores Responsáveis:

Prof. Dr. Marcelo Luiz Dias da Silva Gabriel

Prof. Dr. Dirceu da Silva

Processo de Avaliação:

Artigo convidado

Resumo

O papel do marketing está evoluindo rapidamente, e desenhos e métodos de análise usados por pesquisadores de marketing também estão mudando. Essas mudanças estão emergindo das transformações nas habilidades de gerenciamento, inovações tecnológicas e evolução do comportamento do consumidor. Porém, talvez, o maior condutor dessas mudanças seja o aparecimento do big data e dos métodos analíticos usados para examinar e entender os dados. Para continuar a ser relevante, a pesquisa de marketing deve permanecer tão dinâmica quanto os mercados e se adaptar de acordo com o seguinte: os dados continuarão crescendo exponencialmente; a qualidade dos dados irá se aprimorar; analytics (inteligência analítica) será mais poderosa, fácil de usar e mais amplamente usada; gerenciamento e decisões do consumidor serão, cada vez mais, baseados em conhecimento; questões de privacidade e desafios serão tanto um problema quanto uma oportunidade, enquanto as organizações desenvolvem suas habilidades analíticas; dados analíticos se tornarão fortemente estabelecidos como uma vantagem competitiva, tanto na indústria de pesquisa em marketing quanto nos estudos acadêmicos; e, num futuro previsível, a demanda por cientistas de dados altamente treinados excederá a oferta.

Keywords: Big Data. Análise de Dados. Qualidade de Dados. Marketing Analítico. Pesquisa em Marketing.

Pesquisa em Marketing no Século XXI: Oportunidades e Desafios

O papel do marketing para consumidores e empresas está evoluindo rapidamente (Ferrell, Hair, Marshall & Tamilya, 2015). De fato, a função do marketing está fundamentalmente mudando, como resultado da transformação digital, dos dados e da análise dos dados. Mais recentemente, devido a dispositivos móveis pessoais, como os *softwares* de infusão, os quais rastreiam o tempo enquanto os indivíduos trabalham ou brincam, estes podem procurar por empresas locais ou consumidores enquanto estão em uma cafeteria, podem enviar uma fatura ou citação do escritório de um cliente, e muito mais (Shah et al., 2014). O desenho da pesquisa em marketing e os métodos de análise também estão mudando rapidamente (Hair, Black, Babin, & Anderson, 2019). Tais mudanças estão emergindo, vindas de transformações nas habilidades de gerenciamento (Henke, Levine, & McNerney, 2018; Davenport, 2018), inovação tecnológica, particularmente no espaço digital (Davenport, 2018), e continuamente evoluindo o comportamento do consumidor (necessidades e expectativas) (Wedel & Kannan, 2016). Para continuar a ser relevante, a pesquisa em marketing deve permanecer tão dinâmica quanto os próprios mercados.

Ao mesmo tempo, a pesquisa acadêmica está, cada vez mais, utilizando ferramentas analíticas avançadas e algoritmos (Erevelles, Fukawa, & Swayne, 2016; Syam & Sharma, 2017; Wedel & Kannan, 2016; Petrescu & Krishen, 2017), e até mesmo inteligência artificial, em combinação com redes de interligações neurais (Ababukar et al., 2017). Enquanto a inteligência analítica avança e está fornecendo importantes vantagens competitivas para as práticas das indústrias, também está forçando rápidas mudanças na

pesquisa acadêmica em nas ciências sociais (Krishen & Petrescu, 2018).

Diretrizes para a pesquisa, especialmente em marketing e ciências sociais relacionadas, incluem aplicações de técnicas avançadas de análises e tecnologias. Wedel e Kannan (2016), por exemplo, sugerem que métodos de aprendizado de máquina (*machine learning*) e tecnologias cognitivas computadorizadas podem ser aplicados para melhor compreensão de problemas e oportunidades de marketing. Similarmente, Erevelles, Fukawa e Swayne (2016) identificaram proposições para examinar as soluções de *big data* em várias atividades de marketing, tanto quanto para o modo com esses achados podem ser aplicados para desenvolverem vantagens competitivas sustentáveis. Syam e Sharma (2017) destacam a importância de se compreender como o aprendizado de máquina (AM) e a inteligência artificial (IA) podem contribuir para a pesquisa em marketing avançar, e Abadular et al. (2017) propuseram meios de aplicar a IA e as redes de contatos neurais.

Assim, à medida que esses e outros incrementos paralelos são aplicados para expandir nosso conhecimento sobre as tendências de marketing e do comportamento do consumidor, as empresas podem atender com mais eficiência as necessidades dos consumidores e reduzir a sobrecarga de informações.

O objetivo deste artigo é sugerir como as tendências emergentes do mercado, e particularmente as do marketing, provavelmente afetarão a pesquisa em marketing. Primeiro, exploraremos o papel emergente da função do marketing, que está se desenvolvendo a partir de novos modelos de negócios. Em segundo lugar, examinaremos as implicações dessa mudança na pesquisa acadêmica em marketing. Finalmente, abordaremos as transformações que

provavelmente continuarão evoluindo no futuro.

Papel Emergente do Marketing e da Pesquisa em Marketing

Vários incrementos estão influenciando o marketing e, portanto, a pesquisa em marketing. Entre os incrementos mais importantes, estão os que seguem:

Mercados Modernos

Talvez uma das tendências mais importantes que impactam a pesquisa em marketing sejam os mercados baseados na internet. Modelos de negócios, como a economia de compartilhamento ou empresas de correspondência digital, têm emergido de plataformas de tecnologia avançada e se tornaram mercados altamente bem-sucedidos e digitalmente conectados (Harrison & Hair 2017). Os exemplos incluem empresas baseadas na internet, tais como Uber, Amazon, Airbnb, Salesforce e Netflix, que forjaram novos modelos de negócios prósperos, enfim revolucionando as indústrias. Embora esses incrementos tenham se materializado gradualmente nos últimos 20 anos, seu impacto total está se tornando agora evidente.

Cientes e empresas estão se tornando coletivamente menos avessos a riscos frequentemente associados a transações *on-line*, e isso impulsionou o crescimento desses modelos de negócios emergentes. Além disso, o comportamento dinâmico do cliente e as mudanças no mercado têm contribuído para a o estabelecimento da necessidade de maior conveniência e experiências mais personalizadas, do que as oferecidas inicialmente pelos mercados *on-line*. Por exemplo, tendências de mudança mais rápidas em modismos e moda de roupas são exemplos dos muitos incrementos de mercado que podem ser atribuídos às capacidades de

produtos e serviços baseados na internet. Porém, há muitos outros exemplos. Em essência, as companhias inovadoras têm desenvolvido e dominado proposições de valor que respondem mais efetivamente às oportunidades de mercado e atendem mais de perto às necessidades e aos desejos dos clientes.

