

Complexidade do resultado inovativo setorial na indústria criativa brasileira¹

Área 9 - Economia Industrial e da Tecnologia

Thiago Cavalcante de Souza & Ana Paula Macedo de Avellar

[1] Faculdade de Administração, Contabilidade e Economia, Universidade Federal de Goiás, thiagocavalcante@ufg.br.

[2] Instituto de Economia e Relações Internacionais, Universidade Federal de Uberlândia, anaavellar@ufu.br.

Resumo

Este estudo compreende uma análise da complexidade do resultado inovativo da indústria criativa brasileira. Por meio de simulações computacionais em redes neurais artificiais com dados de duas edições da Pesquisa de Inovação (PINTEC, 2011 e 2014), realiza-se previsões probabilísticas sobre o resultado inovativo dos setores da indústria criativa a partir de relações não-lineares entre variáveis de esforço inovativo, base de conhecimento/aprendizado, trajetória tecnológica e financiamento público. Os resultados mostram que, no geral, a indústria criativa reproduz um resultado inovativo de baixa complexidade, comparado às evidências internacionais. Além disso, o aumento de interações sinápticas afeta inversamente o resultado inovativo em termos de receita, sugerindo baixa capacidade dinâmica e adaptativa no interior dessa indústria.

Palavras-chave: Redes Neurais. Inovação. Criatividade. PINTEC. Brasil.

Código JEL: L6, L26, M21.

Abstract

This study comprises an analysis the complexity at innovative result of the Brazilian creative industry. Through computer simulations in artificial neural networks with data from two editions of the Innovation Survey (PINTEC, 2011 and 2014), probabilistic predictions are made about the innovative result of the creative industry sectors based on non-linear relationships between variables of innovative effort, knowledge/learning base, technological trajectory and public funding. The results show that, in general, the creative industry reproduces an innovative result of low complexity, compared to international evidence. Furthermore, the increase in synaptic interactions inversely affects the innovative result in terms of revenue, suggesting low dynamic and adaptive capacity within this industry.

Keywords: Neural networks. Innovation. Creativity. PINTEC. Brazil.

JEL Code: L6, L26, M21.

1 Introdução

Na abordagem evolucionária, a análise do resultado inovativo deve incorporar explicitamente a natureza estocástica da inovação, de forma a considerar a diversidade e complexidade organizacional como elementos preponderantes para o processo inovativo. Nessa abordagem, os projetos de P&D revestem-se de relevância, pois são considerados processos heurísticos que as empresas empreendem como estratégia de adaptação aos mecanismos de seleção dos mercados.

É justamente nesse tipo de heurística que reside a diferença de produtividade entre as empresas, pois cada uma delas estabelecem esforços inovativos distintos. Esse resultado é obtido pois nem todas as empresas realizam P&D, utilizando-se de outras fontes de inovação para a aprendizagem interna, como aquisição de projetos oriundos de fornecedores, centros científicos ou institutos de pesquisa governamentais, aquisição de máquinas e equipamentos ou subcontratação de projetos de engenharia ou conhecimento especializado. Segundo Dosi (1988) essas diferenças de esforço inovativo em nível da empresa explicitam-se em virtude da natureza da inovação desenvolvida endogenamente.

Nelson (2006) acrescenta que a principal fonte de diferença entre as empresas consiste no grau de apropriabilidade do conhecimento oriundo desse esforço, pois este fornece às empresas um conjunto de aptidões dinâmicas e organizacionais, que as tornam capazes de gerar soluções inovadoras e integrá-las ao processo de produção, comercialização e marketing. Portanto, o resultado inovativo empresarial deriva da interação complexa entre a dinâmica organizacional da empresa, seus recursos e competências e, ainda, com as inter-relações realizadas com o ambiente externo à empresa.

Por isso, um conjunto de autores tem sugerido uma maior aproximação da agenda de pesquisa em inovação com a teoria da complexidade (Poutanen, Soliman e Ståhle, 2016), em que o resultado inovativo setorial decorre de um conjunto de inter-relações complexas provenientes das diferenças de intensidade do esforço inovativo empresarial e suas respectivas bases de conhecimento e formas de aprendizado. Nesse caso, os setores da atividade econômica

¹Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes).

são considerados como sistemas adaptativos complexos, compostos de empresas que experimentam, exploram, se organizam, aprendem e se adaptam (em vários graus) às mudanças do mercado.

Ao realizar simulações computacionais em redes neurais artificiais com dados de duas edições da Pesquisa de Inovação (PINTEC, 2011 e 2014), este artigo realiza previsões probabilísticas sobre o resultado inovativo dos setores da indústria criativa a partir de relações não-lineares entre variáveis de esforço inovativo, conhecimento/aprendizado, trajetória tecnológica e financiamento público. São considerados como resultado inovativo a receita líquida de vendas e inovações de produto, processo, organizacional e marketing implementadas pelas empresas. Especificamente, o artigo identifica diferentes combinações do comportamento inovativo que levam as empresas a obterem uma receita líquida de vendas superior/inferior à média setorial registrada.

Na literatura econômica, não há uma unanimidade em relação a definição e delimitação setorial da indústria criativa. Nesse artigo, utiliza-se uma definição multidimensional, em que a indústria criativa consiste em um conjunto de empresas que processam a criatividade na dimensão artística, cultural, científica e/ou tecnológica, cujos bens e serviços obtêm valor agregado quando protegidos por instrumentos de proteção intelectual ou quando vinculam sua vantagem e diferencial de comercialização em algum conteúdo simbólico restrito, que sejam difundidos em um núcleo multidimensional de campo e de domínio. Nessa definição, considera-se que a criatividade é naturalmente um processo evolucionário de retenção seletiva de ideias em um determinado núcleo de campo e domínio. Assim, a indústria criativa consiste em uma rede complexa de setores, em que “ideias” são operacionalizadas a fim de gerar bens e serviços úteis e dotados de valor “seletivo” para um conjunto específico de consumidores.

