



Francisco Salas-Molina
Departamento de Dirección
de Empresas "Juan José
Renau Piqueras"
Universitat de València
francisco.salas-molina@uv.es

New languages for economics

Nuevos lenguajes para la economía

I. INTRODUCTION

The use of technology, understood as a tool to facilitate the development of a task, is not new in economics. Indeed, economic science, although traditionally placed within the field of social sciences alongside law, sociology or psychology, has used mathematics (a technology) to describe the economic behavior of society. The use of mathematics in economics probably has its origin in the figure of Léon Walras (1834-1910) and perhaps one of its peak moments when Samuelson (1952) quoted Willard Gibbs (1839-1903) saying: "Mathematics is a language", and came to an end by attributing Irving Fisher (1867-1947) the irony: "there is nowhere you can go by train to which you cannot go on foot" in response to critics of the use of mathematics in economics. The great advantage of mathematics in economics is both its ability to synthesize and its precision, the possibility of saying much with very little, of expressing an idea with a very small set of symbols and avoiding ambiguities. In this context, the concept of language is defined as a general set of signs and rules that allows communication between agents. The definition itself is a guarantee of the usefulness of new languages as tools for economic interaction and knowledge transmission. In this sense, language is a technology, a tool that facilitates the development of a task.

It would be absurd to deny that information and communications technologies (ICT), especially artificial intelligence, will mark a new economic era. A different matter is, however, if economic agents (consumers, companies, governments and other organizations) are prepared to assimilate ICT as a critical element for their development. If we assume that the digital transformation is going to become a sine qua non condition for economic advancement, it seems reasonable to work to provide economic agents of the near future with the right tools. To this end, a language different to the common one is necessary: the language of machines. The language



EXECUTIVE SUMMARY

The digital economy implies the need for managers to understand new languages that were usually restricted to other fields. Artificial intelligence requires that economic agents understand the language of machines to make data-driven decisions. Moreover, the language of multicriteria economics shows to be more coherent with economic reality than the traditional single criterion perspective. The quality of decision-making depends on the ability of managers to learn these new languages.

RESUMEN DEL ARTÍCULO

La economía digital implica la necesidad de los directivos de comprender nuevos lenguajes que habitualmente estaban restringidos a otros ámbitos. La inteligencia artificial requiere que los agentes económicos comprendan el lenguaje de las máquinas para tomar decisiones basadas en datos. Además, el lenguaje de la economía multicriterio demuestra ser una herramienta más coherente con la realidad económica que la tradicional perspectiva de criterio único. De la capacidad de los directivos para aprender estos nuevos lenguajes dependerá la calidad de sus decisiones.

...although traditionally placed within the field of social sciences alongside law, sociology or psychology, has used mathematics (a technology) to describe the economic behavior of society.

of machines should be understood as a broad concept that encompasses different aspects of ICT such as access, treatment and communication of information in its different formats. These aspects make the language of machines a key element in business management systems, in the communication between individuals and companies, in the automation of industrial and administrative processes and also in decision making support. From them, this work focuses on supporting business decision making through the application of artificial intelligence in business. The reason for this selection is twofold. Firstly, due to its current impact on the economy (Dirican, 2015) and, secondly, due to the high probability that its application in the field of decision results in an improved performance of managers and companies (Provost and Fawcett, 2013).

Artificial intelligence refers to algorithms that allow machines to learn to perform tasks autonomously, demonstrating a certain degree of rationality that resembles the natural intelligence of humans. The big investors in artificial intelligence are technological companies such as Google, Microsoft, Facebook, Amazon, Apple whose economic importance, measured in terms of market capitalization and / or market presence, is beyond any kind of doubt. From a competitive point of view, the most important economic impact of artificial intelligence will happen in employment. Recent works such as Acemoglu and Restrepo (2018) and Hidalgo (2018) study the impact that artificial intelligence will have on employment. The first one carries out a more formal and academic analysis and concludes that automation and artificial intelligence increase productivity further than the wages of workers by reducing the relative importance of labor share in the economy. The second one aims to a wider audience and point out the economic, labor and social imbalances that will arise with technological change and the need of adaptation processes. This work aims to highlight the benefits that artificial intelligence can provide managers in their decision-making processes due to the lack of current development in business. Admitting that predictive models have been extensively studied in the literature through econometrics, managers are constantly looking for alternative methods to make better decisions such as those based on artificial intelligence (e.g. Salas-Molina et al., 2017).

Another language that has traditionally been neglected in the educational field of economics and finance is the multicriteria language. Briefly, the traditional economic approach addresses most problems by selecting the best among the feasible (Caballero and Romero, 2006). Feasible decisions include all the alternatives that satisfy a set of constraints and, therefore, are available to the economic decision maker for evaluation and subsequent implementation. The characterization of the best alternative requires the use of a criterion (normally, a mathematical function) that represents the preferences of the decision maker in a realistic way. This aspect, the representation of reality, is the main reason of the limitations of the traditional approach. By making decisions based on a single criterion, the economic world whose nature is obviously multidimensional, is reduced to a single dimension. When considering a single criterion, the economic problem is simpler, and we can easily find solutions. But at the same time, some aspects of the problem are necessarily out of the analysis, reducing its suitability to appropriately represent the reality under consideration. The motivation of the multicriteria language in economics and finance is to respect the internal coherence of classical models while advancing in its external coherence to better adjust them to economic reality, as pointed out by Ballesteros and Romero (1998). The main motivation of the multicriteria language in business is the fact that when there is a decision maker concerned with two or more criteria, he/she cannot continue using traditional optimization techniques, but it is necessary to apply new techniques to make the best decisions.

The underutilization of ICT and operational research when learning economics will hinder the integration of future professionals in businesses and, ultimately, the economic development of the organizations in which they carry out their job. To reduce this training deficit, this work proposes the expansion of the economic language to integrate these increasingly required abilities. This extension has two main goals:

- Learning the language of machines to manage the impact of ICT and that economic agents become truly intelligent agents through data-driven decisions.
- Learning the multicriteria language to be able to handle the multidimensional complexity of economics and allow a better fit of economic models to reality.

KEYWORDS

operations research, artificial intelligence, multicriteria decision-making, training.

PALABRAS CLAVE

investigación operativa, inteligencia artificial, decisión multicriterio, formación.



The combination of the language of machines and the multicriteria language represents an additional contribution of this work. Both the language of machines and the multicriteria language are tools designed to make better decisions based on data or considering more than one criterion. Both proposals are two sides of the same coin: the use of methods to facilitate the resolution of many problems in an increasingly complex business environment. Learning the basics of these two languages by managers can be very useful as a starting point to deepen in the presented techniques.

Together with this introduction, Section 2 introduces the language of machines as a critical factor in economic and business development. In Section 3, the multicriteria language is added as a tool to broaden the range of aspects considered to make better decisions. Section 4 presents the main conclusions that can be drawn from the proposal described in this paper.

2. THE LANGUAGE OF MACHINES


Are economic agents truly intelligent? Some experiments in behavioral economics seem answer no to this question (Thaler, 2015). However, it is worth considering whether we can provide economic agents with tools that improve their ability to interact with a complex and changing economic environment. Any refusal to improve the abilities of a professional group seems unjustified. One of those skills is the language of machines. From a broad perspective, learning the language of machines allows managers to be ready to improve the outcome of their decisions using ICT. Reducing the degree of abstraction, we must talk about artificial intelligence that is increasingly becoming a basic tool in the decision-making process of managers. It is true that artificial intelligence encompasses some complexity, but it is also true that some artificial intelligence techniques such as decision trees can reduce complexity so that managers can focus on what really matters, that is, on improving decision-making.

The first interesting question that arises from the binomial concept of artificial intelligence is its antagonism with respect to natural intelligence. Although we do not know with certainty what artificial intelligence is, we do know what it is not, that is, it is something different from the natural intelligence with which we humans are endowed. This first inverse approach to the concept of artificial

intelligence is deliberate and intentional. By depriving the concept of all technological sophistication, artificial intelligence becomes something much more affordable, available to anyone who wants to learn. Let's think for a moment about the traffic lights that regulate vehicles and pedestrians at any junction in a city. A program (an algorithm) determines who should move and who should stop by means of a color code and a time sequence. And the best thing is that the process is autonomous. Once the algorithm has been executed, human intervention is not necessary for its development. It could be running indefinitely as long as there is no power failure or any other breakdown. That feature is the key. One way or another, we have provided the system with the required autonomy to make decisions. These decisions are probably simple and repetitive. Probably, as simple and repetitive as many of our economic decisions. The interesting thing, however, is that our innovative capacity is the only limit to develop artificial intelligences that are more complex than those of a traffic light and that are also useful for improving the capabilities of economic agents.