Um componente crítico que emergiu junto com tais novas proposições de valor são os dados digitais, que permitiram à empresas e aos consumidores não apenas se tornarem mais informados do que nunca antes, mas também venderem e buscarem quase todos os produtos e serviços completamente por via *on-line*. Por exemplo, se você tem uma conta My Google, está tendo suas atividades monitoradas 24 horas por dia, sete dias por semana. Um indivíduo que verificar o número de itens rastreados ao longo de um período irá descobrir que, em média, mais de 200 atividades são adicionadas à sua conta do My Google por dia, o que representa mais de 73.000 adições por ano. Quem poderia imaginar, há alguns anos, que os indivíduos não apenas compartilhariam seus dados pessoais, mas bicicletas e carros, em vez de comprá-los, sem mencionar que estariam dispostos a dar para organizações, como Google ou Facebook, acesso a vastas quantidades de seus dados pessoais? Ou usar seu celular para procurar e comprar mantimentos, ou para quase qualquer outro produto ou serviço que se queira?

Surgimento do Big Data

Companhias e consumidores estão produzindo grandes quantidades de dados, a partir de vários pontos de contato. Do lado do consumidor, os dados são capturados por experiências de *omni-channel* fortemente promovidas. Como exemplos, considerem a compra da Target *on-line* e a retirada imediata na loja, a associação principal da Amazon e as relações de vendas e empresas de transporte parceiras, ou o uso da metodologia *blockchain*

pela FedEx, para gerenciar dados de disputa de clientes e como método eficiente de rastreamento de pacotes. Assim, todos estão produzindo quantidades significativas de informações úteis, tanto para as empresas quanto para os consumidores envolvidos nas transações. Talvez o coletor de dados mais difundido seja o Google, que tem rastreadores em quase 80% do total de *sites* (exceto na China, de onde o Google se retirou porque se recusou a permitir a censura de informações). Da mesma forma, no lado *B-to-B* (*business-to-business*), General Electric e Boeing estão instalando sensores em motores a jato, os robôs estão sendo programados para fabricarem muitos produtos, como automóveis e aviões, sensores estão permitindo marcas de veículos, como Volvo, Tesla, Mercedes, BMW e outros, a comercializarem carros autônomos, além de muitas outras inovações de distribuição e manufatura, que também coletam dados em todo o ecossistema de fabricação e distribuição, para gerar *insights* valiosos e praticáveis. Como resultado, as empresas podem gerenciar melhor a produção, entender e responder às demandas do cliente e agregar valor. Com esse recurso emergente de dados, empresas podem gerenciar, de maneira mais inteligente, seus negócios, podem melhorar tempos de resposta, promover inovações, reduzir custos e impulsionar receitas e lucros.

Dados mudam o poder dentro das organizações. Atualmente, apenas 5% da economia dos Estados Unidos é referente a dados – um percentual pequeno agora, mas que está se expandindo exponencialmente. No passado, dados eram responsabilidade do *chief information officer* (CIO), uma posição de funcionário. No ano passado (2017), nos Estados Unidos, pela primeira vez, o orçamento de tecnologia da informação foi gasto mais por gestores de linha de frente do que por CIOs. Para os CIOs, o sistema de segurança dos dados é uma prioridade. Ao contrário, CMOs (*Chief Marketing Officers*) e CFOs (*Chief Financial*

Officers) se importam com a execução do negócio. A divulgação de quebra e roubo da informação feita pela empresa Equifax, em 2017, foi provavelmente a responsável pelo resultado dessa transição na responsabilidade pela segurança de dados. Ao mesmo tempo, para indivíduos treinados na faculdade de Administração, é surpreendente que mais de 15% dos CEOs (*Chief Executive Officers*) sejam agora cientistas de dados – eles não têm um MBA!

Dados e análise de dados têm o potencial de mudar a ordem econômica do mundo, em modos que perturbarão muitas empresas e pessoas. Além disso, dados baseados no conhecimento se tornarão, provavelmente, uma fonte de poder que é difícil de desafiar, por parte de países e empresas que não possuem este conhecimento e essas habilidades. Em síntese, dados e análises se tornaram, para as economias do século XXI, o que o petróleo era para o século XX, ou seja, um ativo valioso essencial para uma vida econômica aprimorada. Parece, portanto, que estamos à beira de um novo mundo de dados, que definitivamente mudará tanto o marketing quanto a pesquisa em marketing.

Em relação à análise de dados, a tecnologia avançada e os custos mais baixos agora são capazes de armazenar e processar grandes quantidades de dados vindos dessas várias interações. Os custos de armazenamento de um *megabyte* de informação, por exemplo, caíram de 15 dólares, em 1992, para menos de 10 centavos de dólar por um *megabyte* em 2017. Mas, à medida que mais dados são produzidos e armazenados, há uma necessidade maior de se aplicarem métodos analíticos avançados de marketing, para haver um entendimento mais sofisticado dos dados, não apenas relacionados ao que está sendo vendido e por quais canais, mas também para produzir medidas aprimoradas de retorno sobre investimentos de marketing, valor da vida útil do consumidor,

motivadores de fidelidade do consumidor, e assim por diante.

Marketing Transformador

Enquanto a quantidade, o tipo (estruturado e não estruturado), e a complexidade dos dados mudam, assim também mudam os métodos de pesquisa necessários para sustentar esses incrementos. A variedade, velocidade e o volume de dados derivam de ambientes de marketing em mudança, de tecnologia emergente e do menor custo de coleta e armazenamento de dados (Erevelles, Fukawa, & Swayne, 2015; Kumar, 2018; Varadarajan, 2018; Davenport, 2018). Exemplos de direcionadores da criação de dados incluem o comportamento de compra de consumidores em evolução, a Internet das Coisas, *wearables* (tecnologias vestíveis) digitais, a ascensão da inteligência artificial, tecnologia aprimorada da cadeia de suprimentos e a capacidade de incorporar análises em vendas, distribuição e sistemas de produção, para mencionar apenas alguns exemplos (Kumar, 2018). O Facebook sozinho possui mais de 200 bilhões de fotografias armazenadas na nuvem, e mais de 350 milhões são carregadas todos os dias. Em resposta a esses direcionadores, estratégias de marketing, decisões organizacionais e de desempenho estão sendo completamente alteradas pelos recursos de informação, capacidades de análise e pelo conhecimento aprimorado do consumidor.

Mudando o Papel da Pesquisa em Marketing

Há valor em ambas as abordagens de pesquisa tradicionais que examinam, por exemplo, hipóteses derivadas da prática e da teoria, bem como análises preditivas que, geralmente, enfatizam a solução de problemas de negócios com dados (Babin, Griffin, & Hair, 2015; Delen & Zolbanin, 2018). De fato, tanto

ferramentas como técnicas, que informam diferentes níveis de inteligência sofisticada, estão cada vez mais disponíveis (Davenport & Harris, 2017). Essas ferramentas e técnicas abrangem desde planilhas de análises usadas por empresas para entender quantas, com que frequência ou porque alguma coisa ocorreu, até ferramentas preditivas que ajudam a explicar e prever o que provavelmente acontecerá, além de ferramentas automatizadas de aprendizado de máquina aplicadas para obter *insights* de dados. Em resumo, todos os níveis de sofisticação oferecem o potencial para vantagens competitivas (Davenport & Harris, 2017). Entretanto, cada vez mais, as empresas devem adotar e confiar nas ferramentas mais sofisticadas disponíveis. Assim, o que é frequentemente negligenciado é o fato de que o aprendizado de máquina, cada vez mais associado à inteligência artificial, requer intervenção humana para executar e completar as análises. Dessa maneira, o papel dos pesquisadores de marketing tanto se expandirá quanto aumentará em complexidade, exigindo um treinamento muito mais avançado.