O desenho de uma arquitetura de rede complexa, segundo Robert, Yoguel e Lerena (2017) deve presumir micro heterogeneidade das atividades econômicas, nexos de complementariedade em cadeias ramificadas, interações não lineares, *feedbacks* e divergência entre as atividades econômicas e seus respectivos setores, de modo que seus bens e serviços possam ser pautados em trajetórias tecnológicas e ativos criativos distintos e heterogêneos. Nesse particular, define-se uma indústria criativa como sendo um sistema produtivo complexo e bifurcado, estruturado em cadeia produtiva ramificada que se dedica a produção de bens e serviços que mobilizem criatividade econômica, cultural, científica e/ou tecnológica em ao menos uma fase do processo de produção, distribuição ou comercialização. Essa definição demonstra-se similar a proposição de cadeia dinâmica que foi elaborada por Potts et al. (2008)¹, em que às indústrias criativas são predominantemente determinadas por processos semelhantes aos de mercado em redes sociais.

Essa pesquisa soma-se ao debate nacional e internacional sobre inovação na indústria criativa (Bakhshi e McVittie, 2009; Cavalcante e Avellar, 2020, 2021; Galuk et al., 2016; Lee e Drever, 2013; Molina et al., 2019; Müller et al., 2009; Nathan e Lee, 2015; Protogerou et al., 2017). O artigo se insere na agenda reportada ao analisar o resultado inovativo da indústria criativa a partir de um modelo de redes neurais artificiais, em que o comportamento inovativo da indústria criativa brasileira é modelado por meio de um conjunto de interações sinápticas, em que diferentes combinações geram resultados distintos (Allen, 2001; Andriani et al., 2006).

Nesse sentido, as contribuições relevantes do artigo são as seguintes: primeiro, estrutura-se um modelo de rede neural multicamadas como estratégia empírica computacional de análise da complexidade inovativa da indústria criativa brasileira, até onde se sabe, uma contribuição pioneira. Em segundo lugar, este artigo articula o moderno conceito de indústria criativa complexa de Potts et al. (2008) ao referencial teórico-empírico de sistemas complexos adaptativos. Em terceiro lugar, o artigo fornece um método aprimorado para que empresas e *policy makers* identifiquem e fomentem interações e combinações de capacidades internas aptas a potencializar os resultados do esforço inovativo empresarial/setorial.

Os resultados encontrados indicam que os setores analisados apresentam um comportamento inovativo de pouca complexidade, com 12 camadas de interação entre as variáveis incorporadas na simulação. O resultado inovativo com o maior número de interações sinápticas positivas corresponde a variável *output* RECEITArf, com 10 interações. Este resultado indica que, diante do conjunto de dados, o aumento das combinações de diferentes fontes de inovação diminui as chances de o setor criativo ampliar a sua participação na receita líquida setorial, o que remete a uma baixa capacidade dinâmica e adaptativa setorial.

Este artigo encontra-se organizado em cinco seções, que inclui esta introdução. Na segunda seção apresenta-se uma breve revisão da literatura sobre complexidade do resultado inovativo e inovação na indústria criativa. Na terceira seção, descreve-se o recorte setorial e a base de dados e, em seguida, formaliza-se a estratégia empírica. Na quarta seção, são apresentados e discutidos os resultados. Finalmente, na quinta seção, sintetiza-se às conclusões da pesquisa.

¹Esta definição deriva da teoria dos sistemas adaptativos-complexos e da abordagem empírica comportamental e social dos agentes no ambiente econômico moderno, ou seja, a escolha de algo novo que, embora socialmente produzido ou consumido de várias maneiras, envolve uma avaliação de valor individual com base em informações sociais. (POTTS, et al., 2018, p. 171, tradução nossa). Portanto, o resultado da inovação decorre de múltiplas decisões e capacidades absorvidas, em um processo dinâmico, complexo e evolutivo de criação e mudança.

2 Revisão da Literatura

O resultado inovativo setorial é por si só um fenômeno complexo (Strumsky, Lobo e Tainter, 2010), pois não presume uma condição equilíbrio, visto que as empresas mudam constantemente suas rotinas e estratégias em resposta aos padrões que se criam mutuamente nos mercados em que atuam (Arthur, 2015). Além disso, as empresas apresentam capacidades (Teece, 2007) e recursos (Penrose, 2009) diferentes, que associados às suas formas de aprendizado e conhecimentos acumulados (Malerba e Orsenigo, 1997), lhes permitem combinar distintas fontes de inovação para induzirem processos tecnológicos pouco lineares.

Conforme Possas (2008), na perspectiva evolucionária, o resultado inovativo decorre da combinação flexível de diferentes atributos e rotinas subjacentes ao comportamento da firma. Quanto maior for a competência da empresa em empreender um conjunto de combinações, de modo eficiente, mais complexo será o seu resultado inovativo. Assim, um mesmo resultado inovativo pode ser obtido por meio de múltiplas e/ou diferentes combinações de insumos, processos de aprendizados, técnicas e/ou habilidades. Dado que as empresas estão inseridas em contextos tecnológicos típicos, as mudanças resultantes do esforço inovativo formam padrões setoriais específicos.

Na abordagem evolucionária da complexidade, os setores da atividade econômica consistem em estruturas dissipativas que convertem informação em conhecimento com a finalidade de criar, manter e expandir a complexidade organizada do sistema produtivo setorial (Foster, 2005). Por conseguinte, um setor complexo é aquele cujas empresas apresentam um alto nível de interatividade não linear entre as capacidades e recursos úteis a geração de novos bens e/ou processos, bem como o aperfeiçoamento daqueles existentes (Poutanen, Soliman e Ståhle, 2016).