If we admit that artificial intelligence is a technique, a tool, a method that allows us to improve our economic decision-making capacity, let us now ask what kind of capabilities we are talking about. A person's ability is a concept still too abstract. Although its classification admits some discussion, data science is usually framed as a subfield of artificial intelligence (Provost and Fawcett, 2013). One of the tasks where data science can help you make better economic decisions is prediction. However, prediction is not just an estimate of what is expected to happen in the future. And this feature has economic implications that are worth highlighting. In general, predictive models try to segment observations based on the attribute that we would like to know as accurately as possible. This definition fits well in time-series forecasting, where the observations are gathered in a historical data-set and the attribute that is intended to be forecasted is the next value of the series.

However, there are several predictive models that may not be so obvious, but with significant economic repercussions. In business, some attributes that we may be interested in are, for example, if customers will respond positively to a commercial action, if they will repeat their purchase before three months, if they will pay as agreed, if they will be late in payment or if they will unfortunately fail to pay. In this case, the population is a set of customers whose





behavior has been observed in the past and which are characterized by a series of variables. For example, we can make observations about the customers of an online book seller including aspects such as age, gender, place of residence, recommendations sent, when purchases were made and what type of books were bought. The attribute that we are interested in predicting is whether they will purchase a new book in the next Christmas campaign if they receive a personalized recommendation. To this end, we can use classification models, that is, those that do not aim to predict an amount (e.g., sales) but a category: yes / no, type A, B, C or D. In other words, we seek to classify the customers in groups: those who will buy and those who will not buy (Marsland, 2014). Since we know the impact that the recommendations had in the past, we are dealing with supervised learning. The data used contains the value of the objective attribute (buy or not buy) for customers in the past. On the other hand, when we want to group customers according to a series of characteristics that allow for personalized recommendations, we talk about unsupervised learning. One of the unsupervised learning techniques that the online book seller of the previous example could use is clustering or group analysis (Likas et al, 2003) to design personalized recommendations for customers. The objective is now to divide a set of customers into different groups so that the members of each group (cluster) share similar characteristics with each other. In this sense, the similarity is usually established by means of the distance between the points that represent the members of the group. Real world examples of how artificial intelligence is causing a substantial change in business are, among others, the legal services company Juriblox B.V. which uses artificial intelligence to analyze the text of confidentiality agreements, or Anfix that has developed a tool to automatically map an invoice to its corresponding expense account.


Along with automation, one of the main tasks of artificial intelligence is prediction. One could argue that predictions have been part of economic science for a long time. That is right, it is called econometrics. There is nothing to object to such an argument, but artificial intelligence has complemented techniques focusing on parameters of regression models with a broader range of predictive models such as classification and recommendation systems. Sharing mathematical foundations, the focus has shifted from formal statistical properties to the maximization of its practical utility, that

is, to the maximization of precision and the delivery of answers that can be put into practice as we demonstrate in the next use case.

2.1. Application of artificial intelligence in credit risk assessment


Instead of what it may seem at first glance, credit risk assessment is not a task restricted to the banking business. Any company serves its customers and any customer has a risk of default that should be evaluated. To this end, managers face the task of eliciting the level of credit risk they are willing to admit. Let us define now the business problem to be solved. One or more customers ask for new or an extension of the credit with the company. A manager of the company must approve or reject the request. Faced with this situation, the manager has two ways of action: 1) make a decision based on his intuition and experience; and 2) make a decision based on data through the application of artificial intelligence techniques. If the second option is chosen, the first step is collecting historical data about customers. This data-set contains attributes that characterize applicants who have ask for credit in the past including their payment history, age, employment status, type of work, number of dependents, the amount requested, if they have other credits or the purpose of the credit. From this data-set, the objective is to evaluate whether a new application should be accepted or not, whether it should be classified as good or as bad.

To make data-driven decisions, we can use some of the techniques that artificial intelligence offers us such as decision trees (Quinlan, 1986; Rokah and Maimon, 2008). Decision trees show advantages in comparison with other techniques because of their versatility and because their results are easy to interpret. This technique performs a non-linear split of data in a tree-like structure with a root node, with branches starting from the root node and reaching a series of interior nodes and terminal nodes, called leaves, as shown in **Figure 1**. In each of these interior nodes an evaluation of an attribute of the clients is carried out so that each branch collects the cases with a different value of the attribute. The data splitting process is repeated from the root node to the terminal nodes so that each customer follows a single path in the tree and is assigned a credit rating (good or bad) based on the values of each of the attributes considered. When a new loan application is received, a manager who makes decisions based on intuition will consider at most three



or four features. On the contrary, a manager who makes data-driven decisions can consider hundreds of features of a new applicant and can also evaluate in seconds using decision trees. Therefore, it seems clear that the manager who makes data-driven decisions using artificial intelligence has better tools than intuition.

Figure 1. **A decision tree for credit evaluation**
(Source: www.bigml.com)



In the example shown in **Figure 1**, the goal is to classify the credit applicants of a bank based on a set of attributes that allow a multidimensional segmentation into a formal decision tree. The first attribute reviewed is the credit history and the last one the number of dependent persons in charge of the applicant. When receiving a new request, the model and features of the customer are used for evaluation purposes. For example, if the credit history has not been qualified as critical, if his/her savings are not less than 100, if the applicant does not own real estate, if their savings are between 100 and 500, if the purpose of the credit is not the purchase of a car, if the customer's age is less than 50 years, if he/she has had work in the last year and the number of dependents is more than one, the model recommends to accept the credit since 80.64% of the applicants with these features turned out to be good applicants. The decision maker not only receives a recommendation, but also a


list of the criteria used to provide this recommendation. This is one of the great advantages of decision trees.

3. THE MULTICRITERIA LANGUAGE

Economics is a science of reasoning rather than a science of memorization. However, there is a basic reasoning that seems not to have success among mainstream economists and managers. This reasoning is based on the fact that in most economic situations decisions are made taking into account not one but several criteria. The consumer not only looks for the best price, but also analyzes the quality of the products he buys. The consumer aims to find a balance, a compromise between price and quality. The analysis can be extended to companies that not only aim to maximize profits, but also maximize growth or minimize the risks or environmental impact of their activities. If decisions are usually made by considering several criteria, it seems clear that economic agents should develop methods to make the best decisions within a multicriteria context.

The basic idea behind multicriteria decision theory is the evaluation of the available alternatives from several points of view, that is, with different criteria. Its roots date back in time to Benjamin Franklin (1706-1790) who made his most important decisions by taking a sheet of paper and writing all the arguments in favor on one side and all the arguments against on the other side. The side with more arguments established the sign of the decision. More formally, Caballero and Romero (2006) define the multicriteria paradigm as the set of mathematical methods and computing techniques to evaluate with an explanatory, normative or prescriptive purpose a finite and explicit number (discrete case) or infinite (continuous case) of alternatives in terms of a finite number of criteria.

Multicriteria decision theory is based on an economic concept: the Pareto efficiency principle. This principle indicates that a society is in an optimal state if no person can improve its situation without worsening the situation of another. If we substitute the term person with the term criterion, we will deal with the usual scenario of the search for solutions to a multicriteria problem. When this search is done by calculating distances to an ideal point, we use compromise programming (Zeleny, 1982). When the search for the best solutions is done by calculating the deviations from aspiration levels set by the decision maker, we use goal programming (Jones and Tamiz,





2010). Other multicriteria techniques designed to solve problems with discrete alternatives through rankings are PROMETHEE (Brans and Mareschal, 2005) ELECTRE (Figueira et al., 2013) and the hierarchical analytical process (Saaty, 1980). The scope of multicriteria decision theory covers areas such as portfolio selection, location problems, optimal blending problems in textiles, chemical or agri-food industry, minimization of environmental impact, advertising and marketing, selection of suppliers (Steuer, 1986). A successful application of multicriteria in healthcare is the proposal by Omakase consulting of a multicriteria evaluation framework for orphan drugs for which the pharmaceutical industry has little interest due to the small market size involved (Badia et al., 2019). The evaluation of the sustainability of eucalyptus plantations in northwestern Spain through multiple indicators is another example of how multicriteria language enriches decision making (Díaz-Balteiro et al., 2016).


The presence of at least two criteria usually involves the conflict between the achievement of alternative criteria. The consumer interested in the lowest price and the highest quality faces the problem of accepting a worse quality to reduce the price or, conversely, having to accept a higher price to increase the quality of the product under consideration. The investor aiming to increase the expected return will have to accept a higher risk. On the contrary, if he seeks to reduce the risk, he will have to accept a lower return. A trade-off relationship between pairs of criteria is thus established as the amount to be sacrificed in one criterion to achieve an increase of one unit in another criterion. Given this situation of conflict between criteria, decision makers face the problem of finding a compromise solution, a balanced solution that satisfies them according to their personal preferences for each of the criteria under consideration.