Os parágrafos seguintes oferecem uma visão geral de como as três abordagens de pesquisa em marketing – descritiva, preditiva e analítica prescritiva – estão evoluindo e mudando.

Análise Descritiva Tradicional

Pesquisa tradicional usa, frequentemente, métodos descritivos e diagnósticos. Esse tipo de pesquisa é de natureza mais explicativa e confirmatória (Sivarajah, Kamal, Irani, & Weerakkody, 2017). Por exemplo, os indicadores-chave de desempenho (ICD) fornecem visualizações de painel em tempo real, para compreensão do quanto a empresa se mostra efetiva e eficiente, para atingir os objetivos de negócios, como desempenho de vendas, gerenciamento de controle de estoque ou capacidade de resposta

da cadeia de fornecimento. Embora valiosos como métricas históricas, esses *feedbacks* confirmatórios fornecem apenas compreensões preditivas limitadas sobre a possibilidade dos resultados futuros serem semelhantes ao obtidos. Mas esse processo continuará a ser muito útil para os profissionais de marketing, como meio de monitorar as operações cotidianas. Assim, os pesquisadores de marketing precisarão fornecer suporte para melhor compreensão e explicação dos incrementos do mercado, além de sugerirem maneiras inovadoras de aplicação dessas informações.

Os dados usados na análise descritiva podem ser encontrados dentro e fora da organização. As empresas coletam, geralmente, dados sobre clientes e concorrentes, mas também os usam vindos de fontes externas, como o data.com. Embora a quantidade de dados internos seja muito mais fácil de coletar atualmente, é provável que o futuro traga recursos de tecnologia avançada que permitam às organizações coletarem dados de fontes externa mais eficientemente.

Análise Preditiva

A tecnologia avançada combinada com algoritmos complexos facilita as abordagens de análise preditiva. Essas técnicas que vêm surgindo examinam enormes quantidades de dados, para promoverem narrativas para uma avaliação mais eficaz de oportunidades, além da previsão de desenvolvimentos futuros. Assim, a análise preditiva aplica ferramentas de modelagem aos dados para prever futuros incrementos e tendências de mercado (Davenport & Harris, 2017). Os pesquisadores categorizaram a análise preditiva em duas dimensões: técnica de regressão e técnica de aprendizado de máquina (Gandomi & Haider 2015), sendo ambas elementos cada vez mais centrais dos programas de pesquisa em marketing.

Embora a análise preditiva normalmente exija algum nível de intervenção humana, muitas vezes há flexibilidade no nível de envolvimento (por exemplo, selecionar variáveis-alvo, desenvolver modelos teóricos derivados, permitir que os dados contem uma história). *Big data*, obtido a partir de muitas fontes, potencialmente contém milhares e até milhões de variáveis condutoras, sendo analisado por meio de centenas de modelos analíticos. Mas esse tipo de modelagem apresenta desafios substanciais, em comparação aos métodos tradicionais (Davenport & Harris, 2017), e exige mais analistas de dados com bom conhecimento do que no passado. Por exemplo, com muitas fontes e tipos de dados (estruturados e não estruturados) integrados em um único banco de dados, é virtualmente impossível formular hipóteses sobre todas as relações possíveis. De acordo com Peter Norvig (2009), diretor de pesquisa do Google, a vasta quantidade de dados e a complexidade resultante dos relacionamentos geralmente tornam vantajoso para os computadores extrair modelos a partir dos dados, em vez de os humanos gastarem tempo usando abordagens científicas para identificar possíveis modelos. Os computadores, portanto, exploram os dados para localizar relacionamentos ocultos que, normalmente, não seriam identificados e, em seguida, desenvolvem modelos preditivos que suportam conclusões preliminares e facilitam a tomada de decisões estratégicas.

A análise preditiva está sendo, cada vez mais, aplicada também no setor corporativo. Não apenas pelas maiores empresas, mas também algumas de médio porte estão usando a análise preditiva. Entretanto, esse procedimento ainda envolve considerável intervenção humana, promovida por analistas de marketing e de dados. Os indivíduos competentes devem ser capazes de selecionar o método analítico apropriado, e quando as soluções são identificadas, alguém deve

interpretá-las em termos de lógica, relevância para os problemas de negócios e, em última instância, de valor estratégico. O problema é que não há cientistas de dados qualificados suficientemente para tomar tais decisões. A empresa McKinsey estima que, apenas nos Estados Unidos, enfrenta-se uma escassez de 140.000 a 190.000 pessoas com conhecimento analítico e 1.5 milhão de gerentes e analistas com habilidades para entenderem e tomarem decisões com base na análise de *big data*. Em resposta a essa necessidade, as universidades dos Estados Unidos adicionaram mais de 100 programas de graduação em análise de dados nos últimos cinco anos, com ainda mais cursos sendo adicionados a cada ano.

Análise Prescritiva

A análise prescritiva é um nível avançado de análise que examina o que deve ou pode ser feito para que algo aconteça. A análise prescritiva permite que os pesquisadores de marketing determinem os comportamentos ideais e avaliem o impacto final de ações nos negócios (Davenport & Harris, 2017; Sivarajah et al., 2017). Para conseguir esse intento, a análise prescritiva experimenta e otimiza vários cenários em um ritmo acelerado e proporciona menos riscos para a interpretação humana subjetiva (Davenport & Harris, 2017). Isso pode ser interessante se a análise funcionar bem, mas pode não ser tão boa ideia de outra forma. Assim, a análise prescritiva, embora não completamente autônoma, pode produzir implicações e gerar recomendações. Como exemplo, FleetPride, empresa fornecedora de peças para caminhões e reboques para clientes em vários setores, obteve sucesso na implementação de análises prescritivas. Usando soluções oferecidas pela IBM, os resultados da empresa forneceram aos gerentes da cadeia de suprimentos *insights* para operarem de forma integrada. Assim, os resultados permitiram que a empresa

aperfeiçoasse as redes de distribuição, aumentasse a velocidade do fluxo de estoque e reduzisse os erros de embalagem. Embora o número de organizações que usam a análise prescritiva esteja crescendo, é difícil saber o nível de adoção em cada organização. Infelizmente, não é incomum que a adoção tenha ocorrido em silos de unidades e que outras pessoas da organização não estejam cientes de que a análise prescritiva foi implementada (Rossi, 2015). É claro que a chave para a análise prescritiva bem-sucedida depende, como na análise preditiva, das habilidades dos cientistas de dados que a executam e também é evidente que há uma escassez global de indivíduos treinados nessa área.

Para Onde Irá a Pesquisa em Marketing Agora?