De acordo com Wildberger (1998), as pesquisas baseadas em sistemas complexos adaptativos produzem uma compreensão da complexidade de setores industriais, cujas simulações computacionais permitem modelar o comportamento de múltiplos agentes e setores, pois conseguem representar as interações entre as capacidades mobilizadas no interior da indústria e, assim, detectar as combinações de recursos e capacidades dinâmicas que ensejam processos adaptativos.

Os setores da atividade econômica são estruturas que exibem conexões com diferentes fontes de inovação empregadas no interior da indústria. Por isso, o grau de complexidade do resultado inovativo setorial decorre do nível de adaptação que as suas empresas dispõem para transformar conhecimentos em oportunidades tecnológicas, o que exige articulação com os demais atores do sistema setorial de inovação e o acesso a fontes de financiamento inovativo.

De acordo com Yu-Hua et al. (2011), a indústria criativa é um conjunto setorial fortemente baseado na aprendizagem tácita e codificada e cujas empresas desenvolvem-se a partir das capacidades que dispõem para acumular conhecimentos e gerar distintas inovações. Os autores destacam que apesar de a indústria criativa apresentar inúmeras e consistentes não linearidades no comportamento inovativo, poucos são os estudos que tratam o resultado inovativo desse conjunto setorial sob a abordagem da complexidade, já utilizada em estudos de outros mercados fortemente associados a moderna economia do conhecimento e da tecnologia.

De acordo com Gala (2017), a aproximação da teoria da complexidade com a economia surgiu com os trabalhos de Brian Arthur, desenvolvidos no final da década de 1980, por meio de aplicações do instrumental da física computacional para a modelagem de cenários econômicos em perspectiva dinâmica, evolucionária e seletiva, corroborando com os conceitos microeconômicos de path dependence, de escolha sob incerteza e de racionalidade limitada.

Na perspectiva de Rubenson (1992) e Rubenson e Runco (1992), a criatividade econômica é um componente do capital humano, que a torna um ativo específico das firmas. Segundo Fiani (2013), esse tipo de especificidade decorre essencialmente dos processos de aprendizado tácitos internos à firma (learning-by-doing). Trata-se de uma capacidade dinâmica para impulsionar e manter a competitividade (MacLean, 2017), através da melhoria, combinação, proteção e, quando necessário, reconfiguração dos ativos empresariais intangíveis e tangíveis, assim como identificar oportunidades de novos modelos negócios (Teece, 2007).

A partir dessa abordagem, um debate tornou-se proeminente na agenda científica e governamental, transpondo a discussão de criatividade para a perspectiva setorial. Essa agenda situa-se em torno da definição de um conjunto setorial de atividades econômicas que se utilizam da criatividade econômica, científica e cultural para promover inovações e fomentar a produção de bens e serviços de elevado valor agregado, incorporando tecnologia ou atributo cultural, isto é, alguma representação artística em forma de texto, som e imagem. Essa agenda de pesquisa resultou em uma convergência semântica, que denomina esse conjunto setorial como economia criativa (HARTLEY, 2005; HOWKINS, 2013; MACHADO et al., 2018; POTTS et al., 2008).

Uma definição seminal para esse conjunto produtivo é atribuída ao DCMS (1998), tendo direcionado a maior parte das definições posteriores, seja em crítica ou extensão da proposição. Inspirando-se na proposição britânica, Caves (2000) definiu indústrias criativas como sendo um conjunto de atividades econômicas cujo bem ou serviço principal tem a sua produção originada em um elemento substancial de esforço artístico ou criativo. Em sua definição,

considera que os bens criativos são essencialmente complexos e, geralmente, passam entre um ou mais pares de empresas independentes, seja no processo de produção, distribuição ou de comercialização. Dada a composição cultural de sua definição, restringe a indústria criativa aos segmentos de audiovisual, artes cênicas e visuais, antiguidades e patrimônio, radiodifusão, editoração, publicidade e mídia e entretenimento. Em razão da complexidade do seu processo de produção, a indústria criativa articula-se com setores tradicionais da economia, que lhe fornecem apoio. É o caso por exemplo do segmento de editoração, que envolve atividades complementares de computação, comércio e papelaria, além de setores criativos como *design*, publicidade e mídia.

Para Potts et al. (2008), a indústria criativa se constitui de um conjunto de bens e serviços sobre os quais os consumidores não têm regras de decisão bem estabelecidas para escolha. Isso porque são os aspectos distintivos da criatividade incorporada no processo produtivo ou de comercialização que imputa valor econômico aos bens transacionados, cuja percepção individual é heterogênea. Nesse particular, entendem que a inter-relação entre os agentes econômicos, redes e empresas da indústria criativa é eminentemente dinâmica, de modo que todos empenham-se no processo mútuo de criação de valor, simbólico ou econômico.

A partir dessas definições, diversos autores passaram a investigar a indústria criativa sob a perspectiva de seus padrões inovativos. Chaston (2008) procurou analisar padrões inovativos na indústria criativa da região sudoeste do Reino Unido a partir de uma base primária obtida em um universo de 500 empresas. Especificamente, o estudo se propôs a identificar a taxa de colapso empresarial e indicar uma taxonomia de classificação empresarial em função da importância atribuída a programas de formação e treinamento. Em relação ao colapso empresarial segregado por setor da atividade econômica criativa, verificou-se que as atividades mais proeminentes foram: pintura (38%), escultura (5%), têxtil (22%), fabricação de joias (10%), artigos em cerâmica (12%), artigos e produção de vidro (4%), artigos e produção de madeira e mobiliários (3%), pois ambas apresentaram resultados estatisticamente significativos.

Müller, Rammer e Trüby (2009) examinaram o papel das indústrias criativas no apoio à inovação em outros setores da economia, utilizando-se de uma base de mais de 2.000 empresas vinculadas aos setores portadores de criatividade de Alemanha. Os resultados da pesquisa mostram que as empresas que operam nesses setores são mais inovadoras do que os demais setores da economia, no ao gasto com P&D e resultado inovativo. Ademais, os resultados das estimações indicaram que tais empresas são intensivas em interação e cooperação, de modo que seus esforços inovativos contribuem para os processos inovativos dos setores com os quais interage, sobretudo, no segmento de tecnologia da inovação. As evidências empíricas do trabalho revelam que as indústrias criativas não são um setor homogêneo, de fora que as características setoriais limitam o impacto das empresas sobre a inovação industrial.