Since the simultaneous optimization of multiple objectives is usually impossible, the decision maker seeks for a set of solutions that represent a compromise between the different objectives. To do this, we often resort to evaluating alternatives in a normalized space that allows comparisons between criteria with different units and scales. Within this multidimensional space, there is a singular point that produces the highest degree of achievement for all the criteria considered independently. Because of that, it is called the ideal point since it is usually not feasible. However, it is the best reference point to evaluate alternative solutions. A logical method to carry out this evaluation is to follow the Zeleny's axiom of choice (Zeleny, 1982):

“the solutions that are closer to the ideal point are preferred to those that are further”. In this selection rule, near or far are distance expressions that have a solid mathematical support. Although there are many types of distance (Euclidean, Manhattan, Chebyshev, Mahalanobis, Hausdorff), the ones used in this work due to their simplicity are the Euclidean distance calculated as the length of the line between two points and the Manhattan distance that is the sum of the horizontal and vertical separation between two points. However, a variation in the decision maker's preferences toward any of the criteria may cause the best solution to vary. To include the decision maker's preferences for any of the criteria considered, we can use weighted distance functions where a different weight is attached to every criterion.

3.1. A case study in the textile industry

A multicriteria decision problem aims to simultaneously optimize a finite set of objective functions subject to a set of constraints. Within an economic context, this set of objective functions includes the expression of the multiple economic value that the different alternatives have for the decision maker. Consider, for example, the concept of shared value proposed by Porter and Kramer (2011). In a new vision of capitalism, Porter and Kramer propose that organizations should change their traditional vision of profit maximization to a broader perspective in which the purely economic dimension is considered as important as the improvement of economic and social conditions of the communities where they develop their activities. Under this new vision, a company must move from a traditional strategy where a single (economic) criterion is considered to a shared value strategy where two or more criteria (economic, social, environmental ...) are optimized. Some examples of these criteria may be the minimization of cost, emissions to the atmosphere, and the wage inequality between men and women, or the maximization of sales, the satisfaction of employees and clients or the use of renewable energies. The thesis of Porter and Kramer is that this new perspective will solve many of the problems of capitalism while facilitating innovation and long-term economic growth. One of these problems is the consumption of natural resources.





The global demand for textile products has increased in recent decades from 4 kg per person per year in 1950 to 13 kg today (Carrera, 2017). This demand implies a large consumption of resources. For example, the large amount of water needed to grow conventional cotton has led to the desiccation of the Aral Sea (Chapagain et al, 2006). Faced with this situation, the large textile companies selling both fashion and home textiles, should consider a reorientation of their product offering through multicriteria. On the one hand, they must maintain their goal of maximizing long-term benefits. On the other, they should consider reducing the environmental impact of their activities as an additional objective. There is no doubt about the measurement of profits by companies. However, the measurement of the environmental impact of textile production activities involves greater difficulties. One way to solve this problem is to use the Higg index (Sustainable Apparel Coalition, 2019). This index allows companies to analyze the environmental impact of the materials used in their manufacturing process, comparing their products with those made by the rest of the sector to make better decisions about sustainable materials. The Higg index includes aspects such as water consumption, fossil fuels, eutrophication, emissions to the atmosphere or the use of chemical products. Accepting that cotton is the most consumed natural fiber and, at the same time, the one of those with the greatest environmental impact (Chapagain et al, 2006), it seems reasonable to focus the analysis on the conventional and recycled variants of this textile fiber. If we compare the environmental impact of these two options, we see that the Higg index for conventional cotton is 98 while for recycled cotton it is only 39 (a higher figure indicates a greater impact in comparative terms). On the other hand, if recycled materials require additional operations of collection, cleaning and transformation process, this may imply an extra cost of the recycled products. For illustrative purposes, consider a textile company that is evaluating the substitution of the conventional cotton used for tablecloths with recycled cotton and that the respective costs and impacts per unit of production are shown in **Table 1**.

The textile company in our case study aims to know the optimal production mix from a multicriteria perspective, that is, considering both the cost of production and the environmental impact measured according to the Higg index. To this end, we show in **Table 2** all the possible production combinations. Next, we calculate both

Table 1. **Estimated cost and Higg index for conventional and recycled textiles.**

	COST (€)	HIGG INDEX
Conventional	48	98
Recycled	90	39

the cost (C) and the environmental impact (H) derived from the application of each alternative production mix. The result is two different evaluations for each feasible alternative. However, the selection of the best solution is far from being obvious. To select one of the alternatives, a logical method is to calculate the distance to the ideal point where both the cost and the impact are zero. This point is usually unfeasible, but it represents a clear reference for the selection of the best alternatives. The fifth column presents the Euclidean distance to the origin in the C-H space (Cost-Higg Index). From the observation of this column, we see that the closest alternative to the ideal point is the mix 30% conventional - 70% recycled. This production mix is the optimal solution under a multicriteria perspective. It is also possible to use other types of distances such as the Manhattan derived from the sum of the two components C and H. By observing **Table 2**, we observe that the

Table 2. **Deriving the production mix that minimizes cost and environmental impact.**

CONVENTIONAL PRODUCTION (%)	RECYCLED PRODUCTION (%)	COST (C)	IMPACT (H)	EUCLIDIAN DISTANCE $\sqrt{(C^2+H^2)}$	MANHATTAN DISTANCE C+H
0,0	1,0	90,0	39,0	98,09	129,00
0,1	0,9	85,8	44,9	96,84	130,70
0,2	0,8	81,6	50,8	96,12	132,40
0,3	0,7	77,4	56,7	95,95	134,10
0,4	0,6	73,2	62,6	96,32	135,80
0,5	0,5	69,0	68,5	97,23	137,50
0,6	0,4	64,8	74,4	98,66	139,20
0,7	0,3	60,6	80,3	100,60	140,90
0,8	0,2	56,4	86,2	103,01	142,60
0,9	0,1	52,2	92,1	105,86	144,30
1,0	0,0	48,0	98,0	109,12	146,00



use of the Manhattan distance recommends another production mix as the optimum solution. Indeed, it recommends an unbalanced solution since it is known that Manhattan distances tend to recommend solutions that are further from the compromise between the criteria considered.

The main advantage of applying multicriteria techniques to economic and business problems is that it allows enriching the process with aspects that are normally neglected when decisions based on a single criterion are made. Multicriteria analysis allows to analyze what is the tradeoff between two or more criteria. What cost increase do I have to accept for reducing the environmental impact of my production? What increase in risk occurs when the returns of my investment increase by one unit? These questions find answers in the multicriteria language. On the contrary, the presence of multiple criteria forces decision makers to define what their preferences are for each of them. This subjective task can be simple when two or three criteria are considered, but it is more complex when multiple criteria are used to make decisions. However, techniques such as the Hierarchical Analytical Process proposed by Saaty (1980) allow this issue to be logically and consistently solved.

At this point, it is worth asking why the theory of multicriteria decision is important for managers. The answer has already been given before, but it should be repeated now. The traditional approach to economic analysis has focused on the optimization of a single criterion when economic reality involves many problems in which the presence of different decision criteria is a must. In this way, if the aim is the improvement of decision models in a way that represents economic reality as faithfully as possible, multicriteria decision theory is a powerful tool for economic analysis. It is not a matter of replacing the traditional mono-criterion approach, but of providing managers with an additional tool that better fits the decision-making behavior of real economic agents. In short, it is a technological improvement, an innovation that increases the level of their professional skills.


4. CONCLUSIONS

A language is a complex system of signs and expressions that allows communication, but the most important thing is that it increases the ability of the one who masters it to interact with the surrounding environment.

4.1. Implications for management

Currently, the language of machines has changed the way we interact with other people, but also with economic agents. Access to information has dramatically increased and the need to make decisions based on data justifies a broad range of competencies for managers. It is convenient, however, to add a word of caution. Managers should not become computer experts but hybridize their economic knowledge with that coming from the ICT field. Companies generate a large amount of data on an ongoing basis. A good way to learn the language of machines is to extract knowledge from that data through artificial intelligence.

Economics is a complex science but not unaffordable. Traditionally, the single criterion approach has been the mainstream scheme, but reality shows us that economic agents are multidimensional entities. They make decisions trying to optimize different objectives. The multicriteria language allows all these dimensions to be integrated into a logical system so that decisions are more precisely adjusted to the complex surrounding reality. Multicriteria decision techniques become powerful tools to complete the economic abilities of managers.



4.2. Limitations and future lines of research

The scope of this work is limited to demonstrate from a theoretical point of view the usefulness of the language of machines and the multicriteria language to facilitate the resolution of problems of an increasingly complex business and economic environment. The description of key concepts in both fields and the references offered are not intended to be an exhaustive analysis but an introduction that can be useful to managers. The ability to fit managers to the new economic context will ultimately depend on their capacity to learn these new languages. The practical cases provided serve as a starting point to identify the training needs of managers. In this


sense, an interesting future line of research may be the proposal of specific training methodologies on the implementation of these languages in business.