Ferramentas e técnicas sofisticadas estão sendo prontamente adotadas na prática de pesquisa de mercado, com valores e orçamentos cada vez mais dedicados à compra de soluções avançadas de análise (Mela & Moorman 2018). Com as entradas de dados em constante evolução (por exemplo, tecnologias), tipos de dados (por exemplo, dados não estruturados) e mudanças no comportamento do cliente, é importante que a pesquisa em marketing permaneça relevante e oportuna para a gestão. Várias questões relevantes se relacionam a até que ponto os pesquisadores de marketing e os cientistas de dados devem permitir que essas novas ferramentas analíticas desenvolvam modelos e produtos, sem primeiro desenvolver hipóteses teoricamente derivadas? Onde está o lugar na pesquisa em marketing para a integração de ferramentas preditivas e prescritivas? Como esse método poderia desenvolver novas teorias e agregar valor ao campo? Como a pesquisa de marketing pode aplicar *softwares*, como o SAS/STAT, para modelagem preditiva, o LIWK para análise de

texto, ferramentas de análise de rede de mídia social, como o NodeXL, ou ferramentas de aprendizado de máquina como o DataRobot? Como as soluções de inteligência artificial (IA) são aplicadas, como o Salesforce Einstein, que não apenas oferece previsões, mas também tece recomendações sobre como responder aos clientes, afetando os recursos da equipe de vendas? Os pesquisadores de marketing devem permanecer cientes da evolução do *big data* e da análise, entender como e quando utilizar esses métodos na pesquisa e manter o ritmo com as prioridades gerenciais da prática.

Mudanças na Metodologia e no Projeto de Pesquisa

Em paralelo com a evolução em técnicas avançadas e ferramentas, nós também testemunhamos mudanças nos *designs* de nas metodologias de pesquisa.

O Uso de Dados de Surveys

Na década de 1980, mais de 2/3 dos trabalhos acadêmicos publicados eram baseados em pesquisa ou entrevista. Porém, até 2013, o número de artigos publicados com base em pesquisas nas três principais revistas acadêmicas de marketing [*Journal of the Academy of Marketing Science (JAMS)*, *Journal of Marketing (JM)* e *Journal of Marketing Research (JMR)*] estava em torno de 1/3 (Hulland, Baumgartner, & Smith, 2018). Para coletar dados, os pesquisadores têm confiado, cada vez mais, em métodos de pesquisa *on-line*, como o Qualtrics, o Google Survey, o Mechanical Turk e o Survey Monkey (Hulland & Miller, 2018). Empresas e pesquisadores estão capitalizando a transformação digital para alcançar os participantes da pesquisa, por meio de plataformas *on-line*. As plataformas *on-line* proporcionaram acesso conveniente para amostras de empresas e de consumidores, que antes eram difíceis, caras e, muitas vezes,

impossíveis de obter. Infelizmente, as populações estão sendo superestimadas, resultando em recusas para responder *surveys*, e a proporção de artigos baseados em pesquisas começou a declinar (Hulland, Baumgartner, & Smith, 2018). Outra questão notada por várias disciplinas de ciências sociais e, particularmente, por grupos de gerenciamento e cadeia de suprimentos, é o *design* de questionários de respondentes únicos. Nesse tipo de projeto, o mesmo respondente da pesquisa responde também questões relacionadas às variáveis independentes e dependentes, produzindo o que é referido como um viés comum de métodos (Krause, Luzzini & Lawson 2018; Kull, Kotlar, & Spring, 2018; Flynn, Pagell, & Fugate, 2018; Roh, Whipple, & Boyer, 2013). Outras disciplinas, incluindo o marketing, levantaram preocupações semelhantes e estão sugerindo projetos que combinem dados secundários com dados primários como uma solução. Infelizmente, até o momento, nenhum método para mensuração com precisão a extensão do viés de métodos comuns nos projetos de pesquisa foi desenvolvido.

Mudança Para Dados Objetivos

Com o surgimento de dados digitais, uma grande quantidade deles, na verdade, os pesquisadores se voltaram para a coleta de dados objetivos e secundários. Informações arquivísticas ou proprietárias, como dados históricos, estão prontamente disponíveis para pesquisadores (Verma, Agarwal, Kachroo, & Krishen 2017). Usando dados históricos, em estudos de eventos (Sorescu, Warren, & Ertekin, 2017), pode-se examinar o impacto do longo prazo em uma determinada decisão sobre a empresa. Empresas e pesquisadores estão focados em estratégias preditivas e prescritivas, aprimoradas pela inteligência artificial (Huang & Rust 2018) e pelo aprendizado de máquina (Antons & Breidbach, 2018). Até certo ponto,

essas técnicas são capazes de produzir análises autocorretivas, enquanto outras, como a otimização matemática, “determinam a melhor solução para problemas matematicamente definidos” (Snyman, 2005). Nos mercados de consumo, por exemplo, a digitalização facilitou a disponibilidade de dados fisiológicos. De fato, os métodos de pesquisa mais técnicos incluem tanto dados biométricos quanto neurológicos (Chan, Boksem, & Smidts, 2018; Harris, Ciorciara & Gountas, 2017). Essas técnicas, inicialmente emergentes da economia, finanças, ciência da computação e pesquisa médica, estão se tornando cada vez mais predominantes e infundidas na pesquisa de marketing e nas ciências sociais em geral. À medida que voltamos nosso olhar para o futuro, esses métodos de pesquisa em evolução irão tornar-se um recurso crítico nos mercados de negócios de empresa para empresa e para os mercados de consumo, sempre dinâmicos e em constante mudança.

A Ascensão de Dados Não Estruturados

O marketing digital, em áreas como mídias sociais, tem produzido conteúdo substancial não estruturado (Balducci & Marinova, 2018), o qual pode ser submetido à análise de texto (Humphreys & Wang, 2017) e ser, cada vez mais, codificado para modelagem quantitativa. De fato, a conversão de dados não estruturados para análise quantitativa se expande rapidamente, já que 90% de todos os dados não são estruturados. Os dados não estruturados incluem *tweets*, fotografias, registros de chamadas de serviço, *blogs*, dados de reclamações e comentários de clientes, comportamento de compra do cliente etc., que precisam ser analisados e codificados antes de serem enviados ao *software* de análise de dados quantitativos. Programas como o NodeXL e o LIWC são usados para melhorar a modelagem quantitativa (Harrison, Ajan, & Coughlan, 2018). Por meio da coleta e análise de dados não

estruturados, como texto digital ou comentários, empresas e pesquisadores ampliam seus conhecimentos em segmentação, nível de envolvimento e experiência dos clientes, redes sociais e análise de sentimentos, fato que também cria oportunidades ampliadas para pesquisadores de mercado.

Maior Foco em Relevância e Rigor

À medida que os dados e os métodos analíticos se tornam mais complexos, a pesquisa em marketing também experimenta uma mudança em direção a técnicas mais rigorosas. Os pesquisadores devem usar todas as abordagens razoáveis para refutar suas hipóteses *versus* sentir que é necessário apoiar estatisticamente hipóteses para fazer uma contribuição (Babin, Griffin, & Hair, 2015). Por exemplo, endogeneidade, poder estatístico (tamanho do efeito), validade externa e relevância preditiva desempenham papel importante na avaliação precisa das relações entre variáveis exógenas (independentes) e endógenas (dependentes).