Stoneman (2010) analisou o papel da incerteza na implementação de inovações em setores portadores de criatividade da indústria de alimentos, farmacêutica e em serviços financeiros, comparando ao desempenho da indústria tradicional. Os resultados apontaram para um padrão de inovação, incorporação e difusão de baixo impacto, cujas principais características do resultado inovativo residem em estética ou conteúdo intelectual incorporado. No entanto, é possível observar uma inovação flexível abrangente em alguns setores específicos, refletida nos lançamentos de novos produtos que não refletem a funcionalidade alterada. Esse resultado foi especialmente prevalente na indústria de fármacos. Neste estudo, verificou-se que no mercado de genéricos, por exemplo, grande parte das inovações estão associadas a softwares de amparo a produção do que em termos de produtos farmacêuticos. Essas evidências sugerem que setores portadores de criatividade promovem menos inovações disruptivas do que a indústria tradicional, mas a taxa de inovação incremental e de inovações menos sofisticadas demonstraram-se superior nesses setores, que são mais dinâmicos.

Machado, Simões e Diniz (2013) procuraram verificar a existência de aglomerações setoriais de indústrias criativas no Brasil. Foram encontrados seis clusters, sendo três deles bem definidos setorialmente, enquanto os demais apresentaram-se difusos e heterogêneos. No geral, observou-se que as características regionais foram relevantes na determinação do comportamento setorial da indústria e que os aspectos institucionais do mercado afetam os agrupamentos criativos.

O trabalho desenvolvido por Boix, Hervás-Oliver; Miguel-Molina (2015) encontra evidências empíricas de que os clusters de indústrias criativas, especialmente os maiores, tendem a compartilhar o espaço com outros clusters formados por outros setores da indústria criativa. Nesse sentido, os resultados apontam que as redes urbanas de grande parte dos países europeus analisados são formadas por um grande número de clusters criativos sobrepostos, que, segundo os autores, são alimentados por uma gama complexa de economias de localização e urbanização, externalidades de variedade internas ao local e outras economias externas decorrentes de sinergismo, redes complementares e clusters vizinhos. Esses resultados sugerem que sistemas setoriais de inovação subsidiam e sustentam a formação dessas aglomerações.

Benghozi e Salvador (2016) procuraram identificar a existência de padrões inovativos com base no esforço inovativo

de P&D em setores portadores de criatividade conexos com a produção de livros e materiais de circulação digital em formato de texto. Utilizando-se de análise multidimensional os autores reportaram a existência de 4 padrões: empresas baseadas em sistemas operacionais, que abriga empresas focadas na produção e publicação de livros, cuja esforço de P&D reside em tecnologia de tinta eletrônica e displays de papel eletrônico; empresas baseadas em hardware e em tecnologia de terminais, com foco no desenvolvimento de tecnologias de impressão digital e a plataformas que suportam o a comercialização de livros para tablets, leitores eletrônicos e assistentes pessoais digitais; empresas de software, que dedicam-se ao desenvolvimento de tecnologias de informação de suporte ao mercado editorial; empresas de infraestruturas e redes, cujo resultado das inovações residem na direção organizacional e marketing, com novos modelos de comercialização; empresas fornecedoras de equipamentos capazes de suportar outros formatos de publicações (braile e audiovisual). Finalmente, os resultados da pesquisa indicaram que o maior esforço inovativo em P&D acompanha o grau de intensidade tecnológica das empresas, o que reforçou os padrões setoriais.

Protogerou, Kontolaimou e Caloghirou (2017) examinaram o desempenho de 4.000 empresas distribuídas em 10 países europeus, de forma a captar diferenças nos indicadores de inovação de empresas criativas e tradicionais. Os resultados sugerem que as empresas criativas superam as que empresas dos setores tradicionais da economia, tanto em termos de inovação de produto, quanto na intensidade do esforço inovativo em PD. A análise empírica também sugere que o capital humano dos fundadores, bem como as características específicas da empresa, desempenha um papel significativo na atividade inovadora das empresas criativas. As habilidades criativas dos trabalhadores (*skill*) também apresentou efeito positivo sobre o resultado inovativo das empresas.

Cavalcante e Avellar (2021) analisaram a composição e organização setorial da indústria criativa brasileira a partir da estrutura produtiva, tecnológica e ocupacional. Os resultados mostraram que a indústria criativa brasileira apresenta diferenças setoriais em função do tipo de criatividade – cultural, científica e tecnológica – inserida como capacidades em seu processo produtivo. Entre os padrões inovativos identificados, destacou-se os setores intensivos em escala, em mão de obra/criatividade cultural, em tecnologia/bens de capital e em criatividade científica.

Em sua maioria, os resultados elencados nesse conjunto de trabalhos empíricos convergem para evidências que apontam que as características e o desempenho econômico das empresas, bem como as características do pessoal ocupado influenciam a organização setorial da indústria criativa, conformando padrões setoriais específicos em razão dessas características, o que fornece subsídio a escolha das variáveis para a análise da complexidade do resultado inovativo pretendida nesse artigo.

