



Ass. Prof. Dr. Oksana Urikova

is an associate professor at the Department of Finance, Lviv Polytechnic National University. She graduated from the university in 2004 with a specialization in finance and received a Ph.D. in economics in 2013. Her professional career at the university began in 2005, when she started working as an assistant at the Department of Finance. Since then, she has been actively involved in the field of finance and financial education. Her main research focuses on the study and investigation of financial processes and issues related to financial management.

ist Privatdozentin an der Fakultät für Finanzen der Nationalen Polytechnischen Universität Lwiw. Sie schloss ihr Studium 2004 mit dem Schwerpunkt Finanzen ab und promovierte 2013 in Wirtschaftswissenschaften. Ihre Karriere an der Universität begann 2005 als Assistentin an der Fakultät für Finanzen. Seitdem ist sie in den Bereichen Finanzwissenschaft und Finanzbildung tätig. Ihre Forschung konzentriert sich auf die Untersuchung von Finanzprozessen und Fragen des Finanzmanagements.

Contact/Kontakt: oksana.m.urikova@lpnu.ua



Prof. Dr. rer. pol. Teresa Dierkes

Teresa Dierkes studied business administration at the University of Paderborn and received her doctorate from the Brandenburg University of Technology in Cottbus. She gained professional experience in sales at a large capital goods manufacturer in Lünen and in the credit business at the Investitionsbank des Landes Brandenburg. Since 2007, she has been a full-time lecturer in business administration with a focus on marketing at the Berufsakademie Sachsen (University of Cooperative Education) in Dresden.

Teresa Dierkes studierte Betriebswirtschaftslehre an der Universität Paderborn und promovierte an der Brandenburgischen Technischen Universität Cottbus. Berufliche Erfahrungen sammelte sie im Vertrieb eines großen Investitionsgüterherstellers in Lünen und im Kreditgeschäft der Investitionsbank des Landes Brandenburg. Seit 2007 ist sie hauptamtliche Dozentin für Betriebswirtschaftslehre mit Schwerpunkt Marketing an der Berufsakademie Sachsen am Standort Dresden.

Contact/Kontakt: Teresa.Dierkes@ba-sachsen.de



Ass. Prof. Dr. Halyna Beshley

received the Ph.D. degree in Telecommunication Systems and Networks from Lviv Polytechnic National University in 2021. She is currently an associate professor at the Department of Telecommunications, Lviv Polytechnic National University. Her research interests include 5G, cloud computing, SDN, M2M and IoT.

promovierte 2021 im Bereich Telekommunikationssysteme und -netze an der Nationalen Polytechnischen Universität Lwiw. Derzeit arbeitet sie als Privatdozentin an der Fakultät für Telekommunikation der Nationalen Polytechnischen Universität Lwiw. Ihre Forschungsinteressen umfassen 5G, Cloud Computing, SDN, M2M und das Internet der Dinge (IoT).

Contact/Kontakt: halyna.v.beshlei@lpnu.ua

Modeling Economic Processes in the Era of Digitalization

Oksana Urikova/Teresa Dierkes/Halyna Beshley

Abstract

The digital revolution, driven by rapid advances in digital technology, big data analytics, artificial intelligence, and the Internet of Things, is fundamentally changing the way we monitor, analyze, and predict economic trends. It is not only improving data collection, but also equipping us with tools for practical insights that enrich our understanding of economic dynamics. This article explores the role of economic process modeling in the digital age. We will look at how digital technologies affect economic dynamics, what modern methods and tools are used to analyze economic phenomena, and how models can help solve complex problems in the digital revolution.

A number of important concepts and terms related to the digital economy are also explored, as well as the changes taking place in the field of modeling economic processes in the context of digital transformation. This article provides an example of creating a predictive model of corporate defaults and describes how digital technologies affect the process of modeling economic phenomena.

Keywords: Digital economic, digital technologies, big data analysis, artificial intelligence, economic phenomena, observe, analyze, forecast.

1. Introduction

In today's world, which is characterized by the rapid development of technology, the economy is undergoing an extremely important period of transformation. The age of digitalization is bringing about significant changes in the way businesses operate, government agencies function, and people interact. In this context, modeling economic processes is proving to be a key tool for understanding and anticipating developments in this new digital world.

The digital revolution, driven by the rapid growth of digital technologies, big data analytics, artificial intelligence, and the Internet of Things, is leading to radical changes in the way we observe, analyze, and predict economic phenomena. This revolution not only enhances our ability to collect large amounts of data, but also provides us with the tools to draw practical conclusions from that data, contributing to a deeper understanding of economic dynamics. Overall, digitalization brings new opportunities and challenges to the modern economy. It allows us to manage resources more efficiently, improve business processes, and respond to change in real time. However, along with these opportunities, it also threatens traditional business models and requires new approaches to managing and analyzing economic phenomena. This article explores the role of economic process modeling in the digital age. We will look at how digital technologies affect economic dynamics, what modern methods and tools are used to analyze economic phenomena, and how models can help solve complex problems in the digital revolution (see Figure 1).

based on the Internet and mobile devices. The economic sectors based on information and communication technologies are called "digital economy". This paper suggests that the digital economy has three main areas of activity. The first is the "digital sector", which includes the information technology (IT/ICT) industry and the production of basic digital goods and services. A true "digital economy", as defined in this paper (Figure 1), exists when a significant part of economic production is based on digital technologies and has a business model based on digital goods and services. This area consists of the "digital sector" and new digital and platform services. The broadest use of information and communication technologies (ICT) across all sectors of the economy is called the "digital economy" [1].

2. Digital Innovations in Economic Process Modeling

Today, the development of informatization is primarily associated with the introduction of digital communication technologies and platforms

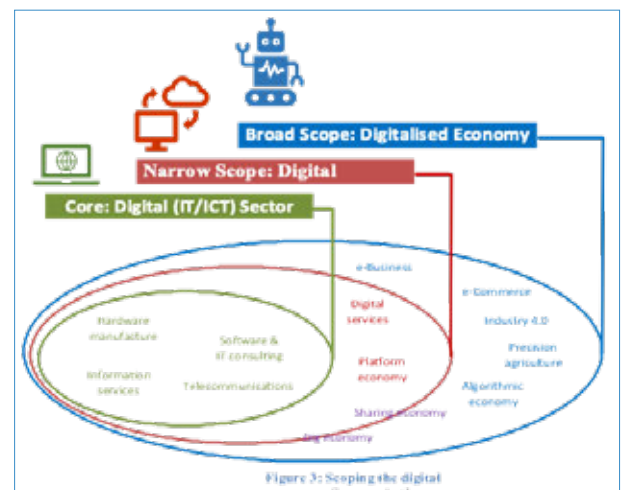


Fig.1. Defining the scope of the digital economy

Economic process modeling is critical to understanding and exploiting the digital economy. First and foremost, economic process modeling is an analytical and mathematical approach to studying and understanding the functioning of economic systems, processes, and phenomena. This approach uses various mathematical and statistical methods, computer technology, and economic theory to create models that can reflect real-world aspects of the economy.