REFERENCES

- Acemoglu, D., & Restrepo, P. (2018). Artificial Intelligence, Automation and Work (No. w24196). National Bureau of Economic Research.
- Badia, X., Chugani, D., Abad, M. R., Arias, P., Guillén-Navarro, E., Jarque, I., Posada, M., Vitoria, I. & Poveda, J. L. (2019). Development and validation of an MCDA framework for evaluation and decision-making of orphan drugs in Spain. *Expert Opinion on Orphan Drugs*, 7(7-8), 363-372.
- Ballestero, E., & Romero, C. (1998). Multiple criteria decision making and its applications to economic problems. Kluwer. Dordrecht.
- Brans, J. P., & Mareschal, B. (2005). PROMETHEE methods. In *Multiple criteria decision analysis: state of the art surveys* (pp. 163-186). Springer, New York, NY.
- Caballero, R., & Romero, C. (2006). Teoría de la decisión multicriterio: un ejemplo de revolución científica Kuhniana. *Boletín de Estadística e Investigación Operativa. BEIO*, 22(4), 9-15.
- Carrera Gallissà, E. (2017). Los retos sostenibilistas del sector textil. *Revista de Química e Industria Textil*, (220), 20-32.
- Chapagain, A. K., Hoekstra, A. Y., Savenije, H. H., & Gautam, R. (2006). The water footprint of cotton consumption: An assessment of the impact of worldwide consumption of cotton products on the water resources in the cotton producing countries. *Ecological Economics*, 60(1), 186-203.
- Díaz-Balteiro, L., Alfranca, O., González-Pachón, J., & Romero, C. (2016). Ranking of industrial forest plantations in terms of sustainability: a multicriteria approach. *Journal of Environmental Management*, 180, 123-132.
- Dirican, C. (2015). The impacts of robotics, artificial intelligence on business and economics. *Procedia-Social and Behavioral Sciences*, 195, 564-573.
- Figueira, J. R., Greco, S., Roy, B., & Słowiński, R. (2013). An overview of ELECTRE methods and their recent extensions. *Journal of Multi-Criteria Decision Analysis*, 20(1-2), 61-85.
- Hidalgo, M. A. (2018). El empleo del futuro: Un análisis del impacto de las nuevas tecnologías en el mercado laboral. Deusto. Barcelona.
- Jones, D., & Tamiz, M. (2010). *Practical goal programming* (Vol. 141). New York: Springer.
- Likas, A., Vlassis, N., & Verbeek, J. J. (2003). The global k-means clustering algorithm. *Pattern recognition*, 36(2), 451-461.
- Marsland, S. (2014). *Machine learning: an algorithmic perspective*. Chapman and Hall/CRC, Londres.
- Porter, M. E., & Kramer, M. R. (2011). The big idea: Creating shared value. *Harvard Business Review*, 89 (1-2).

- Provost, F., & Fawcett, T. (2013). *Data Science for Business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media.
- Rokach, L., & Maimon, O. Z. (2008). *Data mining with decision trees: theory and applications* (Vol. 69). World scientific.
- Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1), 81-106.
- Saaty T.L., (1980). *The Analytic Hierarchy Process*. McGraw Hill, New York.
- Salas-Molina, F., Martin, F. J., Rodriguez-Aguilar, J. A., Serra, J., & Arcos, J. L. (2017). Empowering cash managers to achieve cost savings by improving predictive accuracy. *International Journal of Forecasting*, 33(2), 403-415.
- Samuelson, P. A. (1952). Economic Theory and Mathematics--An Appraisal. *The American Economic Review*, 42(2), 56-66.
- Steuer, R. E. (1986). *Multiple criteria optimization: theory, computation, and application* (Vol. 233). New York: Wiley.
- Sustainable Apparel Coalition (2019). Materials sustainability index. <https://msi.higg.org/>
- Thaler, R. H. (2015). *Misbehaving: The making of behavioral economics*. Norton. New York.
- Zeleny, M., (1982). *Multiple criteria decision making*. McGraw-Hill, New York.





Francisco Salas-Molina
Departamento de Dirección
de Empresas "Juan José
Renau Piqueras"
Universitat de València
francisco.salas-molina@uv.es

Nuevos lenguajes para la economía

New languages for economics

I. INTRODUCCIÓN

El uso de la tecnología, entendida como una herramienta que facilita el desarrollo de una tarea, no es nuevo en economía. De hecho, la ciencia económica, aunque tradicionalmente encuadrada en el ámbito de las ciencias sociales junto al derecho, la sociología o la psicología, se ha valido de las matemáticas (una tecnología) para ir avanzando en su intento de describir el comportamiento económico de la sociedad. El uso de las matemáticas en la economía tiene probablemente su origen en la figura del economista Léon Walras (1834-1910) y quizá uno de sus momentos álgidos cuando Samuelson (1952) puso en boca del físico Willard Gibbs (1839-1903) la expresión: "las matemáticas son un lenguaje" y finalizó atribuyendo al economista Irving Fisher (1867-1947) la ironía: "no hay ningún sitio al que puedas ir en tren al que no puedas ir a pie" como respuesta a los críticos de la matematización de la economía. La gran ventaja de las matemáticas en economía es tanto su capacidad de síntesis como su precisión, es decir, la posibilidad de decir mucho con muy poco, de expresar una idea con un conjunto muy reducido de símbolos y evitar ambigüedades. En este contexto, el concepto de lenguaje se define como un conjunto general de signos y reglas que permite la comunicación entre agentes. La propia definición es garantía de la utilidad de los nuevos lenguajes como herramientas para la interacción económica y la transmisión de conocimientos. En este sentido, el lenguaje es una tecnología, una herramienta que facilita el desarrollo de una tarea.

Sería absurdo negar que las tecnologías de la información y las comunicaciones (TIC), muy especialmente la inteligencia artificial, van a marcar una nueva era económica si es que no lo están haciendo ya. Cuestión distinta es, sin embargo, si los agentes económicos (consumidores, empresas, gobiernos y otras organizaciones) están preparados para asimilar las TIC como un elemento crítico



RESUMEN DEL ARTÍCULO

La economía digital implica la necesidad de los directivos de comprender nuevos lenguajes que habitualmente estaban restringidos a otros ámbitos. La inteligencia artificial requiere que los agentes económicos comprendan el lenguaje de las máquinas para tomar decisiones basadas en datos. Además, el lenguaje de la economía multicriterio demuestra ser una herramienta más coherente con la realidad económica que la tradicional perspectiva de criterio único. De la capacidad de los directivos para aprender estos nuevos lenguajes dependerá la calidad de sus decisiones.

EXECUTIVE SUMMARY

The digital economy implies the need for managers to understand new languages that were usually restricted to other fields. Artificial intelligence requires that economic agents understand the language of machines to make data-driven decisions. Moreover, the language of multicriteria economics shows to be more coherent with economic reality than the traditional single criterion perspective. The quality of decision-making depends on the ability of managers to learn these new languages.

***...las ciencias sociales junto
al derecho, la sociología
o la psicología, se ha
valido de las matemáticas
(una tecnología) para
ir avanzando en su
intento de describir
el comportamiento
económico de la sociedad.***

para su desarrollo. Si asumimos que la transformación digital se va a convertir en condición sine qua non para el avance económico, deberíamos estar trabajando para que los agentes económicos de un futuro no tan lejano dispongan de las herramientas adecuadas. Para ello, es necesario un lenguaje distinto al habitual: el lenguaje de las máquinas. El lenguaje de las máquinas debe entenderse como un concepto amplio que engloba distintos aspectos de las TIC como el acceso, el tratamiento y la comunicación de información en sus distintos formatos. Estos aspectos hacen que el lenguaje de las máquinas sea un elemento clave en los sistemas de gestión empresarial, en las comunicaciones entre individuos y empresas, en la

automatización de los procesos industriales y administrativos y en el soporte a la toma de decisiones. De todos ellos, este trabajo se centra en el soporte a la toma de decisiones empresariales a través de la aplicación de la inteligencia artificial en el ámbito empresarial. La razón de esta selección es doble. En primer lugar, por su impacto actual en la economía (Dirican, 2015) y, en segundo lugar, por la alta probabilidad de que su aplicación en el ámbito de la decisión sirva para mejorar el desempeño de directivos y empresas (Provost y Fawcett, 2013).

La inteligencia artificial hace referencia a los algoritmos que permiten a las máquinas aprender a realizar tareas de una manera autónoma demostrando cierto grado de racionalidad que se asemeja a la inteligencia natural propia de los humanos. Los grandes inversores en inteligencia artificial son las multinacionales tecnológicas como Google, Microsoft, Facebook, Amazon, Apple cuya importancia económica, medida en términos de capitalización bursátil y/o de presencia en el mercado, está fuera de toda duda. Desde un punto de vista competencial, el gran impacto económico de la inteligencia artificial se producirá en el ámbito del empleo. Trabajos recientes como Acemoglu y Restrepo (2018) e Hidalgo (2018) estudian el impacto que la inteligencia artificial tendrá en el empleo. El primero de los trabajos realiza un análisis más formal y académico y llega a la conclusión de que la automatización y la inteligencia artificial aumentan la productividad por encima de los salarios de los trabajadores reduciendo la importancia relativa del factor trabajo en la economía. El segundo de ellos está dirigido a una audiencia más amplia y advierte de los desequilibrios econó-

micos, laborales y sociales que surgirán con el cambio tecnológico y de la necesidad de adaptarse a ellos. Este trabajo trata de destacar la ayuda que la inteligencia artificial puede ofrecer a los directivos en el proceso de toma de decisiones por la falta de desarrollo que ha tenido en el ámbito empresarial. Admitiendo que los modelos predictivos se han estudiado sobradamente en la literatura a través de la econometría, los directivos buscan constantemente métodos alternativos para tomar mejores decisiones como los basados en la inteligencia artificial (e.g. Salas-Molina et al., 2017).