3 Metodologia

3.1 Recorte setorial e base de dados

Na literatura internacional não existe consenso sobre quais setores pertencer as indústrias criativas ou culturais (Flew e Cunningham, 2010). No entanto, há argumentos favoráveis à inclusão de atividades econômicas intensivas em criatividade científica e tecnológica em setores com alto potencial de crescimento (Mangematin, Sapsed e Schübler, 2014), que forneçam insumos relevantes para atividades econômicas geradoras de propriedade intelectual, ativos simbólicos e de entretenimento (Cavalcante e Avellar, 2018). Então, para arbitrar o conjunto de setores da indústria criativa brasileira utilizamos como parâmetro a metodologia proposta por Bakhshi, Freeman, e Higgs (2013), em que foram selecionadas atividades intensivas em criatividade, definido pela proporção da força de trabalho qualificada e criativa atuando em dedicação exclusiva em atividades de inovação dentro das empresas. Esse é um critério que dialoga com diversos trabalhos empíricos internacionais, o que auxilia a comparabilidade internacional e a discussão das evidências encontradas para o caso do Brasil.

Para estratificar o conjunto de empresas vinculadas à indústria criativa brasileira foram considerados 12 conjuntos de setores econômicos: artes e criação artística, artesanato e produção de artefatos, audiovisual, biotecnologia, cosmético e beleza, design, engenharia e arquitetura, moda, publicação, publicidade e serviços relacionados, serviços criativos personalizados, software, games, aparelhos e plataformas digitais, recreação e lazer. A seleção das atividades que compõem cada setor criativo ponderou aspectos exploratórios relacionados a Classificação Nacional da Atividade Econômica (CNAE) dentro da base de dados: a) existência de registros de ativos simbólicos na Fundação Biblioteca Nacional (FBN) na CNAE; b) existência de registro de propriedade intelectual no Instituto Nacional de Propriedade Intelectual (INPI) na CNAE; c) compatibilidade com as taxonomias da indústria criativa; e, d) relação com cultura.

O exercício empírico realizado neste artigo foi operacionalizado com dados da Pesquisa Brasileira de Inovação (PINTEC), referentes às edições de 2011 e 2014, publicadas pelo Instituto Brasileiro de Geografia e Estatística (IBGE), obtida por tabulação especial. A edição de 2011 se compreende o período de 2009-2011, enquanto a edição de 2014

corresponde à 2012-2014. As variáveis extraídas da PINTEC foram categorizadas em quatro dimensões do comportamento inovativo: 1) resultado inovativo; 2) esforço inovativo; 3) conhecimento e aprendizado; e, 4) trajetória tecnológica (Quadro 1). A dimensão resultado inovativo agrupa as variáveis de resultado, ou seja, as variáveis dependentes do modelo computacional estimado, enquanto as variáveis das demais dimensões correspondem as variáveis independentes, as quais foram subgrupadas pelo grau de importância (baixa, média e alta) atribuído pelas empresas.

Quadro 1 - Descrição das variáveis e indicadores utilizados na pesquisa - PINTEC

Indicador inovativo		Descrição
Resultado	RECEITAref	Proporção de receita líquida de vendas acima da média setorial.
	RI_MKT	Proporção de empresas que inovaram em <i>marketing</i> .
	RI_ORG	Proporção de empresas que realizaram inovações organizacionais.
	RI_PROC	Proporção de empresas que inovaram em processos.
	RI_PROD	Proporção de empresas que inovaram em produtos
Esforço	IN_P&D	Dispêndios em P&D/Receita líquida de vendas (RLV).
	IN_P&DEXT	Dispêndios com aquisição externa de P&D/ RLV.
	IN_CONHECIMENTOEXT	Dispêndios com aquisição de outros conhecimentos/RLV.
	IN_MEQP	Dispêndios com aquisição de máquinas e equipamentos/RLV.
	IN_TREI	Dispêndios com treinamento/RLV.
	IN_MKT	Dispêndios com introdução de inovações no mercado/RLV.
	IN_D&E	Dispêndios em projetos industriais e outras preparações técnicas/RLV.
Conhec. e aprendizado	CA_TACITO	Relevância de contatos com outras empresas do grupo, clientes, fornecedores, concorrentes, clientes, feiras e/ou eventos, etc.
	CA_CODIFICADO	Relevância de fontes formais de produção de conhecimento (centros de capacitação profissional, assistência técnica, institutos de testes, ensaios e afins).
	CA_PESQUISA	Relevância do departamento interno de P&D.
	CA_INTERACAO	Relevância da interação com redes de informações empresariais.
	CA_SUBCONTRATAcao	Relevância de empresas de consultoria para inovação.
	CA_UNIVERSIDADE	Relevância à interação com universidades e centros de pesquisa.
	CA_SKILL	Proporção de mestres e doutores em dedicação exclusiva na P&D.
Trajetória tecn.	TT_CUSTO	Relevância de inovações que reduzem custos de produção.
	TT_CAPACIDADE	Relevância de inovações que aumentam a capacidade produtiva.
	TT_FLEX	Relevância de inovações que flexibilizam a produção.
	TT_NMERCADOS	Relevância de inovações que permitem a abertura de novos mercados.
	TT_AMBIENTAL	Relevância de inovações que reduzem os impactos ambientais.
	TT_NORMAS	Relevância às inovações que permitem a adaptação a normas reguladoras.
Financ. público	FI_FISCAL	Proporção de empresas que receberam incentivos fiscais à P&D e inovação.
	FI_SUBVENCAO	Proporção de empresas que receberam subvenção econômica à P&D e inovação.
	FI_P&D	Proporção de empresas que receberam financiamento para P&D e inovação.
	FI_FINECLUSIV	Proporção de empresas que receberam financiamento para a compra de máquinas e equipamentos utilizados em projetos de inovação.
	FI_BOLSAS	Proporção de empresas que receberam bolsas de FAPs e CNPq.
	FI_CAPRISCO	Proporção de empresas que receberam capital de risco como apoio do governo.
	FI_OUTROS	Proporção de empresas que receberam outras formas de apoio público à inovação.

Fonte: Elaborado pelos autores a partir de PINTEC (2014).