Digitalization is having a significant impact on the modeling of economic processes, transforming this approach and expanding the possibilities for analyzing economic phenomena. Here are some ways in which this is happening:

- **Access to vast amounts of data:** Digital technologies make it possible to collect and store vast amounts of data from multiple sources, including social media, e-commerce, IoT sensors, and more. This provides economists with more data to build models and conduct analysis.
- **Big Data Analysis:** Digitalization promotes the development of big data analysis, which allows processing and analyzing large amounts of information in real time. This approach allows economists to obtain more detailed and accurate modeling results.
- **Artificial Intelligence (AI):** Artificial intelligence techniques such as machine learning enable the creation of predictive models that can adapt to new data and identify complex relationships that may be missed by traditional models.

- **Analysis and Forecasting:** Digital technologies enable real-time analysis and forecasting of economic events. This is useful for monitoring markets, financial stability and making quick decisions.
- **Personalized models:** With access to a wealth of consumer data, it is possible to create personalized economic models that take into account individual customer characteristics and behaviors.
- **Automation and Process Optimization:** Digital technologies allow for the automation of many aspects of economic modeling, making it easier to develop and update models.
- **Expand the geographic scope of research:** Digital technologies allow economists to collaborate and share data with colleagues around the world, expanding opportunities for comparative analysis.
- **The main concept explaining the principles of creating a digital economy ecosystem is shown in the figure.**

The digital economy ecosystem (Figure 2) is a set of interconnected industries, companies, technologies, data, and infrastructure that together create an economic ecosystem product or digital ecosystem product. This ecosystem is based on the use of digital technologies and aims to ensure competitiveness and sustainability in the modern digital environment.

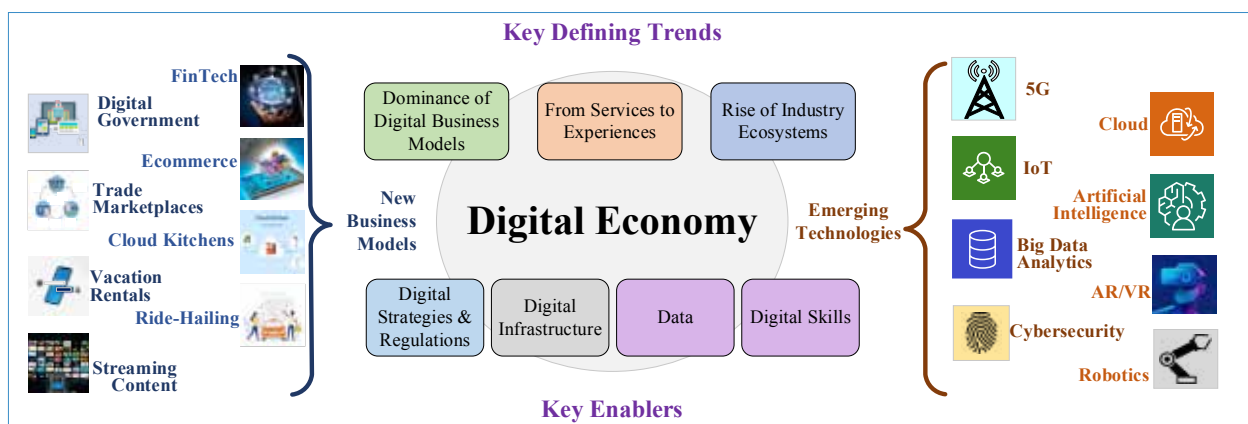


Fig.2. Digital economy ecosystem

All the changes associated with global digitization create new opportunities for modeling economic processes, making them more accurate, adaptive, and useful for solving complex problems in the modern economy [2].

3. Modeling Economic Processes and Forecasting Corporate Defaults

Modeling economic processes and forecasting corporate default rates are important tasks in the global context of the modern economy. Defaults are known to have a significant impact on financial stability, lending costs, the investment climate, and the overall economic condition

of a country. Therefore, the ability to effectively predict and manage corporate default risks is important for many industries, including the banking sector, the investment sector, and corporations themselves [3]. The rapidly evolving digital transformation in today's world has brought with it significant changes in economic modeling and default forecasting. The use of digital technologies, big data, and artificial intelligence tools can significantly improve the accuracy of forecasts, adapt models to rapid market changes, and improve the overall reliability of the forecasting process.

In this example, we illustrate the process of creating a predictive model for corporate defaults.

Risk parameters are dynamic and it is important to understand how they change over time, which is a key aspect of risk management. In the first case study, we use historical credit migration data to build various time series and visualize the dynamics of default rates. In the next case study, we use some of the time series created in the first case study as well as additional data to develop a predictive model of corporate defaults. In addition, we introduce the basic concepts related to backtesting. Although we present a linear regression model of corporate defaults, the tools and principles discussed can be applied to various forecasting methods.

In this part of our paper, we analyze historical data on transition probabilities for corporate issuers, represented by the variable TransMat. These data cover the years 1981 to 2005 and were obtained from [10]. They contain information on the number of issuers at the beginning of each year for each rating (variable nIssuers) and the number of new issuers that appeared for the first time on each rating during the year (variable nNewIssuers). We also use data on corporate earnings forecasts from [9] and data on corporate spreads from [4] (variables CPF and SPR). In addition, we include a variable that indicates the years of recession (Recession) and corresponds to the recession periods defined in [7]. This variable is mainly used for data visualization. We begin by conducting aggregations to obtain the corporate default rates for issuers categorized as Investment Grade (IG) and Speculative Grade (SG), as well as the overall corporate default rate. Investment-grade and speculative-grade issuers are two different categories of companies or corporate issuers that have different credit ratings or credit quality. These ratings determine how reliable the issuer's ability to repay its debts and meet its financial obligations to investors is considered to be.

Investment grade issuers:

- These are companies that have a high credit rating, called an "investment grade" rating.
- An investment grade rating means that these companies are considered high risk to investors and their debts are considered reliable.
- These companies have the ability to repay their debts and generate profits with a low risk of default.

Speculative grade issuers:

- These are companies with a lower credit rating that is considered "speculative".
- A speculative rating means that these companies have a higher risk of default and lower credit quality than investment-grade companies.
- These companies may be less stable financially and have limited ability to repay their debts.

Here is a graphical representation illustrating the trends in Investment Grade (IG), Speculative Grade (SG), and overall corporate de-

fault rates. A logarithmic scale is utilized to accentuate the patterns rather than the absolute values. The shaded regions indicate years of economic recession. Recession years are periods of economic downturn or decline in economic activity, which can be measured by a drop in GDP (Gross Domestic Product) and other economic indicators (refer to Fig. 3).