Otro de los lenguajes que tradicionalmente se ha visto relegado a un segundo plano en el ámbito educativo de la economía y las finanzas es el lenguaje multicriterio. De manera sucinta, el enfoque económico tradicional afronta los problemas a través de un proceso de selección de lo mejor entre lo posible (Caballero y Romero, 2006). Dentro del conjunto de lo posible se encuentran todas las alternativas que son viables y que, por tanto, están a disposición del decisor económico para su evaluación y posterior implementación. La caracterización de lo mejor requiere la utilización de un criterio (normalmente, una función matemática) que represente de la manera más fiel posible las preferencias del decisor. Este último aspecto, la representación fiel de la realidad, es el que provoca que el enfoque tradicional presente algunas limitaciones. Al tomar decisiones en base a un único criterio, un mundo económico cuya naturaleza es evidentemente multidimensional, se reduce a una única dimensión. Al considerar un único criterio, el problema económico resulta más sencillo y podemos encontrar soluciones útiles con mayor facilidad. Pero al mismo tiempo, algunos aspectos del problema quedan irremediabilmente fuera del análisis reduciendo su riqueza y su grado de aproximación a la realidad. La motivación del lenguaje multicriterio en economía y finanzas no es otra que la de respetar la coherencia interna de los modelos clásicos al tiempo que se avanza en su coherencia externa para ajustarlos mejor a la realidad económica, tal como apuntan Ballester y Romero (1998). La principal motivación para el uso del lenguaje multicriterio en el ámbito empresarial es la constatación de que cuando hay un decisor preocupado por dos o más criterios, no puede seguir utilizando técnicas de optimización tradicionales, sino que es necesario aplicar nuevas técnicas para tomar las mejores decisiones empresariales.

La infrautilización de las TIC y la investigación operativa en el aprendizaje de la economía dificultará la integración laboral de los

PALABRAS CLAVE

investigación operativa, inteligencia artificial, decisión multicriterio, formación.

KEYWORDS

operations research, artificial intelligence, multicriteria decision-making, training.



profesionales del futuro y, en última instancia, el desarrollo económico de las organizaciones en las que desempeñen su labor profesional. Para reducir este déficit formativo, este trabajo propone la ampliación del lenguaje económico para integrar competencias cuya necesidad será cada vez mayor. Esta ampliación tiene dos propuestas principales:

- Aprender el lenguaje de las máquinas para gestionar el impacto de las TIC y que los agentes económicos puedan así convertirse en agentes verdaderamente inteligentes mediante decisiones basadas en datos.
- Aprender el lenguaje multicriterio para poder manejar la complejidad multidimensional de la economía y permitir un mayor ajuste de los modelos económicos a la realidad.

La combinación del lenguaje de las máquinas y del lenguaje multicriterio representa una contribución adicional de este trabajo. Tanto el lenguaje de las máquinas como el lenguaje multicriterio son herramientas diseñadas para tomar mejores decisiones basadas en datos o considerando más de un criterio. Ambas propuestas son caras de una misma moneda: el uso de métodos que faciliten la resolución de un gran número de problemas en un ámbito empresarial cada día más complejo. El conocimiento por parte de los directivos de estos dos lenguajes puede resultar muy útil como punto de partida para profundizar en las técnicas presentadas.

Junto a esta introducción, en la Sección 2 se introduce el lenguaje de las máquinas como factor crítico en el desarrollo económico y empresarial. En la Sección 3, se añade el lenguaje multicriterio como herramienta para ampliar el rango de aspectos considerados para tomar mejores decisiones. La Sección 4 presenta las principales conclusiones que se pueden extraer de la propuesta descrita en este trabajo.


2. EL LENGUAJE DE LAS MÁQUINAS

¿Se puede decir que los agentes económicos son verdaderamente inteligentes? Algunos experimentos de la economía conductual parecen decirnos que no (Thaler, 2015). Sin embargo, cabe plantearse si podemos dotar a los agentes económicos de herramientas que mejoren sus habilidades para interactuar con un entorno económico complejo y cambiante. Cualquier negativa a mejorar las competencias de un colectivo profesional parece poco justificada.

Una de esas habilidades es el lenguaje de las máquinas. Desde una perspectiva amplia, conocer el lenguaje de las máquinas permite capacitar a los directivos para mejorar el resultado de sus decisiones a través del uso de las TIC. Reduciendo un escalón el grado de abstracción del lenguaje de las máquinas, debemos hablar de la inteligencia artificial que se está convirtiendo cada vez más en una herramienta básica en el proceso de toma de decisiones de los directivos. Es cierto que la inteligencia artificial engloba cierta complejidad, pero también lo es que algunas técnicas de inteligencia artificial como los árboles de decisión son capaces de eliminar la complejidad técnica de manera que los directivos puedan centrarse en lo que realmente importa, es decir, en mejorar la toma de decisiones.

La primera cuestión interesante que surge del binomio que forma el concepto de inteligencia artificial es su antagonismo con respecto a la inteligencia natural. Aunque no sepamos con certidumbre qué es la inteligencia artificial, sí que sabemos lo que no es, es decir, se trata de algo diferente a la inteligencia natural con la que estamos dotados los humanos. Esta primera aproximación inversa al concepto de inteligencia artificial es deliberada e intencional. Al desprover al concepto de toda sofisticación tecnológica se pretende que la inteligencia artificial se convierta en algo mucho más asequible, al alcance de cualquier persona con ganas de aprender. Pensemos por un momento en los semáforos que regulan el paso de vehículos y peatones en cualquier cruce de una ciudad. Un programa (un algoritmo) determina quién debe pasar y quién no debe hacerlo mediante un código de colores y una secuencia temporal. Lo mejor de todo es que lo hace de manera autónoma, es decir, una vez puesta en marcha la secuencia temporal, no es necesaria la intervención humana para su desarrollo. Podría estar ejecutándose de manera indefinida mientras no se produzca un fallo de suministro eléctrico o cualquier otra avería. Esa característica es la clave. De una manera o de otra hemos dotado al sistema de autonomía para tomar decisiones. Probablemente sean decisiones sencillas y repetitivas. Tan sencillas y repetitivas como muchas de nuestras decisiones económicas. Lo interesante, sin embargo, es que nuestra capacidad innovadora es el único límite para desarrollar inteligencias artificiales más complejas que las de un semáforo y que además sean útiles para mejorar las capacidades de los agentes económicos.

Si admitimos que la inteligencia artificial es una técnica, una herra-





menta, un método que permite mejorar nuestra capacidad de decisión económica, preguntémonos ahora de qué tipo de capacidades estamos hablando. La capacidad de una persona es un concepto todavía demasiado abstracto. Aunque su clasificación admite cierta discusión, la ciencia de los datos suele enmarcarse como un subcampo de la inteligencia artificial (Provost y Fawcett, 2013). Una de las tareas donde la ciencia de datos puede servir de gran ayuda para tomar mejores decisiones económicas es la predicción. Sin embargo, la predicción no es solo una estimación de aquello que se espera que pase en el futuro. Y este matiz tiene implicaciones económicas que merece la pena destacar. De manera general, los modelos predictivos tratan de segmentar una población a partir de aquel atributo que nos gustaría conocer con la mayor precisión posible. En esta definición caben las previsiones de series temporales, donde la población es un conjunto de datos históricos y el atributo que se pretende conocer es el siguiente valor de la serie.