3.2 Estratégia Empírica

Para investigar a complexidade do resultado inovativo obtido pelos setores da indústria criativa e identificar as interações mais relevantes para este resultado, adotou-se como estratégia empírica um modelo de rede neural de regressão probabilística não linear. Até onde se sabe, não existem estudos sobre essa temática que utilizam redes neurais artificiais para analisar o comportamento inovativo, o que constitui uma contribuição relevante do artigo. Segundo Haykin (2001), uma rede neural consiste em um algoritmo computacional paralelamente distribuído, que constitui-se de unidades de processamentos simples, as quais possuem propensão natural ao armazenamento de conhecimento

experimental disponível para uso. Este algoritmo possui caráter sináptico, cuja função é modificar os pesos da rede de forma ordenada para que seja possível inferir probabilidades não lineares de relações complexas entre variáveis do estudo.

Essa metodologia que tem como vantagem a capacidade de detecção implícita de relações não-lineares entre múltiplas variáveis dependentes e as variáveis explicativas consideradas como sinapses de aprendizado (Santos et al., 2005). Tais sinapses são representadas por neurônios, isto é, unidades de processamento de informação, as quais denotam os elos de conexão entre as variáveis incorporadas no algoritmo computacional. Em cada sinapse neurológica do modelo têm-se um peso (pode ser cumulativo) que se desdobra sobre toda extensão da rede. Especificamente, um sinal x_j na entrada da sinapse i conectada ao neurônio k é multiplicada pelo peso sináptico w_{kj} . Nesse caso, a estrutura da rede interliga um componente somatório, responsável por somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio; e, uma função de ativação, responsável por restringir a amplitude da saída de um neurônio, de forma a respeitar um intervalo unitário fechado $[0, 1]$. O bias b_k tem como finalidade aumentar ou diminuir a entrada líquida da função de ativação. Matematicamente, pode-se descrever um neurônio k a partir do seguinte par de equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (2)$$

Onde x_1, x_2, \dots, x_m são sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o bias; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio. o uso do bias b_k tem o efeito de aplicar uma transformação afim à saída u_k do combinador linear do modelo, dado por:

$$v_k = u_k + b_k \quad (3)$$

Assim, dependendo do sinal do bias b_k , a relação entre o campo local induzido ou potencial de ativação v_k do neurônio k e a saída do combinador linear u_k é modificada. Portanto, o bias b_k é um parâmetro externo do neurônio artificial e tem relevância fundamental para os resultados.

Segundo Ferneda (2006), uma rede neural artificial pode ser representada como um grafo de fluxo, em que os nós são os neurônios e as ligações fazem a função das sinapses. Para a interpretação grafológica, são necessários satisfazer três regras: a) um sinal flui ao longo de um elo somente no sentido definido pela seta do elo, de maneira que dois tipos de elos podem ser distinguidos – sinápticos, cujo comportamento é governado por uma relação de entrada-saída linear, onde o sinal nodal x_j é multiplicado pelo peso sináptico w_{kj} para produzir o sinal nodal y_k ; e de ativação, cujo comportamento é governado por uma relação de entrada-saída não linear; b) um sinal nodal é igual a uma soma algébrica de todos os sinais que entram no nó; e, c) o sinal em um nó é transmitido para cada elo de saída originário deste nó, sendo a transmissão inteiramente independente das funções de transferência dos elos de saída contido na rede neural.

Nessa pesquisa será utilizada a arquitetura grafos neurais artificiais em multicamadas. Este algoritmo é baseado na regra de aprendizagem por correção de erros proposta por Widrow e Hoff (1960), que imputam um ajuste ao peso sináptico w_{kj} no de tempo n , definido por:

$$\Delta w_{kj} = \eta e_k(n) x_j(n) \quad (4)$$

Em que η , é uma constante positiva que determina a taxa de aprendizado quando se avança em um passo no processo de aprendizagem, nesse caso, quando outra variável é incorporada como capacidade inovativa do setor. Teoricamente, o ajuste feito em um peso sináptico de um neurônio é proporcional ao produto do sinal de erro pelo sinal de entrada da sinapse em questão. Haverá, desse modo, um conjunto de nós ocultos, responsáveis por distribuir as interações entre as variáveis explicativas e as dependentes, denotando a complexidade da renda pelo peso w_{kj} .

O número de nós na camada de entrada corresponde ao número de variáveis utilizadas para alimentar a rede neural, nesse caso serão utilizados as variáveis contínuas relacionadas à fonte e financiamento da inovação, com a finalidade de expressar a complexidade do resultado inovativo dos setores da indústria criativa, bem como o desempenho da receita líquida, se acima ou abaixo da média nacional dos setores da indústria criativa. Como fatores de comparabilidade

serão utilizados a predominância da base de conhecimento e aprendizado e a trajetória tecnológica mais relevantes para o esforço inovativo, classificadas em alta, média e baixa relevância, conforme resposta atribuída pelo conjunto de firmas do setor.

Fundamentando-se em Murtgath (1994), o número de neurônios ocultos será calibrado através de critérios de ajustamento-penalidade (*complexity-regularization*), que são análogos aos critérios estatísticos *Akaike Information Criterion* (AIC) e *Bayesian Information Criterion* (BIC). Em geral, redes neurais com poucos neurônios ocultos são preferíveis, visto que tendem a gerar um melhor poder de generalização, o que reduz problemas de sobreajuste (*overfitting*). Isto feito, operacionaliza-se a função de ativação dos neurônios, que neste estudo consiste na Função Tangente Hiperbólica, que é definida matematicamente através da seguinte expressão:

$$\varphi(v_j(n)) = [(\alpha \tan h(bv_j(n))), \quad (a, b) > 0 \quad (5)$$

Onde a e b são constantes. Em última instância, a função tangente hiperbólica corresponde a uma função logística reescalada e modificada por um bias, da qual deriva-se em relação a $v_j(n)$:

$$\begin{aligned} \varphi(v_j(n)) &= ab \sec h^2(bv_j(n)) \\ &= ab(1 - \tan h^2(bv_j(n))) \\ &= \frac{a}{b}[a - y_i(n)][a + y_i(n)] \end{aligned} \quad (6)$$