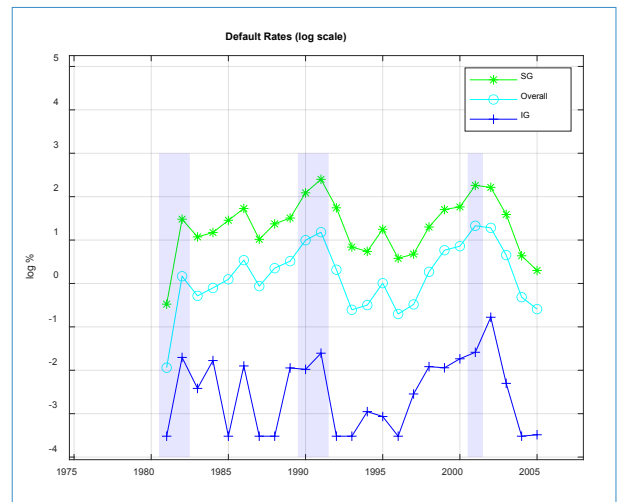


Fig.3. Dynamics of IG, SG, and overall corporate default rates

Notably, the patterns of SG and IG default rates exhibit slight variations. For instance, the IG default rate is higher in 1994 compared to 1995, while SG displays the opposite trend. Moreover, the peak for IG default rates occurred in 2002, post the 2001 recession, whereas SG experienced its peak in 2001. This observation implies that models for predicting the dynamics of IG and SG default rates may have significant distinctions, which is a common scenario when dealing with different market segments. The overall corporate default rate, being a composite of the two, exhibits a pattern more aligned with SG, likely due to the relative proportion of SG versus IG issuers in the dataset. The default rates we have calculated fall into different categories: point-in-time (PIT) rates, through-the-cycle (TTC) rates, and average rates during recession or expansion periods. PIT rates rely solely on the most recent data for estimation. In contrast, TTC rates consider all migrations observed over the dataset's 25-year period for estimation. Additionally, we are interested in average default rates during economic recessions or expansions (refer to Fig. 4).

Calculating these rates is straightforward using our available data and tools. For instance, to estimate the average transition probabilities during recession years, we can filter the data using logical indexing based on the 'Recession' variable. Then, we can pass the corresponding 'totals' structures to the 'transprobytotals' function, which aggregates the data over time and provides us with the relevant transition matrix.

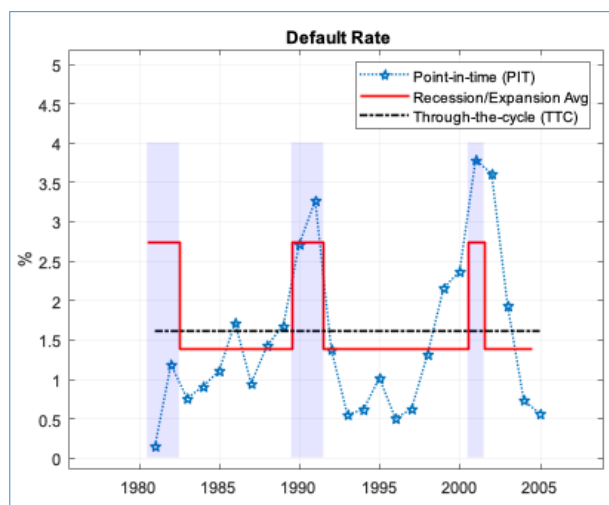


Fig. 4 Estimated PIT rates, TTC rates, and recession and expansion rates.

In some analyses, simulations are employed where the default rate is dependent on the overall economic condition, such as recession or expansion. Estimates of default rates during recession and expansion periods can be valuable in such a framework. It's important to note that these estimates are historical averages and may not be suitable for predicting the actual default rates expected in any specific year.

In the second part of this example, we will reevaluate the use of these historical averages as forecasting tools by conducting a backtesting exercise. This exercise will help us assess how well these historical averages perform when used for prediction purposes.

Using the credit data, we can create new time series that are of interest. One such series is an age proxy, which serves as a predictor in the forecasting model discussed in the second part of this example. Age is a known and significant factor in predicting default rates, as demonstrated in [1] and [5]. In this context, age refers to the number of years since a bond was issued. It's important to note that the age of a portfolio is determined by calculating the average age of its bonds. Historical data has shown certain patterns: many lower-quality borrowers tend to default shortly after issuing a bond. Troubled companies, when issuing bonds, often use the borrowed funds to make payments for the first year or two. Beyond that period, their primary source of funds becomes their cash flows, and if these are insufficient, defaults may occur.

Calculating the precise age of the portfolio is challenging due to the absence of issuer-level information in the dataset. However, following the methodology proposed in [6], we use an age proxy. This proxy is calculated as the number of new issuers in year "t-3" divided by the total number of issuers at the end of year "t." It's worth mentioning that this age proxy calculation began in 1984. For the nume-

erator (the number of new issuers), we have explicit data available. Regarding the denominator (the number of issuers at year-end), it's equal to the number of issuers at the beginning of the following year, which is known for all years except the last one. For the final year, it's computed as the sum of total transitions into a non-default rating plus the number of new issuers in that year.

In our analysis, we employ the following linear regression model to predict corporate default rates:

$$\text{Default Rate} = \beta_0 + \beta_1 * \text{AGE} + \beta_2 * \text{CPF} + \beta_3 * \text{SPR} \quad (1)$$

Here's what each variable represents:

AGE: The age proxy, as defined earlier.

CPF: Corporate profits forecast, which provides insights into the economic context.

SPR: Corporate spread over treasuries, serving as a proxy for credit quality.

It's important to note that this model is consistent with the one outlined in [6], albeit with a distinction that the model in [6] is specifically tailored for Investment Grade (IG) issuers.

As previously emphasized, age, economic conditions (captured by corporate profits forecast), and credit quality (reflected by corporate spread) are three fundamental dimensions often considered in credit analysis models.

The regression coefficients in the model exhibit the anticipated directional relationships: default rates tend to rise with a larger proportion of 3-year issuers, decline when corporate profits are robust, and increase in the presence of elevated corporate yields. Furthermore, the adjusted R-squared value indicates a strong fit for the model.

To visualize the in-sample fit, which measures how closely the model predictions align with the data points used for model fitting is depicted in Fig.5.

There is no substantial statistical evidence to suggest a violation of the linear regression assumptions. It's evident that default rates do not follow a normal distribution. However, the model doesn't assume normality in the distribution of default rates itself. The only normality assumption within the model is that, given the predictor values, the errors between the predicted and observed default rates are normally distributed. When examining the in-sample fit, this assumption doesn't appear unreasonable. The error magnitudes don't seem to depend on whether default rates are high or low. For instance, the year 2001 has a high default rate and a large error, but the years 1991 or 2002 also have high rates with very small errors. Similarly, years with low default rates like 1996 and 1997 exhibit significant errors, while the years 2004 or 2005, with similarly low rates, have tiny errors (refer to Fig. 5).




Fig.5. Forecasting Corporate Defaults

A comprehensive statistical analysis of the model is beyond the scope of this discussion, but you can find detailed examples in Statistics and Machine Learning Toolbox™ and Econometrics Toolbox™.

4. Business Simulations Game and the Digital Economy: Interconnection and Prospects

In today's world, where digital transformation plays an important role in the development of business and the global economy, business simulations are becoming not only an important learning tool but also a tool for analysis and forecasting in the digital economy. This article explores the relationship between business simulations and the digital economy and considers the prospects for their joint development.

The digital economy is characterized by the rapid development of technology, the growing amount of data, and the emergence of new business models. In this environment, business simulations become an ideal tool for analyzing and modeling the impact of digital innovations on business processes. They allow participants to feel like company executives and make strategic decisions in a digital environment. These simulations are widely used in educational institutions, corporate training, and development programs.