Sin embargo, hay una serie de modelos predictivos que pueden resultar no tan cercanos, pero con notables repercusiones económicas. En el mundo empresarial, algunos atributos que nos pueden interesar conocer son, por ejemplo, si un cliente responderá positivamente a una determinada acción comercial, si repetirá su compra antes de tres meses, si pagará según lo acordado, si se retrasará en el pago o si desgraciadamente acabará no pagando. En este caso, la población es un conjunto de clientes cuyo comportamiento se ha observado en el pasado y que están caracterizados por una serie de variables. Por ejemplo, sobre cada uno de los clientes de una compañía de venta de libros por internet podemos conocer aspectos como la edad, el género, el lugar de residencia, las recomendaciones enviadas, el momento en que realizó sus compras en el pasado y qué tipo de libros compró. El atributo que nos interesa predecir es si responderá mediante una compra en la próxima campaña de Navidad a una recomendación personalizada. Para ello podemos utilizar modelos predictivos de clasificación, es decir, aquellos que no buscan predecir una cifra (de ventas, por ejemplo) sino una categoría: sí/no, tipo A, B, C o D. En otras palabras, buscamos clasificar los clientes entre los que sí comprarán y los que no comprarán (Marsland, 2014). Como conocemos el impacto que las recomendaciones tuvieron en el pasado, hablamos de predicción supervisada ya que los datos utilizados contienen el valor del atributo objetivo (compró o no compró) para los clientes en el pasa-

do. Por otro lado, cuando se persigue agrupar a los clientes según una serie de características que permitan realizar recomendaciones personalizadas, hablamos de predicción no supervisada. Una de las técnicas de predicción no supervisada que podría utilizar la empresa de venta de libros por internet del ejemplo anterior sería el *clustering* o análisis de grupos (Likas et al, 2003) para diseñar las recomendaciones personalizadas para los clientes. El objetivo sería ahora dividir un conjunto de clientes en diferentes grupos de tal manera que los miembros de cada grupo (*cluster*) compartan características similares entre sí. En este sentido, la similitud suele establecerse mediante la distancia entre los puntos que representan a los miembros del grupo. Ejemplos de cómo la inteligencia artificial está provocando un cambio sustancial en el mundo empresarial son los de la empresa de servicios legales Juriblox B.V. que utiliza la inteligencia artificial para analizar el texto de acuerdos de confidencialidad, o el de la empresa Anfix que ha desarrollado una herramienta que asigna automáticamente una factura a su cuenta de gasto correspondiente.

Junto con la automatización, una de las principales tareas de la inteligencia artificial es la predicción. Se podría argumentar que hace tiempo que las predicciones forman parte de la ciencia económica. Así es, se llama econometría. Nada hay que objetar a tal argumento, pero la inteligencia artificial ha complementado las técnicas habituales que centran su atención en los parámetros de los modelos de regresión con modelos predictivos más amplios como la clasificación o los sistemas de recomendación. Aunque con un soporte matemático común, el foco se ha trasladado de las propiedades estadísticas formales a la maximización de su utilidad práctica, es decir, a la maximización de la precisión y a la facilidad de obtener respuestas que puedan ponerse en práctica como se demuestra en el siguiente caso de uso.

2.1. Aplicación de la inteligencia artificial en la evaluación del riesgo crediticio

Contrariamente a lo que pueda parecer a primera vista, la evaluación del riesgo crediticio no es una tarea restringida al negocio bancario. Cualquier empresa tiene clientes y cualquier cliente tiene un riesgo de impago que conviene ser evaluado. Para ello, los directivos se enfrentan a la tarea de decidir el nivel de riesgo crediticio que están dispuestos a admitir. Definamos ahora cuál es el problema






empresarial que se pretende resolver. Uno o varios clientes solicitan la concesión o la ampliación de la deuda contraída con la empresa y un directivo de la empresa debe aprobar o rechazar dicha solicitud. Frente a esta situación, el directivo tiene dos vías de acción: 1) tomar una decisión basada en su intuición y experiencia; y 2) tomar una decisión basada en datos mediante la aplicación de técnicas de inteligencia artificial. Si elige la segunda de las opciones, primero tendrá que recabar una serie de datos históricos sobre sus clientes. Estos datos forman el conjunto de atributos que caracterizan a los clientes que han solicitado crédito en el pasado como su historial de pagos, edad, situación laboral, tipo de trabajo, número de personas dependientes a su cargo, la cantidad solicitada, si tiene otros créditos o el propósito de la solicitud. A partir de todos estos datos, el objetivo será decidir si una nueva solicitud debe aceptarse o no, si debe clasificarse como buena o como mala.

Para tomar decisiones basadas en datos, podemos utilizar alguna de las técnicas que la inteligencia artificial nos ofrece como los árboles de decisión (Quinlan, 1986; Rokah y Maimon, 2008). Los árboles de decisión presentan ventajas respecto a otras técnicas por su versatilidad y también porque sus resultados son fáciles de interpretar. Esta técnica realiza una segmentación no lineal de los datos en forma de árbol en el que existe un nodo raíz, unas ramas que parten de ese nodo raíz y que llegan a una serie de nodos interiores y unos nodos terminales tal como se muestra en la **Figura 1**. En cada uno de estos nodos interiores se realiza una evaluación de un atributo de los clientes de manera que cada rama que parte de un nodo recoge todos los casos que presentan un valor distinto del atributo. El proceso de segmentación de datos se repite desde el nodo raíz hasta los nodos terminales de manera que cada cliente sigue un único camino en el árbol y se le asigna una clasificación de crédito (buena o mala) en función de los valores particulares de cada uno de los atributos considerados. Ante una nueva solicitud de crédito, un directivo que tome decisiones basadas en la intuición tendrá en cuenta a lo sumo tres o cuatro características. Por el contrario, un directivo que tome decisiones basadas en datos, podrá considerar cientos de características de una nueva solicitud y la podrá evaluar en cuestión de segundos mediante un algoritmo de segmentación de datos como los árboles de decisión. Por tanto, parece claro que el directivo que toma decisiones basadas en datos a

Figura 1. Un árbol de decisión para la evaluación de crédito
(Fuente: www.bigml.com)



partir de la aplicación de la inteligencia artificial cuenta con mejores herramientas que la intuición.

En el ejemplo de la **Figura 1**, se pretende clasificar a los solicitantes de crédito de una entidad bancaria a partir de un conjunto de atributos que permiten una segmentación multidimensional en forma de árbol de decisión. El primer atributo revisado es su historial crediticio y el último el número de personas dependientes a cargo del solicitante. Ante una nueva solicitud, se utiliza el modelo y las características del nuevo cliente para su evaluación. Por ejemplo, si el historial crediticio no ha sido calificado como crítico, si sus ahorros no son inferiores a 100, si el solicitante no posee propiedades inmobiliarias, si sus ahorros están entre 100 y 500, si el propósito del crédito no es la compra de un coche, si la edad del cliente es inferior a 50 años, si ha tenido trabajo en el último año y el número de personas dependientes a su cargo es superior a uno, el modelo recomienda la concesión del crédito ya que el 80.64% de los solicitantes con estas características resultaron ser créditos buenos. El decisor no solo recibe una recomendación, sino también una relación de los criterios utilizados para elaborar dicha recomendación. Esta es una de las grandes ventajas de los árboles de decisión.

3. EL LENGUAJE MULTICRITERIO

La economía es una ciencia de razonamientos más que de memorización. Sin embargo, hay un razonamiento básico que parece no haber calado entre los economistas y directivos actuales. Este razonamiento está basado en el hecho de que en la mayoría de las situaciones económicas las decisiones se toman teniendo en cuenta no uno sino varios criterios. El consumidor no solo busca el mejor precio, sino que también analiza la calidad de los productos que compra. Busca un balance, un compromiso entre el precio y la calidad. El análisis se puede hacer extensivo a las empresas que no solo pretenden maximizar los beneficios, sino también maximizar el crecimiento o minimizar los riesgos o el impacto ambiental de sus actividades. Si las decisiones se suelen tomar barajando varios criterios, parece claro que la economía debería haber desarrollado métodos para tomar las mejores decisiones dentro de un contexto multicriterio.

La idea básica de la teoría de la decisión multicriterio es la evaluación de las alternativas disponibles desde diversos puntos de vista, es decir, con distintos criterios. Sus raíces se hunden en el tiempo hasta la época de Benjamin Franklin (1706-1790) que tomaba sus decisiones más importantes cogiendo una hoja de papel y escribiendo todos los argumentos a favor en una cara del papel y todos los argumentos en contra en la otra cara. La cara del papel que presentaba más argumentos establecía el signo de la decisión. De manera más formal, Caballero y Romero (2006) definen el paradigma multicriterio como el conjunto de métodos matemáticos y técnicas de computación que tienen como propósito explicativo, normativo o prescriptivo evaluar un número finito y explícito (caso discreto) o infinito (caso continuo) de alternativas en base a un número finito de criterios.


La teoría de la decisión multicriterio está basada en un concepto económico: el principio de eficiencia de Pareto. Este principio indica que una sociedad está en estado óptimo si ninguna persona puede mejorar su situación sin empeorar la situación de otro. Si sustituimos el término persona por el de criterio estaremos ante el escenario habitual cuando buscamos soluciones a un problema multicriterio. Cuando esta búsqueda se hace mediante el cálculo de distancias a un punto ideal estaremos utilizando la programación compromiso (Zeleny, 1982). Cuando la búsqueda de las mejores soluciones se realiza calculando las desviaciones respecto



a unos niveles de aspiración marcados por el decisor utilizaremos la programación por metas (Jones y Tamiz, 2010). Otras técnicas multicriterio diseñadas para resolver problemas con alternativas discretas mediante rankings son PROMETHEE (Brans y Mareschal, 2005) ELECTRE (Figueira et al., 2013) y el proceso analítico jerárquico (Saaty, 1980). El ámbito de aplicación de la teoría de la decisión multicriterio abarca ámbitos tan variados como la selección de inversiones, problemas de localización de plantas, problemas de mezclas en la industria textil, química o agroalimentaria, problemas de minimización de impacto ambiental, publicidad y marketing, selección de proveedores (Steuer, 1986). Un ejemplo de caso de éxito en el ámbito sanitario es la propuesta por parte de la consultora Omakase de un marco de valoración multicriterio de fármacos huérfanos sobre los que la industria farmacéutica tiene poco interés por el reducido tamaño del mercado (Badia et al., 2019). La evaluación de la sostenibilidad de plantaciones de eucaliptos en el noroeste de España mediante múltiples indicadores es otro ejemplo de cómo el lenguaje multicriterio enriquece la toma de decisiones (Díaz-Balteiro et al., 2016).