Para um neurônio j localizado na camada de saída, o gradiente local será:

$$\begin{aligned} \delta_j(n) &= \varphi'_j(v_j(n)) \sum_k \delta_j(n) w_{kj}(n) \\ &= \frac{b}{a}[a - y_j(n)][a + y_j(n)] \sum_k \delta_j(n) w_{kj}(n) \end{aligned} \quad (7)$$

Sequencialmente, se procederá à separação do conjunto de dados em dois grupos: conjunto de treinamento e conjunto de teste (Haykin, 2001). Segundo Santos et al. (2005), o primeiro grupo é utilizado para o treinamento da rede e ajuste dos parâmetros do modelo neural, devendo conter um número estatisticamente significativo de setores criativos em estudo, de modo a constituir uma amostra representativa da complexidade do resultado inovativo. Por outro lado, o conjunto de teste é utilizado para verificar a capacidade de generalização da rede. Baseando-se em Smith (1993) foi utilizado o algoritmo treinamento por retropropagação, cujo critério de parada é referenciado pela norma euclidiana do vetor gradiente em menor valor.

Na aplicação do algoritmo de retropropagação, distinguem-se dois passos distintos de programação computacional – propagação (para frente) e retropropagação (para trás). Na propagação, os pesos sinápticos se mantêm inalterados em toda a rede e os sinais funcionais da rede são calculados individualmente, a cada neurônio presente do modelo. Para tanto, o sinal funcional a ser registrado na saída do neurônio j será obtido através da seguinte função:

$$y_j(n) = \varphi_j(v_j(n)) \quad (8)$$

Onde $v_i(n)$ corresponde ao campo local induzido do neurônio j , definido por:

$$(v_j(n)) = \sum_{i=0}^m w_{ij}(n) y_i(n) \quad (9)$$

Em que m é o total de entradas (excluindo o bias) aplicadas ao neurônio j ; $w_{ji}(n)$ é o peso sináptico que conecta o neurônio i ao neurônio j ; $y_i(n)$ é o final de entrada do neurônio j , ou seja, o sinal de saída do neurônio i . Caso o neurônio j estivesse na primeira camada oculta da rede, $m=m_0$ e o índice i se refere ao i -ésimo terminal de entrada da rede, para o qual formaliza-se:

$$y_j(n) = o_j(n) \quad (10)$$

Em que $o_j(n)$ é o j -ésimo elemento do vetor padrão de saída. Esta saída é comparada com a resposta desejada $d_j(n)$, obtendo o sinal de erro $e_j(n)$ para o j -ésimo neurônio de saída. Assim, a fase de propagação do algoritmo inicia-se

na primeira camada oculta do modelo, sendo finalizada na camada de saída. De maneira contrária, a retropropagação inicia-se na camada de saída, cujos sinais de erro são transferidos à esquerda da arquitetura multicamadas da rede, em que, de forma recursiva, calcula-se o gradiente local δ de cada neurônio. Este processo recursivo permite que os pesos sinápticos obedeçam a regra de Widrow-Hoff (equação 4), cuja operacionalização matemática-computacional do algoritmo expressa-se pela seguinte equação:

$$\delta_j(n) = \varphi_j(v_j(n)) \sum_k (n) w_{kj}(n) \quad (11)$$

Nesse caso, j corresponde ao neurônio oculto; e, o fator $[(\phi')_j]_j (v_j(n))$ envolvido no cálculo do gradiente local $\delta_j(n)$ depende unicamente da função de ativação associada ao neurônio oculto j , conforme equação 2. O segundo conjunto de termos, $w_{kj}(n)$, consiste nos pesos sinápticos (SIMONTON, 2001). Esses procedimentos identificaram o grau de sensibilidade do nível de receita e do resultado inovativo ao conjunto de interações complexas observadas no modelo, bem como indicar a importancia normalizada das variáveis.

4 Análise dos resultados

Nesse estudo, procurou-se investigar como o armazenamento e a interação entre as capacidades vinculadas a absorção de fontes internas e externas de inovação e o acesso a mecanismos de financiamento impactaram o resultado inovativo dos setores da indústria criativa, bem como o nível de receita líquida registrado setorialmente. A análise foi operacionalizada por uma rede neural artificial, cujo algoritmo computacional processou 25 casos setoriais, sendo 20 treinamentos e 5 testes. Os testes representam os setores criativos mais representativos quanto as regularidades estatísticas do resultado inovativo, mediante simulação computacional realizada.

Dentre a amostra, foram excluídos 1 setor, por não apresentarem predição significativa. Também foi excluída das interações computacionais a variável CA_PESQUISA, por ter apresentado uma tendência linear nas interações, não sendo relevante à amostra de simulação. Desse modo, o modelo foi sumarizado em 49 unidades de processamento e 12 camadas ocultas. Quanto maior o número de camadas ocultas, maior o número de interações sinápticas, ou seja, maior o conjunto de combinações de capacidades que complexificam o resultado inovativo setorial. No caso da indústria criativa brasileira, a existência de 12 camadas sugere pouca complexidade.

A Tabela 1 sumariza os resultados rede neural das amostras de treinamento e teste. Inicialmente, apresenta-se a soma dos quadrados do erro para a amostra de treinamento e de teste. Esses resultados são reportados devido a existência variáveis dependentes contínuas (RLMKT, RLORG, RLPROC e RLPROD). Nesse caso, durante o treinamento, o modelo foi calibrado para minimizar a função de erro da rede neural. A partir desse procedimento, a soma dos quadrados e todos os demais valores de erro foram calculados para os valores redimensionados das variáveis dependentes. Por isso, o resultado consiste em uma medida de discrepância entre os dados observados e a estimativa da simulação computacional. Nota-se que na amostra de teste, responsável por reportar a capacidade de generalização dos resultados, o erro foi menor (5,8078) em comparação a amostra de treinamento (8,7490), o que indica que entre os 5 setores da indústria criativa mais representativos, obteve-se um menor desvio das observações em torno da média.