Virtual reality (VR) is a technology that immerses users in an immersive virtual environment. With the help of special headphones and motion detection, users can feel as if they are in this virtual world.

VR and business simulations represent a powerful alliance that opens up new opportunities for learning and development.

The future of business simulations is likely to involve the integration of artificial intelligence and machine learning. This will allow for more adaptive and dynamic simulations that provide personalized feedback and challenges for participants. With the growing trend towards remote work, business simulations can facilitate collaboration and decision-making in a virtual space. Future developments may focus on improving the virtual teamwork experience.

The interplay between business simulations, the digital economy, and AI is driving a paradigm shift in business training and development. AI's role in personalizing learning experiences and facilitating collaboration within virtual environments is reshaping the way professionals prepare for the challenges and opportunities presented by the digital economy. As we move forward, business simulations will continue to be a linchpin in nurturing talent and fostering strategic thinking in an AI-powered business world.

5. Conclusions

The digital revolution, accelerated by the rapid growth of digital technologies, big data analytics, artificial intelligence, and the Internet of Things, is leading to radical changes in the way we observe, analyze, and predict economic phenomena. This revolution not only increases the ability to collect large amounts of data but also provides tools to draw practical conclusions from this data, which contributes to a deeper understanding of economic dynamics.

Thus, digitalization opens up new opportunities and challenges for the modern economy. It allows us to better manage resources, improve business processes, and respond to changes in real-time. However, along with these opportunities, it also threatens traditional business models and requires new approaches to managing and analyzing economic phenomena. We explored the role of economic process modeling in the digital revolution. We examined how digital technologies affect economic dynamics, what modern methods and tools are used to analyze economic phenomena, and how models can help solve complex problems in the digital revolution.

As a result, the digital revolution provides new opportunities for modeling economic processes, making them more accurate, adaptive, and useful for solving complex problems in the modern economy.

The combination of business simulations and virtual reality opens up new opportunities for education and training in various business areas. This integration provides participants with an immersive experience and the opportunity to learn in virtual business environments where every step has real-world consequences.

Modellierung wirtschaftlicher Prozesse im Zeitalter der Digitalisierung

Oksana Urikova/Teresa Dierkes/Halyna Beshley

Abstract

Die digitale Revolution, die durch rasante Fortschritte in den Bereichen Digitaltechnik, Big Data-Analyse, künstliche Intelligenz und Internet der Dinge vorangetrieben wird, verändert die Art und Weise, wie wir wirtschaftliche Entwicklungen beobachten, analysieren und vorhersagen, nachhaltig. Sie verbessert nicht nur die Datenerhebung, sondern stellt auch Werkzeuge zur Verfügung, mit denen praktische Erkenntnisse gewonnen werden können, die unser Verständnis der wirtschaftlichen Dynamik bereichern. Der vorliegende Beitrag untersucht die Bedeutung der Modellierung wirtschaftlicher Prozesse im Zeitalter der Digitalisierung. Er beleuchtet, wie sich digitale Technologien auf die wirtschaftliche Dynamik auswirken, welche modernen Methoden und Werkzeuge zur Analyse wirtschaftlicher Phänomene eingesetzt werden und wie Modelle zur Lösung

komplexer Probleme in der digitalen Revolution beitragen können. Darüber hinaus werden einige wichtige Konzepte und Begriffe im Zusammenhang mit der digitalen Wirtschaft sowie Veränderungen in der Modellierung wirtschaftlicher Prozesse im Kontext der digitalen Transformation untersucht. Anhand eines Beispiels wird die Erstellung eines Prognosemodells für Unternehmensausfälle veranschaulicht und beschrieben, wie digitale Technologien den Modellierungsprozess wirtschaftlicher Phänomene beeinflussen.

Key Words: Digitale Wirtschaft, digitale Technologien, Big-Data-Analyse, künstliche Intelligenz, wirtschaftliche Phänomene beobachten, analysieren, prognostizieren.

1. Einleitung

In einer Welt, die von einer rasanten technologischen Entwicklung geprägt ist, befindet sich die Wirtschaft in einem tiefgreifenden Wandel. Das Zeitalter der Digitalisierung führt zu grundlegenden Veränderungen in der Art und Weise, wie Unternehmen und Behörden arbeiten und wie Menschen miteinander interagieren. Die Modellierung wirtschaftlicher Prozesse ist in diesem Zusammenhang ein wichtiges Instrument, um die Entwicklungen in dieser neuen digitalen Welt zu verstehen und zu antizipieren.

Die digitale Revolution, die durch das rasante Wachstum digitaler Technologien, Big Data-Analysen, künstliche Intelligenz und das Internet der Dinge vorangetrieben wird, führt zu tiefgreifenden Veränderungen in der Art und Weise, wie wir wirtschaftliche Phänomene beobachten, analysieren und vorhersagen. Diese Revolution verbessert nicht nur unsere Fähigkeit, große Datenmengen zu sammeln, sondern stellt auch Werkzeuge bereit, um aus diesen Daten praktische Schlussfolgerungen zu ziehen und so zu einem tieferen Verständnis der wirtschaftlichen Dynamik beizutragen.

Die Digitalisierung eröffnet grundlegend neue Chancen und Herausforderungen für die moderne Wirtschaft. Sie ermöglicht es, Ressourcen effizienter zu nutzen, Geschäftsprozesse zu optimieren und in Echtzeit auf Veränderungen zu reagieren. Neben diesen Chancen stellt die Digitalisierung aber auch eine Bedrohung für traditionelle Geschäftsmodelle dar und erfordert neue Ansätze zur Steuerung und Analyse wirtschaftlicher Phänomene.

Der vorliegende Artikel befasst sich mit der Bedeutung der Modellierung wirtschaftlicher Prozesse im Zeitalter der Digitalisierung.

Er beleuchtet, wie sich digitale Technologien auf die wirtschaftliche Dynamik auswirken, welche modernen Methoden und Werkzeuge zur Analyse wirtschaftlicher Phänomene eingesetzt werden und wie Modelle zur Lösung komplexer Probleme in der digitalen Revolution beitragen können (siehe Abb. 1).

2. Digitale Innovationen bei der Modellierung wirtschaftlicher Prozesse

Die Entwicklung der Informatisierung wird heute vor allem mit der Einführung digitaler Kommunikationstechnologien und -plattformen in Verbindung gebracht, für die das Internet und mobile Geräte die Grundlage bilden. Die auf Informations- und Kommunikationstechnologien basierenden Wirtschaftssektoren werden als "digitale Wirtschaft" bezeichnet. In diesem Beitrag wird davon ausgegangen, dass die digitale Wirtschaft drei Haupttätigkeitsbereiche umfasst. Der erste ist der "digitale Sektor", der die Informationstechnologie (IT/ICT) und die Produktion grundlegender digitaler Güter und Dienstleistungen umfasst. Eine echte "digitale Wirtschaft", wie sie in diesem Beitrag definiert wird (Abb. 1), liegt dann vor, wenn ein wesentlicher Teil der wirtschaftlichen Produktion auf digitalen Technologien beruht und ein Geschäftsmodell zugrunde liegt, das auf digitalen Gütern und Dienstleistungen basiert. Dieser Bereich umfasst den "digitalen Sektor" und die neuen digitalen Dienstleistungen und Plattformen. Die weitestgehende Nutzung von Informations- und Kommunikationstechnologien (IKT) in allen Bereichen der Wirtschaft wird als "digitale Wirtschaft" bezeichnet [1].