Por muitos anos, pesquisadores de marketing examinaram a heterogeneidade observada. A heterogeneidade observada baseia-se no conhecimento de que subgrupos de populações, provavelmente, apresentam diferenças, e também que essas diferenças são conhecidas quando a pesquisa é planejada e conduzida. Por exemplo, os consumidores homens e mulheres, geralmente, exibem diferentes padrões de pesquisa e de compras e, por fim, de comportamento de compra. Para os consumidores, a heterogeneidade observada geralmente se baseia em dados demográficos. Para as organizações, a heterogeneidade observada é baseada no tamanho da empresa, ofertas de produtos ou serviços, conveniência, e assim por diante. Mais recentemente, a tecnologia permitiu aos analistas de dados examinarem a possibilidade de heterogeneidade não observada, ou seja, que as

populações consistem em subgrupos da população que não são facilmente observáveis. O conhecimento sobre a presença de heterogeneidade não observada é crítico nos estudos empíricos atuais e, se não for explorado, potencialmente ameaçará a validade dos modelos de medição e estruturais ao se aplicarem análises descritivas e preditivas (Becker, Rai, Ringle, & Volckner, 2013; Sarstedt & Ringle, 2010; Hair, Matthews, Matthews, & Sarstedt, 2017). Pesquisadores acadêmicos e do setor industrial estão rapidamente avançando no desenvolvimento de análises estatísticas aprimoradas, que abordam efetivamente possíveis questões de confiabilidade e validade.

Embora essas questões sejam, há muito tempo, uma preocupação na pesquisa de marketing, métodos estatísticos mais avançados passaram a permitir que os pesquisadores os abordem com mais rigor (Hult, Hair et al., 2018; Worm, Bharadwaj, Ulaga, & Reinartz, 2017). Análise baseada em regressão funciona para a hipótese de multicolinearidade mínima. Ao mesmo tempo, porém, a moderação ocorre quando dois ou mais fatores covariam o suficiente para alterar o impacto no resultado. Se a moderação é conhecida ou conjecturada, pode ser testada com variáveis contínuas ou categóricas. Isso é particularmente útil para identificação de variáveis intervenientes ou problemas de correlação espúria.

Os acadêmicos e profissionais estão usando, cada vez mais, *softwares* mais sofisticados para execução de análises preditivas. Um exemplo, o *software* SmartPLS (www.SmartPLS.de), é considerado de ponta em termos de análise, sendo uma opção preferida por muitos estudiosos e profissionais, porque é de uso bastante amigável. O *software* executa análise multigrupo no SmartPLS e pode ser usado para examinar a heterogeneidade observada, na qual se propõe que grupos conhecidos se comportam de maneiras diferentes (por exemplo, comparações entre

feminino e masculino; grandes e pequenas empresas), bem como heterogeneidade não observada (Sarstedt et al., 2017; Hair et al., 2016; Matthews et al., 2016). Análises multigrupo (AMG) auxiliam pesquisadores a descobrirem se existem diferenças nas estimativas dos parâmetros (por exemplo, pesos externos, cargas externas e estimativas de parâmetros) de grupos de dados pré-definidos (Matthews, Hair, & Matthews, 2018). Em PLS-SEM, a AMG é benéfica, ao examinar, com eficiência, a moderação em várias relações (Hair, Sarstedt, Ringle, & Mena 2012). Outro *software* cada vez mais popular é o R, que é amplamente usado entre estatísticos e cientistas de dados, para execução da análise de dados. Infelizmente, não é muito amigável, mas é de código aberto e gratuito.

Se os moderadores são desconhecidos antecipadamente, tal tipo de análise se torna mais difícil. Frequentemente, aparecem *clusters* que possuem valores semelhantes para determinadas variáveis. Essas tipologias de grupos não podem ser definidas com precisão por nenhuma variável de dados demográfica ou descritiva específica. Esse tipo de moderação pode ser difícil de prever ou até mesmo de identificar. Nesses casos, técnicas baseadas em previsão podem ser usadas para identificar segmentos que possam criar uma heterogeneidade inexplicável. Além disso, vários pacotes de *softwares* estatísticos oferecem aos pesquisadores a oportunidade de verificação da validade externa e a relevância preditiva (www.smartpls.de, www.r-project.org; Schmueli & Ray et al., 2016).

Tratando-se do PLS-SEM, os pesquisadores propuseram a aplicação metodológica da segmentação orientada à predição (PLS-POS) e da segmentação por mínimos quadrados de mistura finita (FIMIX-PLS), como métodos para superação de limitações prévias de identificação de heterogeneidade não observada. Outras técnicas heurísticas devem ser utilizadas

quando a heterogeneidade encontrada nesses efeitos for sequencial. Esse procedimento vai muito além da análise longitudinal, sendo que, muitas vezes, esse tipo de variância resulta em efeitos aninhados, devido à ordem dos efeitos, sazonalidade, agrupamento etc. Tradicionalmente, o HLM tem sido usado para identificar esses efeitos em econometria. Em aprendizado de máquina, o teorema de Bayes é usado para superar a natureza da seção transversal dessas situações. O teorema de Bayes assume que os termos de erro variam, dependendo da situação ou da ordem dos efeitos. A modelagem bayesiana usa o que é conhecido para prever o desconhecido. Além disso, a modelagem Markov Chain Monte Carlo (MCMC), como as técnicas bayesianas, consiste em conjuntos de algoritmos focados em distribuições de probabilidade para grandes modelos multidimensionais, hierárquicos e para parâmetros desconhecidos. O método é vantajoso quando existe um alto nível de incerteza e a informação histórica é escassa, e pode ser usado para investigar informações por meio de múltiplas fontes de dados (Rossi & Allenby, 2003). O uso de métodos bayesianos aumentou em paralelo com a transformação digital impulsionada pelo uso da internet. Pesquisas em marketing, particularmente as acadêmicas, vêm recebendo com agrado a adoção de técnicas bayesianas e aplicado o método para abordar vários aspectos do marketing (Rossi & Allenby, 2003), como publicidade (Agarwal, Hosanager, & Smith 2011), escolha do cliente (Chung, Rust, & Wedel, 2009) e relacionamento com clientes (Netzer, Lattin & Srinivasan, 2008). Embora os dados sejam abundantes, a digitalização ampliou o desconhecido em ambientes dinâmicos em constante evolução.

Observações Finais

Como deve estar evidente, muitas coisas mudaram nas pesquisas em marketing e

no próprio marketing nos últimos anos. Muitas outras mudanças são esperadas nos próximos anos. A seguir, resumimos nossos pensamentos sobre incrementos futuros. As previsões do futuro são claramente arriscadas. Muitos indivíduos inteligentes tentaram prever o futuro – e, muitas vezes, se provaram errados. Nossos pensamentos são baseados no que acreditamos ser um bom raciocínio, mas, como outros no passado, é improvável que nosso pensamento seja, no futuro, inteiramente como nos parece hoje. Acreditamos que estamos corretos e pedimos que você veja nossas ideias como, pelo menos, direcionais – pois estamos confiantes sobre a direção, mas não necessariamente sobre as especificidades.

Os Dados Continuarão Aumentando Exponencialmente

As primeiras discussões sobre a rápida expansão dos dados começaram há, pelo menos, 70 anos, bem antes do atual interesse generalizado por *big data* e seu impacto. Foi então que começaram as primeiras tentativas para quantificar a taxa de crescimento nos dados. Nos 50 anos seguintes, essa tendência foi chamada de “explosão da informação”. Mais ou menos na mesma época (1941), o *Oxford English Dictionary* incluiu, pela primeira vez, o termo explosão de informações em seu índice, e muitos outros termos de dados foram adicionados desde então.