La presencia de al menos dos criterios suele llevar aparejado el conflicto entre la consecución de unos y otros. El consumidor interesado en el menor precio y la mayor calidad se enfrenta al problema de aceptar una peor calidad para reducir el precio o, inversamente, a tener que aceptar un mayor precio para aumentar la calidad del producto que le interesa. El inversor que pretende aumentar la rentabilidad esperada tendrá que hacer frente a un mayor riesgo mientras que si persigue reducir el riesgo no tendrá más remedio que aceptar una menor rentabilidad. Se establece pues una relación de intercambio entre parejas de criterios definida como la cantidad que hay que sacrificar de un criterio para conseguir un aumento de una unidad de otro criterio. Ante esta situación de conflicto entre criterios, el decisor se enfrenta al problema de buscar una solución compromiso, una solución más o menos equilibrada que le satisfaga de acuerdo con sus preferencias personales por cada uno de los criterios que considera importantes.

Como la optimización simultánea de múltiples objetivos habitualmente no es posible, el decisor ha de buscar un conjunto de soluciones que representen un compromiso entre los distintos objetivos. Para ello, con frecuencia se recurre a evaluar las alternativas en un espacio normalizado que permita realizar comparaciones entre






criterios que, con frecuencia, presentan unidades y escalas diferentes. Dentro de este espacio multidimensional, existe un punto singular que produce el mayor grado de consecución para los criterios considerados de manera independiente. Por este motivo, recibe el nombre de punto ideal ya que normalmente no es factible. Sin embargo, es la mejor referencia para evaluar las soluciones alternativas. Un método lógico para llevar a cabo dicha evaluación es seguir el axioma de selección de Zeleny (1982): “las soluciones que están más cerca del punto ideal son mejores que aquellas que están lejos”. En esta regla de selección, cerca o lejos son expresiones de distancia que tienen un sólido soporte matemático. Aunque hay muchos tipos de distancia (Euclidiana, Manhattan, Chebyshev, Mahalanobis, Hausdorff), las utilizadas en este trabajo por su sencillez son la distancia Euclidiana calculada como la longitud de la recta que une dos puntos en el espacio y la distancia Manhattan que es la suma de la separación horizontal y vertical entre dos puntos. Sin embargo, una variación en las preferencias del decisor hacia cualquiera de los criterios puede hacer que la mejor solución varíe. Para incluir las preferencias del decisor por alguno de los criterios considerados, podemos utilizar funciones ponderadas de distancia donde los criterios tendrán un peso diferente al resto.

3.1. Un caso práctico en la industria textil

Un problema de decisión multicriterio trata de optimizar simultáneamente un conjunto finito de funciones objetivo bajo un conjunto de restricciones. En un contexto económico, este conjunto de funciones objetivo recoge la expresión del valor económico múltiple que las diferentes alternativas tienen para el decisor. Pensemos, por ejemplo, en el concepto de valor compartido propuesto por Porter y Kramer (2011). En una nueva visión del capitalismo, Porter y Kramer proponen que cualquier tipo de organización debe cambiar su tradicional visión de maximización del beneficio por una perspectiva más amplia en la que se considera tan importante la dimensión puramente económica como la mejora de las condiciones económicas y sociales de las comunidades donde desarrolla sus actividades. Bajo esta nueva visión, una empresa ha de pasar de una estrategia tradicional donde se considera un único criterio (económico) a una estrategia de valor compartido donde se busca optimizar dos o más criterios (económicos, sociales, ambientales...). Algunos ejemplos de estos criterios pueden ser la minimización del coste, de las

emisiones a la atmósfera, de la desigualdad salarial entre hombres y mujeres, o la maximización de ventas, de la satisfacción de empleados y clientes o del uso de energías renovables. La tesis de Porter y Kramer es que esta nueva perspectiva permitirá resolver muchos de los problemas del capitalismo al tiempo que facilitará la innovación y el crecimiento económico a largo plazo. Uno de esos problemas es el consumo de recursos naturales.

La demanda global de productos textiles no ha parado de crecer en las últimas décadas pasando de los 4 kg por persona y año en 1950 hasta los 13 kg en la actualidad (Carrera, 2017). Esta demanda lleva aparejado un gran consumo de recursos. Por ejemplo, la gran cantidad de agua necesaria para cultivar el algodón convencional ha provocado la desecación del Mar de Aral (Chapagain et al, 2006). Frente a esta situación, las grandes cadenas de distribución textil tanto de moda como de textil hogar deben plantearse una reorientación de su oferta de productos por medio del lenguaje multicriterio. Por un lado, deben mantener su objetivo de maximización de beneficios a largo plazo. Por otro, deben considerar la reducción del impacto ambiental de sus actividades como un objetivo adicional. No hay duda respecto a la medida de los beneficios por las empresas, pero la medida del impacto ambiental de las actividades de producción textil ofrece mayores dificultades. Una forma de resolver este problema es utilizar el índice Higg (Sustainable Apparel Coalition, 2019). Este índice permite analizar el impacto ambiental de los materiales utilizados en la fabricación de productos textiles, comparar sus productos con el resto de la industria y tomar mejores decisiones sobre el uso de materiales sostenibles. El índice de Higg incluye aspectos como el consumo de agua, de combustibles fósiles, la eutrofización, las emisiones a la atmósfera o el uso de productos químicos. Dado que el algodón es la fibra natural más consumida y también una de las de mayor impacto ambiental (Chapagain et al, 2006), parece razonable centrar el análisis en las variantes convencional y reciclada de esta fibra textil. Si comparamos el impacto ambiental de estas dos opciones, veremos que el índice Higg para el algodón convencional es 98 mientras que para el algodón reciclado es solo de 39 (una cifra más alta indica un mayor impacto en términos comparativos). Por otro lado, si la obtención de los materiales reciclados requiere de un proceso adicional de recogida, limpieza y transformación, es posible que esto suponga un sobrecoste de los productos reciclados. Con fines ilustrativos, consideremos que una



empresa textil se plantea la sustitución del algodón convencional que utiliza para la fabricación de manteles por algodón reciclado y que los costes e impactos respectivos por unidad de producción tal como se muestra en la **Tabla 1**.

Tabla 1. Coste estimado e índice de Higg para textiles convencionales y reciclados		
	COSTE (€)	ÍNDICE HIGG
Convencional	48	98
Reciclado	90	39

La empresa textil de nuestro caso práctico está interesada en conocer cuál es el mix de producción óptimo desde un punto de vista multicriterio, es decir, teniendo en cuenta tanto el coste de producción como el impacto ambiental medido según el índice Higg. Para ello, se plantea todas las combinaciones de porcentaje de producción que se recogen en la **Tabla 2**. Posteriormente calcula tanto el coste (C) como el impacto ambiental (H) derivado de la aplicación de cada mix de producción alternativo. El resultado son dos evaluaciones distintas para cada alternativa factible sin que la selección de la mejor solución sea evidente. Para seleccionar una de las alternativas, un método lógico es calcular la distancia al punto ideal donde tanto el coste como el impacto son nulos. Está claro que este punto es habitualmente inviable, pero representa una referencia clara para la selección de las mejores alternativas. La penúltima columna presenta la distancia euclidiana al origen de coordenadas en el espacio C-H (Coste-Índice Higg). De la observación de esta columna, apreciamos como la alternativa más próxima al punto ideal es el mix 30% convencional - 70% reciclado. Este mix de producción es la solución óptima bajo un prisma multicriterio. También es posible utilizar otros tipos de distancias como la Manhattan que suma las dos componentes dimensionales C y H. Si se observa la Tabla 2, se verá que el uso de la distancia Manhattan recomienda otro mix de producción como el óptimo. Recomienda una opción extrema. Es conocido que la distancia Manhattan tiende a recomendar soluciones más alejadas del compromiso entre los criterios considerados.

Tabla 2. Cálculo del mix de producción que minimiza coste e impacto ambiental.