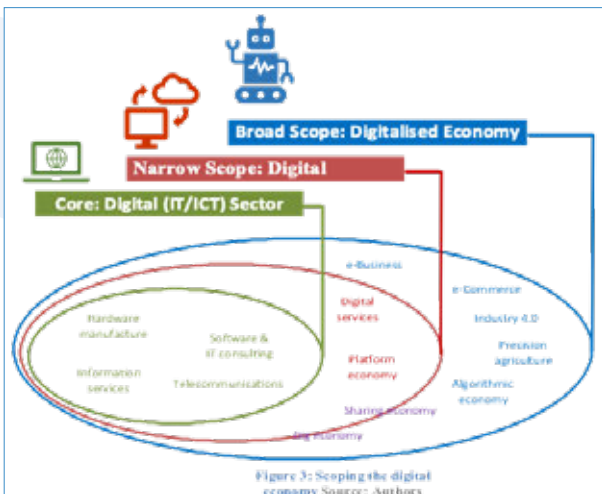


Abb. 1. Definition des Gegenstandsbereichs der digitalen Wirtschaft

Die Modellierung von Wirtschaftsprozessen ist für das Verständnis und die Nutzung der digitalen Wirtschaft von entscheidender Bedeutung. Die Modellierung wirtschaftlicher Prozesse ist in erster Linie ein analytischer und mathematischer Ansatz, um die Funktionsweise wirtschaftlicher Systeme, Prozesse und Phänomene zu untersuchen und zu verstehen. Dieser Ansatz verwendet verschiedene mathematische und statistische Methoden, Computertechnologie und Wirtschaftstheorie, um Modelle zu erstellen, die reale Aspekte der Wirtschaft widerspiegeln können.

Die Digitalisierung hat großen Einfluss auf die Modellierung wirtschaftlicher Prozesse. Sie verändert die Herangehensweise und eröffnet neue Möglichkeiten, wirtschaftliche Phänomene zu analysieren. Dies geschieht unter anderem auf folgende Weise:

- Zugang zu großen Datenmengen: Digitale Technologien ermöglichen die Erfassung und Speicherung riesiger Datenmengen aus verschiedenen Quellen, darunter soziale Medien, E-Commerce, IoT-Sensoren usw. Dadurch stehen den Wirtschaftswissenschaftlern mehr Daten für die Entwicklung von Modellen und die Durchführung von Analysen zur Verfügung.

- Big-Data-Analysen: Die Digitalisierung fördert die Entwicklung von Big-Data-Analysen, mit denen große Datenmengen in Echtzeit verarbeitet und analysiert werden können. Dieser Ansatz ermöglicht es Wirtschaftswissenschaftlern, detailliertere und genauere Ergebnisse bei der Modellierung zu erzielen.
- Künstliche Intelligenz (KI): Methoden der künstlichen Intelligenz wie maschinelles Lernen ermöglichen die Erstellung von Prognosemodellen, die in der Lage sind, sich an neue Daten anzupassen und komplexe Zusammenhänge zu erkennen, die von herkömmlichen Modellen möglicherweise nicht erfasst werden.
- Analyse und Vorhersage: Digitale Technologien ermöglichen die Analyse und Vorhersage wirtschaftlicher Ereignisse in Echtzeit. Dies erleichtert die Überwachung der Märkte, die finanzielle Stabilität und die rasche Entscheidungsfindung.
- Personalisierte Modelle: Der Zugang zu einer Fülle von Verbraucherdaten ermöglicht die Entwicklung personalisierter Geschäftsmodelle, die individuelle Kundenmerkmale und -verhaltensweisen berücksichtigen.
- Automatisierung und Prozessoptimierung: Digitale Technologien ermöglichen die Automatisierung vieler Aspekte der ökonomischen Modellierung, wodurch die Entwicklung und Aktualisierung von Modellen vereinfacht wird.
- Erweiterung des geographischen Forschungsraums: Digitale Technologien ermöglichen es Ökonomen, mit Kollegen aus der ganzen Welt zusammenzuarbeiten und Daten auszutauschen, was die Möglichkeiten für vergleichende Analysen erweitert.
- Das Hauptkonzept, das die Grundsätze für die Schaffung eines Ökosystems der digitalen Wirtschaft erläutert, ist in der Abbildung dargestellt.

Das Ökosystem der digitalen Wirtschaft (Abb. 2) umfasst eine Reihe miteinander verbundener Branchen, Unternehmen, Technologien, Daten und Infrastrukturen, die zusammen ein wirtschaftliches oder digitales Ökosystemprodukt erzeugen. Dieses Ökosystem basiert auf der Nutzung digitaler Technologien und zielt darauf ab, Wettbewerbsfähigkeit und Nachhaltigkeit in der modernen digitalen Umgebung zu gewährleisten.

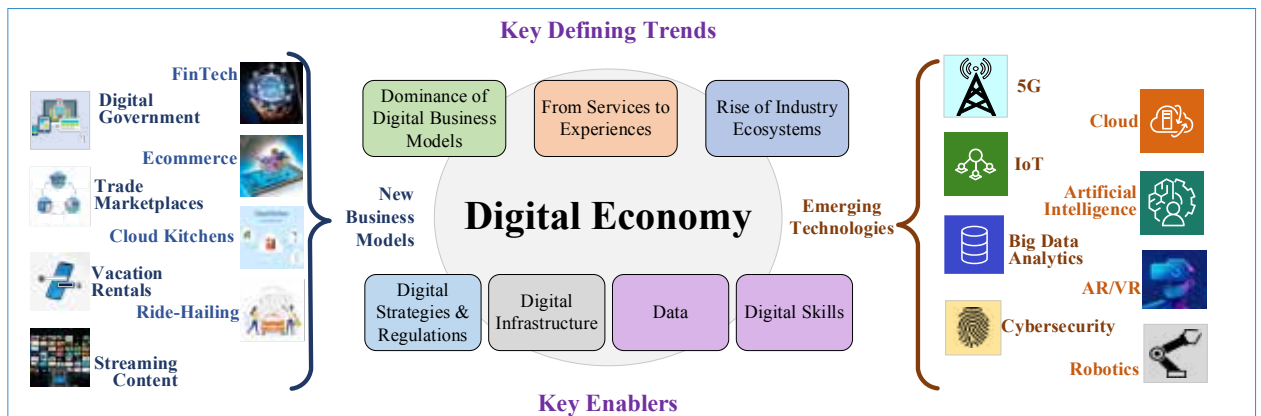


Abb.2: Ökosystem der digitalen Wirtschaft

Alle Veränderungen, die mit der globalen Digitalisierung einhergehen, eröffnen neue Möglichkeiten für die Modellierung wirtschaftlicher Prozesse, die dadurch genauer, anpassungsfähiger und nützlicher für die Lösung komplexer Probleme in der modernen Wirtschaft werden [2].