Entre os primeiros autores de negócios que escreveram sobre esse fenômeno estava Tom Peters, com seu livro de 1991, intitulado *Thriving on Chaos*. Enquanto o livro previa muitas mudanças econômicas relevantes ocorrendo na época, a frase mais importante para o *big data* era: estamos nos afogando em informação e famintos por conhecimento. Tom Peters observou que a diferença entre informação e conhecimento é que a informação consiste apenas em palavras e números que podem ser interessantes, mas não são úteis para

a tomada de decisões. Além disso, o pensamento à época era de que talvez apenas 5% de toda a informação fosse conhecimento, sendo que o desafio era converter mais da informação disponível em conhecimento. Peters e outros acreditavam que isso seria possível se houvesse a criação da consciência desse problema, mas não previam o impacto que causaria a internet e, particularmente, o surgimento de dados digitais.

No final da década de 1990, o livro intitulado *How much information is there in the world?*, de Michael Lesk (1997), concluiu que “pode haver alguns milhares de *petabytes* de informação contados; e . . . em apenas alguns anos. . . seremos capazes de salvar tudo – nenhuma informação terá que ser descartada, e . . . a informação típica nunca será vista por um ser humano.” Àquela altura, estudiosos e profissionais estavam bem cientes, não apenas da enorme quantidade de dados sendo produzidos, mas também da importância da análise de dados e, particularmente, do papel do aprendizado de máquina na análise dos dados disponíveis. Certamente, os cientistas de dados também estavam desenvolvendo novos termos, em um esforço para esclarecer como se poderia mensurar grandes quantidades de dados, e começaram a usar palavras como *terabyte*, *petabyte*, *exabyte*, *zettabyte* e finalmente *yottabyte*, sendo que cada termo subsequente referia-se a um quantidade 1.000 vezes maior. De acordo com um relatório da Forbes, o volume total de informações, em 2013, foi de 4,4 *zettabytes* e, até 2020, a quantidade de dados chegará a 44 *zettabytes* (Kanellos, 2016). Para o leigo, 44 *zettabytes* significa pouco, mas para o cientista de dados indica claramente uma enorme quantidade de dados. Com certeza, esta e outras estimativas são apenas previsões informadas, mas a direção e a quantidade de aumento no acúmulo e armazenamento de dados são, inquestionavelmente, corretas.

Assim, acreditamos que os dados continuarão a aumentar exponencialmente, e

isso claramente afetará tanto os profissionais de pesquisa de mercado quanto os pesquisadores acadêmicos. Os profissionais devem ajudar as organizações a melhor entenderem e responderem de forma eficaz a esse excesso de dados. Tais profissionais devem aconselhar o pessoal de marketing sobre quais dados são relevantes e quais podem ser descartados. Além disso, os pesquisadores em marketing precisarão ser mais eficazes para informar os gerentes de marketing sobre como os dados podem ser usados e quais dados serão mais úteis. A maior parte dos dados disponíveis atualmente e no futuro será secundária e digital. Tal fenômeno está em contraste gritante com o passado, no qual os pesquisadores de marketing coletavam dados primários e controlavam quais tipos de dados seriam coletados, na esperança de que fossem direta e imediatamente aplicáveis aos problemas enfrentados por seus clientes. Com o aumento dos dados secundários, os pesquisadores de marketing devem ajudar as organizações a filtrarem as imensas quantidades de dados e determinar o que é relevante e o que é de pouco ou nenhum valor. Além disso, dados prospectivos longitudinais estarão disponíveis para realizar análises retrospectivas, bem como preparar previsões mais efetivas.

Os acadêmicos de marketing devem seguir um caminho semelhante, ou seja, determinar e obter acesso a dados secundários que sejam relevantes para suas pesquisas e permitir que sejam publicados em revistas de qualidade revisadas por pares. Até o momento, os acadêmicos acessam e aplicam dados secundários e digitais em apenas algumas instâncias. Entretanto, há oportunidades cada vez mais substanciais para acessar esse tipo de dados, particularmente em marketing e, à medida que os dados aumentam exponencialmente, também aumentam as oportunidades para que os acadêmicos os busquem. Ao mesmo tempo, os textos de pesquisa em marketing também devem passar

por grandes revisões, já que a maioria inclui apenas material limitado sobre análise de dados, ou mesmo sobre a explosão de dados secundários e digitais.

A Qualidade dos Dados Irá Melhorar

Todos os aspectos tanto da pesquisa acadêmica quanto da profissional estão sendo afetados pela disponibilidade de dados e pelos avanços na análise de dados. Uma área impactada é o exame de dados e, à medida que o exame de dados é implementado nas organizações, melhora a qualidade dos dados e, em última instância, o sucesso ou o fracasso do esforço de pesquisa. Embora muitos pesquisadores continuem operando com dados primários, tanto qualitativos quanto quantitativos, vários outros estão lidando, cada vez mais, com fontes de dados distintas (por exemplo, dados no nível do cliente em várias divisões de empresas, mídias sociais e outros dados digitais, dados de localização etc.), que possuem diferentes estruturas e formatos. O exame de dados expandido, muitas vezes chamado de limpeza de dados, é necessário e melhorará a qualidade dos dados e, portanto, os resultados.

Outra área em evolução, e provavelmente a mais desafiadora da era do *big data*, é o gerenciamento de dados: organizar, limpar e codificar os dados de várias fontes e em vários formatos para preparar a análise. Muitos pesquisadores acreditam que a questão principal seria qual técnica usar, e não percebem que o tipo de dados geralmente determina a seleção da tecnologia e da técnica de análise. Na maioria dos casos, o que precede e determina a técnica de análise apropriada é o gerenciamento de dados de várias origens, que pode, facilmente, tomar 50% ou mais do tempo total para se concluir um projeto de análise de dados.

Combinar e gerenciar dados de várias fontes se torna complexo muito rapidamente. O

que pode parecer uma simples fusão de dados pode ser muito difícil, quando o analista precisa extraí-los de vários bancos de dados, formatos e cronogramas correspondentes, além de muitos outros ajustes necessários. Como 90% dos dados são frequentemente desestruturados, essa tarefa é claramente desafiadora. Portanto, pesquisadores acadêmicos e profissionais em todos os campos terão que se tornar, além de analistas, “gerentes de dados”.

A Análise de Dados Irá Melhorar

Uma força primária por trás da ampla aplicação da análise de dados é a melhoria potencial na tomada de decisões. A análise aprimorada de dados beneficiará tanto profissionais quanto acadêmicos, bem como governos e organizações com ou sem fins lucrativos. Mas, para realizar esses benefícios, os analistas precisarão estar mais envolvidos no fornecimento de informações críticas sobre quais dados coletar, em que formato, como gerenciar e combinar os dados e, finalmente, selecionar a melhor técnica analítica.

Infelizmente, até o momento, os acadêmicos têm sido mais lentos na adoção e aplicação de *big data* e na análise de dados em suas pesquisas. Algumas disciplinas das outras ciências (biologia, biomedicina e neurociência) estão se movendo mais rapidamente na adoção da análise de dados, mas as ciências sociais estão começando a reconhecer o potencial de métodos analíticos mais complexos. Esses métodos aprimorados de análise permitem que tipos adicionais de perguntas de pesquisa sejam examinados e novos desafios sejam superados. À medida que os acadêmicos e profissionais de pesquisa em marketing se tornarem mais conscientes dessas oportunidades, tanto em dados quanto em técnicas, sua utilização aumentará, mais cedo ou mais tarde.