PRODUCCIÓN CONVENCIONAL (%)	PRODUCCIÓN RECICLADA (%)	COSTE (C)	IMPACTO (H)	DISTANCIA EUCLIDIANA $\sqrt{(C^2+H^2)}$	DISTANCIA MANHATTAN C+H
0,0	1,0	90,0	39,0	98,09	129,00
0,1	0,9	85,8	44,9	96,84	130,70
0,2	0,8	81,6	50,8	96,12	132,40
0,3	0,7	77,4	56,7	95,95	134,10
0,4	0,6	73,2	62,6	96,32	135,80
0,5	0,5	69,0	68,5	97,23	137,50
0,6	0,4	64,8	74,4	98,66	139,20
0,7	0,3	60,6	80,3	100,60	140,90
0,8	0,2	56,4	86,2	103,01	142,60
0,9	0,1	52,2	92,1	105,86	144,30
1,0	0,0	48,0	98,0	109,12	146,00

La gran ventaja de la aplicación de las técnicas multicriterio a problemas económicos y empresariales es que permite enriquecer el proceso con aspectos que normalmente quedan relegados a un segundo plano cuando las decisiones se toman en función de un único criterio. El análisis multicriterio permite analizar cuáles son las repercusiones relativas entre dos o más criterios. ¿Qué incremento de coste he de aceptar por reducir el impacto ambiental de mi producción? ¿Qué incremento de riesgo se produce al aumentar en una unidad la rentabilidad exigida a mi inversión? Este tipo de cuestiones encuentran respuesta en el lenguaje multicriterio. Por el contrario, la presencia de múltiples criterios obliga al decisor a definir cuáles son sus preferencias por cada uno de ellos. Este ejercicio subjetivo puede resultar sencillo cuando se consideran dos o tres criterios, pero se complica cuando se utilizan múltiples criterios. Sin embargo, técnicas como el Proceso Analítico Jerárquico propuesto por Saaty (1980) permiten resolver esta cuestión de forma lógica y consistente.

En este punto, cabe preguntarse por qué motivo la teoría de la decisión multicriterio es importante para los directivos. La respuesta ya se ha dado con anterioridad, pero conviene repetirla ahora. El enfoque tradicional del análisis económico se ha centrado en la optimización de un único criterio cuando la realidad económica nos propone un gran número de problemas en los que la presencia de

diferentes criterios de decisión es irrenunciable. De esta manera, si se pretende avanzar en la mejora de los modelos de decisión de manera que represente con la mayor fidelidad posible la realidad económica, la teoría de la decisión multicriterio es una herramienta poderosa para el análisis económico. No se trata de sustituir el enfoque monocriterio tradicional, sino de dotar a los directivos de una herramienta adicional que se ajuste mejor al comportamiento decisonal de los agentes económicos reales. En definitiva, se trata de una mejora tecnológica, de una innovación que permite aumentar el nivel de sus competencias profesionales.

4. CONCLUSIONES

Un lenguaje es un sistema más o menos complejo de signos y expresiones que permite la comunicación, pero lo más importante es que aumenta la capacidad de aquel que lo domina de interactuar con el entorno que lo rodea.

4.1. Implicaciones para la gestión

En la actualidad, el lenguaje de las máquinas ha cambiado la forma en la que nos relacionamos con otras personas, pero también con los agentes económicos. El acceso a la información se ha multiplicado y la necesidad de tomar decisiones basadas en datos justifica la necesidad de ampliar el rango de competencias de los directivos. Es conveniente, sin embargo, realizar una advertencia. Los directivos no han de convertirse en expertos informáticos sino hibridar sus conocimientos económicos con aquellos que proceden de ámbito de las TIC. Las empresas generan una gran cantidad de datos de manera continuada. Una buena forma de aprender el lenguaje de las máquinas es extraer el conocimiento de esos datos mediante la inteligencia artificial.


La economía es una ciencia compleja pero no inabarcable. Tradicionalmente, el enfoque monocriterio ha sido el esquema dominante pero la realidad económica nos muestra que los agentes económicos son entidades multidimensionales. Toman sus decisiones tratando de optimizar diferentes objetivos. El lenguaje multicriterio permite integrar todas estas dimensiones en un sistema lógico de manera que las decisiones se ajusten con mayor precisión a la compleja realidad que los rodea. Los métodos de decisión multicri-



terio se convierten en una herramienta poderosa para completar las competencias económicas de los directivos.

4.2. Limitaciones y futuras líneas de investigación

El alcance de este trabajo se limita a demostrar desde un punto de vista teórico la utilidad del lenguaje de las máquinas y del lenguaje multicriterio para facilitar la resolución de problemas de un entorno empresarial y económico cada día más complejo. La descripción de conceptos clave en ambos campos y las referencias ofrecidos no pretenden ser un análisis exhaustivo sino una introducción que puede resultar de utilidad a los directivos. De su capacidad de aprendizaje a estos nuevos lenguajes dependerá su habilidad para adaptarse a la nueva economía. Se aportan casos prácticos que sirven como punto de partida para identificar las necesidades formativas de los directivos de las empresas. En este sentido, una interesante futura línea de investigación puede ser la propuesta de metodologías formativas específicas enfocadas a la implementación de estos lenguajes en el ámbito empresarial.



REFERENCIAS

Acemoglu, D., & Restrepo, P. (2018). Artificial Intelligence, Automation and Work (No. w24196). National Bureau of Economic Research.

Badia, X., Chugani, D., Abad, M. R., Arias, P., Guillén-Navarro, E., Jarque, I., Posada, M., Vitoria, I. & Poveda, J. L. (2019). Development and validation of an MCDA framework for evaluation and decision-making of orphan drugs in Spain. *Expert Opinion on Orphan Drugs*, 7(7-8), 363-372.

Ballestero, E., & Romero, C. (1998). Multiple criteria decision making and its applications to economic problems. Kluwer. Dordrecht.

Brans, J. P., & Mareschal, B. (2005). PROMETHEE methods. In *Multiple criteria decision analysis: state of the art surveys* (pp. 163-186). Springer, New York, NY.

Caballero, R., & Romero, C. (2006). Teoría de la decisión multicriterio: un ejemplo de revolución científica Kuhniana. *Boletín de Estadística e Investigación Operativa. BEIO*, 22(4), 9-15.

Carrera Gallissà, E. (2017). Los retos sostenibilistas del sector textil. *Revista de Química e Industria Textil*, (220), 20-32.

Chapagain, A. K., Hoekstra, A. Y., Savenije, H. H., & Gautam, R. (2006). The water footprint of cotton consumption: An assessment of the impact of worldwide consumption of cotton products on the water resources in the cotton producing countries. *Ecological Economics*, 60(1), 186-203.

Díaz-Balteiro, L., Alfranca, O., González-Pachón, J., & Romero, C. (2016). Ranking of industrial forest plantations in terms of sustainability: a multicriteria approach. *Journal of Environmental Management*, 180, 123-132.

Dirican, C. (2015). The impacts of robotics, artificial intelligence on business and economics. *Procedia-Social and Behavioral Sciences*, 195, 564-573.

Figueira, J. R., Greco, S., Roy, B., & Słowiński, R. (2013). An overview of ELECTRE methods and their recent extensions. *Journal of Multi-Criteria Decision Analysis*, 20(1-2), 61-85.

Hidalgo, M. A. (2018). El empleo del futuro: Un análisis del impacto de las nuevas tecnologías en el mercado laboral. Deusto. Barcelona.

Jones, D., & Tamiz, M. (2010). *Practical goal programming* (Vol. 141). New York: Springer.

Likas, A., Vlassis, N., & Verbeek, J. J. (2003). The global k-means clustering algorithm. *Pattern recognition*, 36(2), 451-461.

Marsland, S. (2014). *Machine learning: an algorithmic perspective*. Chapman and Hall/ CRC, Londres.

Porter, M. E., & Kramer, M. R. (2011). The big idea: Creating shared value. *Harvard Business Review*, 89 (1-2).

Provost, F., & Fawcett, T. (2013). *Data Science for Business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media.

Rokach, L., & Maimon, O. Z. (2008). *Data mining with decision trees: theory and applications* (Vol. 69). World scientific.

Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1), 81-106.

Saaty T.L., (1980). *The Analytic Hierarchy Process*. McGraw Hill, New York.

Salas-Molina, F., Martín, F. J., Rodríguez-Aguilar, J. A., Serra, J., & Arcos, J. L. (2017). Empowering cash managers to achieve cost savings by improving predictive accuracy. *International Journal of Forecasting*, 33(2), 403-415.

Samuelson, P. A. (1952). Economic Theory and Mathematics--An Appraisal. *The American Economic Review*, 42(2), 56-66.

- Steuer, R. E. (1986). *Multiple criteria optimization: theory, computation, and application* (Vol. 233). New York: Wiley.
- Sustainable Apparel Coalition (2019). Materials sustainability index. <https://msi.higg.org/>
- Thaler, R. H. (2015). *Misbehaving: The making of behavioral economics*. Norton. New York.
- Zeleny, M., (1982). *Multiple criteria decision making*. McGraw-Hill, New York.