3. Modellierung wirtschaftlicher Prozesse und Prognose von Unternehmensausfällen

Die Modellierung von Wirtschaftsprozessen und die Prognose von Ausfallraten von Unternehmen sind wichtige Aufgaben im globalen Kontext der modernen Wirtschaft. Es ist bekannt, dass Zahlungsausfälle erhebliche Auswirkungen auf die finanzielle Stabilität, die Kreditkosten, das Investitionsklima und die allgemeine Wirtschaftslage eines Landes haben. Die Fähigkeit, Ausfallrisiken von Unternehmen effektiv vorherzusagen und zu managen, ist daher für viele Branchen wie den Bankensektor, die Investmentbranche und die Unternehmen selbst von großer Bedeutung [3].

Der rasche digitale Wandel in der modernen Welt hat zu erheblichen Veränderungen bei der Wirtschaftsmodellierung und der Vorhersage von Ausfällen geführt. Der Einsatz von digitalen Technologien, Big Data und Werkzeugen der künstlichen Intelligenz kann die Prognosegenauigkeit erheblich verbessern, Modelle an kurzfristige Marktveränderungen anpassen und die Zuverlässigkeit des Prognoseprozesses insgesamt erhöhen.

Dieses Beispiel veranschaulicht den Prozess der Erstellung eines Prognosemodells für Unternehmensausfälle.

Risikoparameter sind dynamisch und es ist daher von entscheidender Bedeutung zu verstehen, wie sie sich im Laufe der Zeit verändern – ein wichtiger Aspekt des Risikomanagements. In der ersten Fallstudie werden historische Kreditmigrationsdaten verwendet, um verschiedene Zeitreihen zu erstellen und die Dynamik der Ausfallraten zu visualisieren. In der zweiten Fallstudie werden einige der in der ersten Fallstudie erstellten Zeitreihen sowie zusätzliche Daten verwendet, um ein Prognosemodell für Unternehmensausfälle zu entwickeln. Darüber hinaus werden grundlegende Konzepte für das Backtesting vorgestellt. Obwohl wir ein lineares Regressionsmodell für Unternehmensausfälle vorstellen, können die beschriebenen Instrumente und Prinzipien auf verschiedene Prognosemethoden angewendet werden.

In diesem Teil unseres Beitrags analysieren wir historische Daten zu den Übergangswahrscheinlichkeiten von Emittententypen, die durch die Variable *TransMat* repräsentiert werden. Diese Daten umfassen die Jahre 1981 bis 2005 und stammen aus [10]. Sie enthalten Informationen über die Anzahl der Emittenten zu Beginn jedes Jahres für jedes Rating (Variable *nIssuers*) und die Anzahl der neuen Emittenten, die im Laufe des Jahres erstmals in jedes Rating aufgenommen wurden (Variable *nNewIssuers*).

Darüber hinaus verwenden wir Daten zu den Gewinnerwartungen der Unternehmen aus [9] und Daten zu den Unternehmensspreads aus [4] (Variablen *CPF* und *SPR*). Zusätzlich berücksichtigen wir eine Variable, die die Rezessionsjahre (Recession) kennzeichnet und den in [7] definierten Rezessionsperioden entspricht. Diese Variable wird hauptsächlich zur Visualisierung der Daten verwendet.

Zunächst aggregieren wir die Ausfallraten für Emittenten der Kategorien *Investment Grade (IG)* und *Speculative Grade (SG)* sowie die Gesamtausfallrate für Unternehmen.

Investment-Grade- und *Speculative-Grade-*Emittenten sind zwei verschiedene Kategorien von Unternehmen oder Emittenten mit unterschiedlichen Bonitätsratings oder Kreditqualitäten. Diese Ratings bestimmen, wie zuverlässig die Fähigkeit des Emittenten eingeschätzt wird, seine Schulden zurückzuzahlen und seinen finanziellen Verpflichtungen gegenüber den Anlegern nachzukommen.

*Investment-Grade-*Emittenten:

- Diese Unternehmen verfügen über ein hohes Kreditrating, das so genannte "Investment Grade".
- Ein *Investment-Grade-Rating* bedeutet, dass diese Unternehmen von den Anlegern als risikolos und ihre Schulden als zuverlässig eingestuft werden.
- Diese Unternehmen sind in der Lage, ihre Schulden zurückzuzahlen und Gewinne zu erwirtschaften, ohne dass ein Ausfallrisiko besteht.

*Speculative-Grade-*Emittenten:

- Diese Unternehmen haben ein niedrigeres Kreditrating und werden als "spekulativ" eingestuft.
- Ein *spekulatives Rating* bedeutet, dass diese Unternehmen ein höheres Ausfallrisiko und eine geringere Kreditqualität aufweisen als Unternehmen mit *Investment-Grade-Rating*.
- Diese Unternehmen sind möglicherweise finanziell weniger stabil und haben nur begrenzte Möglichkeiten, ihre Schulden zurückzuzahlen.

Die folgende Abbildung zeigt die Entwicklung der Ausfallraten für *Investment Grade (IG)*, *Speculative Grade (SG)* und die Gesamtausfallrate. Die logarithmische Skala veranschaulicht Trends und zeigt keine absoluten Werte. Schattierte Bereiche kennzeichnen Rezessionsjahre. Rezessionsjahre sind Perioden des wirtschaftlichen Abschwungs oder des Rückgangs der wirtschaftlichen Aktivität, der durch einen Rückgang des Bruttoinlandsprodukts und anderer Wirtschaftsindikatoren gemessen werden kann (siehe Abbildung 3).




Abb.3. Dynamik der IG-, SG- und Gesamtausfallraten von Unternehmen

Es fällt auf, dass die Ausfallraten von SG und IG leichte Schwankungen aufweisen. So ist beispielsweise die Ausfallrate der IG 1994 höher als 1995, während bei den SG der umgekehrte Trend zu beobachten ist. Außerdem erreichten die Ausfallraten der IG im Jahr 2002 nach der Rezession von 2001 ihren Höchststand, während die Ausfallraten der SG im Jahr 2001 ihren Spitzenwert erreichten. Diese Beobachtung deutet darauf hin, dass Modelle zur Vorhersage der Dynamik von IG- und SG-Ausfallraten erhebliche Unterschiede aufweisen können, was ein typisches Szenario im Zusammenhang mit unterschiedlichen Marktsegmenten ist. Die Gesamtausfallquote der Unternehmen, die sich aus beiden zusammensetzt, zeigt ein Muster, das dem der SG ähnlicher ist, was wahrscheinlich auf den relativen Anteil von SG gegenüber IG-Emittenten im Datensatz zurückzuführen ist.

Die von uns berechneten Ausfallraten lassen sich in verschiedene Kategorien einteilen: Point-in-Time-Raten (PIT), Through-the-Cycle-Raten (TTC) und durchschnittliche Raten in Rezessions- oder Boomphasen. Die PIT-Quoten werden ausschließlich auf der Grundlage der jüngsten Daten geschätzt. Im Gegensatz dazu werden bei den TTC-Raten alle während der 25 Jahre des Datensatzes beobachteten Migrationen in der Schätzung berücksichtigt. Darüber hinaus sind die durchschnittlichen Ausfallraten während wirtschaftlicher Rezessionen und Expansionen von Interesse (siehe Abbildung 4).