Decisões Serão Mais Baseadas em Conhecimento

Tanto a gestão quanto as decisões dos clientes serão cada vez mais baseadas em conhecimento. A era do *big data* vem fornecendo fontes de dados novas e variadas e colocou requisitos adicionais nas técnicas analíticas que lidam com essas fontes de dados. Há, portanto, desafios únicos enfrentados pelo analista de hoje com os muitos problemas em *big data* e *analytics*. Acreditamos que, com um foco expandido em desafios de dados e análise de dados, os cientistas de dados poderão criar conscientização e motivar a administração a investir nesses desenvolvimentos promissores. Se isso acontecer, a pesquisa de mercado e as decisões de negócios em geral serão baseadas em melhores dados e técnicas analíticas mais eficazes e, portanto, mais baseadas em conhecimento. Visivelmente, as organizações e indivíduos que se movem mais rapidamente nessas áreas emergentes irão adquirir e estabelecer verdadeiras vantagens competitivas nos mercados futuros.

Questões de Privacidade e Desafios

Em seu livro *The Assault on Privacy*, Arthur Miller (1971), observou que “muitos manipuladores de informações parecem medir [um indivíduo pelo] número de *bits* de capacidade de armazenamento que o dossiê ocupará”. Atualmente, em economias avançadas, existem dados em todos, os quais vêm crescendo em tamanho exponencial, devido aos registros digitais. Cada vez mais, no entanto, as mudanças nas políticas implantadas pelo governo afetam a maneira como coletamos, acessamos, armazenamos e usamos os dados. Logo após os problemas de segurança da informação da *Cambridge Analytica*, envolvendo o Facebook, duas ou mais leis de privacidade do consumidor estão ou estarão em processo de adoção nos Estados Unidos – o

Regulamento Geral de Proteção de Dados (RGPD) e a Lei de Privacidade do Consumidor da Califórnia, A.B. 375, que foram desenvolvidas para fornecer maior controle aos clientes dos dados que foram deles coletados. Como resultado, as empresas agora precisam aumentar os controles e a transparência sobre como os dados são coletados, quais dados o são, porque os dados estão sendo coletados, quem tem acesso aos dados e como as empresas estão usando os dados coletados. Pesquisadores de marketing também são obrigados a cumprir esses regulamentos, pois enfrentam as mesmas regras na coleta, proteção e distribuição de dados identificáveis.

Capacidades de Análise de Dados São uma Importante Vantagem Competitiva

Os dados são tão bons quanto a inteligência que podemos extrair deles, e isso envolve análise de dados eficaz e muito poder computacional para lidar com o aumento exponencial do volume e do tipo de dados. A maioria das organizações (grandes, médias e até pequenas) pode aplicar a análise de dados para melhorar as atividades de manufatura, cadeia de suprimentos, gerenciamento e marketing e para ser mais eficiente e eficaz no alcance das metas organizacionais. Embora a aplicação da análise de dados esteja produzindo descobertas úteis nos campos da agricultura, saúde, urbanismo, redução do crime e energia, juntamente com os negócios em geral, ainda há muito a ser feito. O campo da análise está evoluindo rapidamente e mais oportunidades estão surgindo para aplicar as novas fontes de dados e os métodos adicionais e mais sofisticados de análise. A velocidade de adoção e aplicação à tomada de decisão influenciará certamente a aquisição de vantagens competitivas, mas os líderes nesse campo acumularão as vantagens e estas poderão se tornar insuperáveis para os retardatários.

Demanda Por Cientistas Treinados em Dados Vai Ultrapassar a Oferta

Mais universidades precisam se engajar no treinamento de novos cientistas de dados. O treinamento e a conscientização do *big data* e da análise de dados incentivarão os analistas a definirem não apenas suas perguntas de pesquisa de forma mais ampla, mas também o escopo de sua responsabilidade ao liderarem os caminhos para o uso mais eficiente de dados, na solução de problemas do mundo dos negócios. A utilização bem-sucedida da análise de dados será influenciada substancialmente pelos analistas e pelas decisões que tomarão, não apenas ao informar os gerentes seniores sobre o potencial da análise de dados, mas também quanto à seleção e aplicação das técnicas a serem utilizadas no futuro.

De acordo com o site Study Portals, nos Estados Unidos, há pouco mais de 100 programas de bacharelado com concentração no ensino de análise de dados. Esse número precisa ser cinco, talvez 10 vezes maior – e mudanças semelhantes devem seguir-se globalmente. Porém, existe uma necessidade ainda maior de mestRADOS em análise de dados (apenas cerca de 40 desses cursos são oferecidos nos Estados Unidos), já que ser um cientista de dados requer treinamento substancial. Universidades ao redor do mundo precisam se mover rapidamente para treinar tais cientistas de dados, para atendimento não apenas a demanda atual, mas para a continuidade da produção do que será uma necessidade substancial e em expansão para os cientistas de dados no futuro, particularmente no campo da pesquisa em marketing.

Referências

- Abubakar, A.M., Namin, B.H., Harazneh, I., Arasli, H., & Tunç, T. (2017). Does gender moderate the relationship between favoritism/nepotism, supervisor incivility, cynicism and workplace withdrawal: A neural network and SEM approach. *Tourism Management Perspectives*, 23, 129-139.
- Antons, D., & Breidbach, C. F. (2018). Big data, big insights? Advancing service innovation and design with machine learning. *Journal of Service Research*, 21(1), 17-39.
- Agarwal, A., Hosanagar, K., & Smith, M. D. (2011). Location, location, location: An analysis of profitability of position in online advertising markets. *Journal of marketing research*, 48(6), 1057-1073.
- Bachelor's Degrees in Data Science & Big Data in the United States, <https://www.bachelorsportal.com/study-options/269779226/data-science-big-data-united-states.html>, accessed August 2018.
- Balducci, B., & Marinova, D. (2018). Unstructured data in marketing. *Journal of the Academy of Marketing Science*, 46(4), 1-34.
- Becker, J. M., Rai, A., Ringle, C. M., & Völckner, F. (2013). Discovering unobserved heterogeneity in structural equation models to avert validity threats. *MIS Quarterly*, 37(3), 665-694.
- Chan, H. Y., Boksem, M., & Smidts, A. (2018). Neural profiling of brands: Mapping brand image in consumers' brains with visual templates. *Journal of Marketing Research*. 55(4), 600-615.
- Chung, T. S., Rust, R. T., & Wedel, M. (2009). My mobile music: An adaptive personalization system for digital audio players. *Marketing Science*, 28(1), 52-68.
- Davenport (2018) Will data scientist continue to be the sexiest job? Downloaded June 2018 at

<https://iianalytics.com/research/will-data-scientist-continue-to-be-the-sexiest-job>.

Davenport, T., & Harris, J. (2017). *Competing on Analytics: Updated, with a New Introduction: The New Science of Winning*. Harvard Business Press.

Delen, D., & Zolbanin, H. M. (2018). The analytics paradigm in business research. *Journal of Business Research*, 90, 186-195.

Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), 897-904.