Die Berechnung dieser Quoten ist mit den uns zur Verfügung stehenden Daten und Instrumenten sehr einfach. Um beispielsweise die durchschnittlichen Übergangswahrscheinlichkeiten in Rezessionsjahren zu schätzen, können die Daten mit Hilfe einer logischen Indizierung auf Basis der Variable "Rezession" gefiltert werden. Anschließend können die entsprechenden Summenstrukturen an die Funktion "transprobbytotals" übergeben werden, die die Daten über die Zeit aggregiert und die entsprechende Übergangsmatrix liefert.




Abb. 4 Schätzung der PIT-Raten, TTC-Raten sowie der Rezessions- und Expansionsraten

Für einige Analysen werden Simulationen verwendet, bei denen die Ausfallrate von der allgemeinen Wirtschaftslage abhängt, z. B. von einer Rezession oder einem Boom. Schätzungen der Ausfallraten in Rezessions- und Boomphasen können in diesem Zusammenhang nützlich sein. Dabei ist zu beachten, dass es sich bei diesen Schätzungen um historische Durchschnittswerte handelt, die möglicherweise nicht geeignet sind, um die in einem bestimmten Jahr zu erwartenden tatsächlichen Ausfallraten vorherzusagen.

Im zweiten Teil dieses Beispiels werden wir die Verwendung dieser historischen Durchschnitte als Prognoseinstrumente erneut bewerten, indem wir ein Backtesting durchführen. Dieser Ansatz wird hilfreich sein, um die Qualität dieser historischen Mittelwerte als Prognoseinstrumente zu beurteilen.

Mit Hilfe der Kreditdaten können wir neue Zeitreihen erstellen, die von Interesse sind. Eine dieser Zeitreihen ist ein Altersproxy, der als Prädiktor für das Prognosemodell dient, das im zweiten Teil dieses Beispiels besprochen wird.

Das Alter ist ein bekannter und wichtiger Faktor bei der Prognose von Ausfallraten, wie in [1] und [5] gezeigt wurde. Das Alter bezieht sich in diesem Zusammenhang auf die Anzahl der Jahre, die seit der Emission einer Anleihe vergangen sind. Dabei ist zu beachten, dass das Alter eines Portfolios durch die Berechnung des Durchschnittsalters der Anleihen bestimmt wird. Historische Daten weisen gewisse Muster auf: Viele Schuldner schlechter Bonität fallen kurz nach der Emission einer Anleihe aus. Unternehmen, die Anleihen begeben, verwenden die aufgenommenen Mittel häufig für Zahlungen im ersten oder zweiten Jahr. Danach ist der Cashflow die Hauptfinanzierungsquelle, und wenn dieser nicht ausreicht, kann es zu Zahlungsausfällen kommen.

Die Berechnung des genauen Alters des Portfolios ist aufgrund fehlender Informationen auf Emittentenebene im Datensatz

schwierig. In Anlehnung an die in [6] vorgeschlagene Methode wird daher ein Altersproxy verwendet. Dieser Proxy wird berechnet als die Anzahl der Neuemittenten im Jahr "t-3" dividiert durch die Gesamtzahl der Emittenten am Ende des Jahres "t". Es ist zu beachten, dass die Berechnung des Altersproxys im Jahr 1984 begann. Für den Zähler (die Anzahl der Neuemittenten) liegen eindeutige Daten vor. Der Nenner (die Zahl der Emittenten am Ende des Jahres) entspricht der Zahl der Emittenten zu Beginn des folgenden Jahres, die für alle Jahre mit Ausnahme des letzten Jahres bekannt ist. Für das letzte Jahr wird er als Summe aller Übergänge in ein Non-Default-Rating plus der Anzahl der Neuemittenten in diesem Jahr berechnet. In unserer Analyse verwenden wir das folgende lineare Regressionsmodell zur Prognose der Ausfallraten von Unternehmen:

$$\text{Ausfallrate} = \beta_0 + \beta_1 * \text{AGE} + \beta_2 * \text{CPF} + \beta_3 * \text{SPR} \quad (1)$$

Die einzelnen Variablen stehen für:

AGE: Der Altersproxy, wie oben definiert.

CPF: (Corporate Profits Forecast) Prognose der Unternehmensgewinne, die einen Einblick in das wirtschaftliche Umfeld gibt.

SPR: Spread über Staatsanleihen als Indikator für die Kreditqualität. Es ist anzumerken, dass dieses Modell dem in [6] beschriebenen Modell entspricht, mit dem Unterschied, dass das Modell in [6] speziell auf Emittenten mit Investment Grade (IG) ausgerichtet ist.

Wie bereits erwähnt, sind das Alter, die wirtschaftliche Lage (gemessen an den prognostizierten Unternehmensgewinnen) und die Kreditqualität (gemessen am Spread) drei grundlegende Dimensionen, die in Kreditanalysemodellen häufig berücksichtigt werden. Die Regressionskoeffizienten des Modells stellen die erwarteten direktionalen Beziehungen dar: Die Ausfallraten steigen tendenziell mit einem höheren Anteil an 3-Jahres-Emittenten, sinken bei stabilen Unternehmensgewinnen und steigen bei hohen Unternehmensrenditen. Darüber hinaus deutet das korrigierte R-Quadrat auf eine gute Eignung des Modells hin.

Abb. 5 zeigt den Grad der Übereinstimmung zwischen den Modellvorhersagen und den für die Anpassung des Modells verwendeten Datenpunkten.

Es gibt keine stichhaltigen statistischen Beweise für eine Abweichung von den Annahmen der linearen Regression. Es ist offensichtlich, dass die Ausfallraten nicht normalverteilt sind. Das Modell geht jedoch nicht davon aus, dass die Ausfallraten selbst normalverteilt sind. Die einzige Normalitätsannahme innerhalb des Modells ist, dass bei gegebenen Prädiktorwerten die Fehler zwischen prognostizierten und beobachteten Ausfallraten normalverteilt sind. Betrachtet man die Anpassung in der Stichprobe, so scheint diese Annahme nicht unbegründet zu sein. Die Fehlergrößen scheinen nicht davon abzuhängen, ob die Ausfallraten hoch oder niedrig sind. So weist beispielsweise das Jahr 2001 eine hohe Ausfallrate und einen großen Fehler auf, aber auch die Jahre 1991 oder 2002 haben hohe Raten und gleichzeitig sehr kleine Fehler. Ebenso weisen Jahre mit niedrigen Ausfallraten wie 1996 und 1997 hohe Fehler auf, während die

Jahre 2004 oder 2005 mit ähnlich niedrigen Raten nur sehr geringe Fehler aufweisen (vgl. Abb. 5).




Abb.5. Prognose von Unternehmensausfällen

Eine vollständige statistische Analyse des Modells würde den Rahmen dieses Dokuments sprengen. Detaillierte Beispiele finden sich jedoch in der Statistics and Machine Learning Toolbox™ und der Econometrics Toolbox™.

4. Planspiele und digitale Wirtschaft: Wechselwirkungen und Perspektiven

In der modernen Welt, in der die digitale Transformation eine wichtige Rolle für die Entwicklung von Unternehmen und der globalen Wirtschaft spielt, sind Unternehmenssimulationen nicht nur ein wichtiges Lernwerkzeug, sondern auch ein Analyse- und Prognoseinstrument für die digitale Wirtschaft. Dieser Artikel untersucht die Beziehung zwischen Unternehmenssimulationen und der digitalen Wirtschaft und untersucht die Aussichten für ihre gemeinsame Entwicklung.

Die digitale Wirtschaft zeichnet sich durch eine rasante technologische Entwicklung, eine wachsende Datenmenge und die Entstehung neuer Geschäftsmodelle aus. In diesem Umfeld sind Unternehmenssimulationen ein ideales Instrument, um die Auswirkungen digitaler Innovationen auf Geschäftsprozesse zu analysieren und zu modellieren. Sie ermöglichen es den Teilnehmern, in die Rolle von Führungskräften eines Unternehmens zu schlüpfen und strategische Entscheidungen in einem digitalen Umfeld zu treffen. Diese Simulationen werden häufig in Bildungseinrichtungen, Unternehmensschulungen und Entwicklungsprogrammen eingesetzt.

Virtual Reality (VR) ist eine Technologie, die die Nutzer/innen in eine virtuelle Umgebung eintauchen lässt. Mit Hilfe von speziellen Kopfhörern und Bewegungserkennung können sich die Nutzer/innen so fühlen, als würden sie sich in dieser virtuellen Welt befinden.

VR und Unternehmenssimulationen bilden eine starke Kombination, die neue Lern- und Entwicklungsmöglichkeiten eröffnet.

In Zukunft werden Unternehmenssimulationen wahrscheinlich durch

den Einsatz von künstlicher Intelligenz und maschinellem Lernen geprägt sein. Dies ermöglicht anpassungsfähigere und dynamischere Simulationen, die personalisiertes Feedback und Herausforderungen für die Teilnehmer/innen bieten. Angesichts der zunehmenden Bedeutung von Telearbeit können Unternehmenssimulationen die Zusammenarbeit und Entscheidungsfindung in einem virtuellen Raum erleichtern. Zukünftige Entwicklungen werden sich auf die Verbesserung der virtuellen Teamarbeit konzentrieren.

Das Zusammenspiel von Unternehmenssimulationen, digitaler Wirtschaft und künstlicher Intelligenz führt zu einem Paradigmenwechsel in der beruflichen Aus- und Weiterbildung. Die Rolle der KI bei der Personalisierung von Lernerfahrungen und der Erleichterung der Zusammenarbeit in virtuellen Umgebungen verändert die Art und Weise, wie Fachkräfte auf die Herausforderungen und Chancen der digitalen Wirtschaft vorbereitet werden. Unternehmenssimulationen werden weiterhin eine zentrale Rolle bei der Förderung von Talenten und strategischem Denken in einer KI-gestützten Geschäftswelt spielen.

5. Fazit

Die digitale Revolution, die durch rasante Fortschritte in den Bereichen Digitaltechnik, Big Data-Analyse, künstliche Intelligenz und Internet der Dinge vorangetrieben wird, verändert die Art und Weise, wie wir wirtschaftliche Phänomene beobachten, analysieren und vorhersagen, nachhaltig. Diese Revolution verbessert nicht nur die Datenerhebung, sondern stellt auch Werkzeuge zur Verfügung, mit denen praktische Er-

kenntnisse gewonnen werden können, die unser Verständnis der wirtschaftlichen Dynamik bereichern.

Die Digitalisierung eröffnet somit neue Chancen und Herausforderungen für die moderne Wirtschaft. Sie ermöglicht es, Ressourcen besser zu verwalten, Geschäftsprozesse zu optimieren und in Echtzeit auf Veränderungen zu reagieren. Neben diesen Chancen bedroht die Digitalisierung jedoch auch traditionelle Geschäftsmodelle und erfordert neue Ansätze zur Steuerung und Analyse wirtschaftlicher Phänomene. Wir haben die Bedeutung der Modellierung von Geschäftsprozessen im Kontext der digitalen Revolution untersucht. Wir haben analysiert, wie sich digitale Technologien auf die wirtschaftliche Dynamik auswirken, welche modernen Methoden und Werkzeuge zur Analyse wirtschaftlicher Phänomene eingesetzt werden und wie Modelle zur Lösung komplexer Probleme in der digitalen Revolution beitragen können.

Im Ergebnis bietet die digitale Revolution neue Möglichkeiten für die Modellierung wirtschaftlicher Prozesse, die präziser, anpassungsfähiger und nützlicher für die Lösung komplexer Probleme in der modernen Wirtschaft sind.

Die Kombination von Unternehmenssimulationen und virtueller Realität eröffnet neue Möglichkeiten für die Aus- und Weiterbildung in verschiedenen Wirtschaftsbereichen. Diese Kombination ermöglicht den Teilnehmern eine intensive Erfahrung und die Möglichkeit, in virtuellen Geschäftsumgebungen zu lernen, in denen jeder Schritt reale Auswirkungen hat.

References / Literatur

- [1] S. Venter and S. Grobbelaar, "A technology management capabilities framework for technology platforms," *IEEE Trans. Eng. Manage.*, vol. 70, no. 7, pp. 2558–2573, Jul. 2023, doi: 10.1109/TEM.2022.3172720.
- [2] W. R. Ho, N. Tsolakis, T. Dawes, M. Dora, and M. Kumar, "A digital strategy development framework for supply chains," *IEEE Trans. Eng. Manage.*, vol. 70, no. 7, pp. 2493–2506, Jul. 2023, doi: 10.1109/TEM.2021.3131605.
- [3] Basel Committee on Banking Supervision, "Principles for Sound Stress Testing Practices and Supervision - Final Paper," Bank for International Settlements (BIS), May 2009. Available at: <https://www.bis.org/publ/bcbs155.htm>.
- [4] FRED, St. Louis Federal Reserve, Federal Reserve Economic Database, <https://research.stlouisfed.org/fred2/>.
- [5] Helwege, J., and P. Kleiman, "Understanding Aggregate Default Rates of High Yield Bonds," Federal Reserve Bank of New York, Current Issues in Economics and Finance, Volume 2, Number 6, May 1996.
- [6] Loeffler, G., and P. N. Posch, *Credit Risk Modeling Using Excel and VBA*, West Sussex, England: Wiley Finance, 2007.
- [7] NBER, National Bureau of Economic Research, Business Cycle Expansions and Contractions, <https://www.nber.org/cycles/>.
- [8] Otani, A., S. Shiratsuka, R. Tsurui, and T. Yamada, "Macro Stress-Testing on the Loan Portfolio of Japanese Banks," Bank of Japan Working Paper Series No.09-E-1, March 2009.
- [9] Survey of Professional Forecasters, Federal Reserve Bank of Philadelphia, <https://www.philadelphiafed.org/>.
- [10] Vazza, D., D. Aurora, and R. Schneck, "Annual 2005 Global Corporate Default Study And Rating Transitions," Standard & Poor's, Global Fixed Income Research, New York, January 2006.
- [11] J. Peterková, Z. Repaská, and L. Prachařová, "Best practice of using digital business simulation games in business education," *Sustainability*, vol. 14, no. 15, p. 8987, 2022.