Flynn, B., Pagell, M., & Fugate, B. (2018). Survey Research Design in Supply Chain Management: The Need for Evolution in Our Expectations. *Journal of Supply Chain Management*, 54(1), 1-15.

Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137-144.

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate Data Analysis* (8th ed.). Cengage Learning, U.K.

Hair, J.H., Matthews, L., Matthews, R., & Sarstedt, M. (2017). PLS-SEM or CB-SEM: Updated Guidelines on Which Method To Use," (2017), *International Journal of Multivariate Data Analysis*, Vol. 1 (2), pp 107-123.

Hair, J.H., Matthews, L., Ringle, C., & Sarstedt, M. (2016). Identifying and Treating Unobserved Heterogeneity with FIMIX-PLS: Part I – Method, *European Business Review*, 28(1), 63-76.

Hair, J. F., Sarstedt, M., Ringle, C. M., & Mena, J. A. (2012). An Assessment of the use of Partial Least Squares Structural Equation Modeling in Marketing Research. *Journal of the Academy of Marketing Science*, 40(3), 414-433.

Harris, J. M., Ciorciari, J., & Gountas, J. (2018). Consumer neuroscience for marketing researchers. *Journal of Consumer Behaviour*, 17(3), 239-252.

Harrison, D.E., Ajjan, H. and Coughlan, A. (2018). Working paper: Understanding social media sentiment, positioning and engagement: the impact on direct selling sales performance. *Informs Society of Marketing Science Proceedings*.

Harrison, D. E., & Hair, J. F. (2017). The Use of Technology in Direct-Selling Marketing Channels: Digital Avenues for Dynamic Growth. *Journal of Marketing Channels*, 24(1-2), 39-50.

Henke, N., Levine, J., McInerney, P. (2018). You don't have to be a data scientist to fill this must have analytics role. *Harvard Business Review*. February 05.

Huang, M. H., & Rust, R. T. (2018). Artificial intelligence in service. *Journal of Service Research*, 21(2), 155-172.

Hulland, J., Baumgartner, H., & Smith, K. M. (2018). Marketing survey research best practices: evidence and recommendations from a review of JAMS articles. *Journal of the Academy of Marketing Science*, 46(1), 92-108.

Hulland, J., & Miller, J. (2018). "Keep on Turkin"? *Journal of the Academy of Marketing Science*, 46(5), 789-794.

Hult, T., Hair, J. F., Sarstedt, M., Ringle, C., Proksch, D., and Pinkwart, A. (2018). Addressing Endogeneity in International

Marketing Applications of Partial Least Squares Structural Equation Modeling, *Journal of International Marketing*, forthcoming.

Humphreys, A., & Wang, R. J. H. (2017). Automated text analysis for consumer research. *Journal of Consumer Research*, 44(6), 1274-1306.

Kanellos, M. (2016). 152,000 smart devices every minute in 2025: IDC outlines the future of smart things. March 2016, retrieved from <https://www.forbes.com/sites/michaelkanellos/2016/03/03/152000-smart-devices-every-minute-in-2025-idc-outlines-the-future-of-smart-things/>.

Krause, D., Luzzini, D., & Lawson, B. (2018). Building the Case for A Single Key Informant in Supply Chain Management Survey Research. *Journal of Supply Chain Management*, 54(1), 42-50.

Kull, T. J., Kotlar, J., & Spring, M. (2018). Small and Medium Enterprise Research in Supply Chain Management: The Case for Single-Respondent Research Designs. *Journal of Supply Chain Management*, 54(1), 23-34.

Kumar, V. (2018). Transformative Marketing: The Next 20 Years. *Journal of Marketing*, 82(4), 1-12.

Matthews, L., Hair, J., Matthews, R. (2018). PLS-SEM: The holy grail for advanced analysis. *Marketing Management Journal*, 28(1), 1-13.

Matthews, L., Hair, J.H., Sarstedt, M., and Ringle, C. (2016). Identifying and Treating Unobserved Heterogeneity with FIMIX-PLS: Part II – Case Study, *European Business Review*, 28(2).

Mela, C.F. & Moorman, C. (2018). Why Marketing Analytics hasn't lived up to its promise. May 30, retrieved from <https://hbr.org/2018/05/why-marketing-analytics-hasnt-lived-up-to-its-promise>.

Netzer, O., Lattin, J. M., & Srinivasan, V. (2008). A hidden Markov model of customer relationship dynamics. *Marketing science*, 27(2), 185-204.

Roh, J. A., Whipple, J. M., & Boyer, K. K. (2013). The effect of single rater bias in multi-stakeholder research: A methodological evaluation of buyer-supplier relationships. *Production and Operations Management*, 22(3), 711-725.

Rossi, B. (2015), From insight to action: why prescriptive analytics is the next big step for data. February 2015, retrieved from <https://www.information-age.com/insight-action-why-prescriptive-analytics-next-big-step-big-data-123458977/>.

Rossi, P. E., & Allenby, G. M. (2003). Bayesian statistics and marketing. *Marketing Science*, 22(3), 304-328.

Sarstedt, M., & Ringle, C. M. (2010). Treating unobserved heterogeneity in PLS path modeling: a comparison of FIMIX-PLS with different data analysis strategies. *Journal of Applied Statistics*, 37(8), 1299-1318.

Sarstedt, M., Ringle, C., & Hair, J. (2017). Identifying and Treating Unobserved Heterogeneity in PLS: A State of the Art Review," chapter in *Recent Developments on Partial Least Squares Structural Equation Modeling: Basic Concepts, Methodological Issues and Applications*, H. Latan, and Richard Noonan, Editors, Springer International Publishing AG, Switzerland.

Shmueli, G., Ray, S., Velasquez Estrada, J. M., & Chatla, S. B. (2016). The elephant in the room: Predictive performance of PLS models, *Journal of business Research*, 69, 4552-4564.

Sivarajah, U., Kamal, M. M., Irani, Z., & Weerakkody, V. (2017). Critical analysis of Big Data challenges and analytical methods. *Journal of Business Research*, 70, 263-286.

Sorescu, A., Warren, N. L., & Ertekin, L. (2017). Event study methodology in the marketing literature: an overview. *Journal of the Academy of Marketing Science*, 45(2), 186-207.

Snyman, J. A. and Wilke, D. N. (2005). Practical mathematical optimization: basic optimization theory and gradient-based algorithms. Springer.

Varadarajan, R. (2018). A Commentary on "Transformative Marketing: The Next 20 Years". *Journal of Marketing*. 82(4), 15-18.

Verma, P., Agarwal, S., Kachroo, P., & Krishen, A. (2017). Declining transportation funding and need for analytical solutions: dynamics and control of VMT tax. *Journal of Marketing Analytics*, 5(3-4), 131-140.

Wedel, M., & Kannan, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(6), 97-121.

White, S., (2017). What is a data scientist? A key data analytics role and a lucrative career. <https://www.cio.com/article/3217026/data-science/what-is-a-data-scientist-a-key-data-analytics-role-and-a-lucrative-career.html>, accessed August, 2018.

Worm, S., Bharadwaj, S. G., Ulaga, W., & Reinartz, W. J. (2017). When and why do customer solutions pay off in business markets? *Journal of the Academy of Marketing Science*, 45(4), 490-512.