No geral, o erro relativo médio geral e os erros relativos das variáveis RLMKT, RLORG, RLPROC e RLPROD foram razoavelmente constantes nas amostras de treinamento e teste, o que permite rejeitar a hipótese de sobrecarga do modelo (Tabela 1). Contudo, os resultados sumarizados indicam que as inovações organizacionais (RLORG) são mais difíceis de generalização dos resultados. Os dados também indicam que o percentual de previsões incorretas em relação a variável categórica RECEITARf é igual para a amostra de treinamento e para a amostra de teste (20%). Isto representa os ajustes dos parâmetros estimados (treinamento) e a capacidade de generalização do modelo (teste) são compatíveis. Esses resultados concedem robustez ao modelo.

Com a finalidade de avaliar se o conjunto de previsões gerado pelo modelo apresenta resultados satisfatórios sobre a variável dependente categórica do resultado inovativo (RECEITARf), realizou-se a classificação dos setores da indústria criativa, cujos resultados estão descritos na Tabela 2. A classificação mostra os resultados práticos do uso da rede neural estimada. Para cada setor, a receita líquida encontra-se ACIMA da receita líquida média de toda a indústria criativa se a pseudo-probabilidade prevista nesses setores for maior que 0,5. Dos 25 setores usados para criar o modelo, 9 deles apresentaram um nível de receita líquida superior à média indústria criativa, com 100% dos setores classificados corretamente. Por outro lado, 7 dos setores com receita líquida ABAIXO foram classificados corretamente. No geral, 80% dos casos de treinamento foram classificados corretamente, o que satisfaz o critério de inferência de Haykin (2001). Este mesmo percentual é observado pela classificação da amostra de teste, o que indica um ajuste satisfatório

de previsão.

A avaliação do grau de correção da classificação preditiva do modelo também pode ocorrer por meio de uma análise gráfica em boxplots. Em estatística descritiva, o boxplot é uma ferramenta que permite representar a variação amostral de um conjunto de dados por meio de quartis, sem que haja qualquer suposição da distribuição estatística subjacente aos dados. Como existem apenas duas variáveis de resposta, a região superior do gráfico abriga 50% de predição. Portanto, a parte acima da marca 0,5 no eixo y representa às previsões corretas mostradas na Tabela 2.

A parte situada na região inferior a 0,5 corresponde às previsões incorretas. Na Figura 2 são apresentados quatro boxplots. O primeiro boxplot mostra a classificação dos setores da indústria criativa que tiveram uma receita líquida ABAIXO da RECEITArf, dos quais a previsão obtida pelo modelo foi adequada, cuja área na parte superior do gráfico corresponde a 63,6% de asserção.

O segundo *boxplot* mostra os casos onde os dados da amostra de treinamento mostram que os setores tiveram uma receita líquida ABAIXO da RECEITArf, mas a previsão foi contrária, o que denota 36,6% de predição incorreta. O terceiro boxplot relaciona os casos em que os dados mostraram receita líquida ACIMA da RECEITArf, mas a previsão indicou um comportamento contrário. Nota-se que neste caso toda a área do gráfico está abaixo da linha de referência, o que denota 0% de predição incorreta. Semelhantemente, o quarto *boxplot* indica que 100% das previsões foram classificadas corretamente, pois toda a área do gráfico está acima da linha de referência, o que confirma que todos os casos foram compatíveis.

Em resumo, em relação a amostra de treinamento, os dois primeiros *boxplots* indicam a ocorrência de discrepância em relação ao efeito de interações complexas nas fontes de inovação e mecanismos de financiamento sobre o desempenho setorial da receita. Os resultados indicam que diminuir o intervalo de corte pode aumentar a probabilidade de se capturar um maior número de relações complexas, mas com baixa previsibilidade sob a receita. No geral, o percentual de classificação do modelo demonstrou-se satisfatório nas amostras (65% e 60%).




Figure 1: Pseudo probabilidade prevista da complexidade sobre a receita de referência
Fonte: Elaborado pelos autores.

Quando analisado os processos sinápticos relacionados a complexidade do resultado inovativo dos setores da indústria criativa brasileira, obteve-se uma rede neural com 12 camadas ocultas. A saída, isto é, o resultado inovativo, com os maiores números de interações sinápticas positivas corresponde a variável RECEITArf=Abaixo, com 10 interações (Anexo 1). Esse número é observado pelas linhas cinzas do diagrama reproduzido na Figura 3, cujas relações sinápticas foram positivas, denotando a existência de interações entre as capacidades.

Este resultado indica que a obtenção de uma receita líquida abaixo da média de toda a indústria criativa encontra-se interconectada a um conjunto de camadas ocultas (Bias, H1:2, H1:3, H1:4, H1:6, H1:7, H1:8, H1:10, H1:11 e H1:12), conforme Tabela 3. Essas camadas são responsáveis por agrupar as interações entre as variáveis de entrada (esforço inovativo, conhecimento e aprendizado, trajetória tecnológica e financiamento à inovação) que foram determinantes para que a receita líquida dos setores da indústria criativa se situasse abaixo do valor de referência. Portanto, tais camadas ocultas correspondem ao peso que cada interação entre variáveis de entrada desempenhou sobre o resultado inovativo da receita líquida.

Desse conjunto de camadas ocultas, aquela que apresentou maior capacidade de afetar o resultado inovativo da

receita líquida dos setores da indústria criativa corresponde ao neurônio H1:10, cujas interações sinápticas agrupadas aumentam a probabilidade de um setor criativo obter uma receita líquida abaixo da média de toda a indústria criativa em 42,20%. Esse resultado sugere que ampliar o número de combinações de distintas capacidades inovativas não melhora as chances de uma empresa alcançar uma receita líquida setorial superior à média setorial. É possível, desse modo, que uma empresa faça uso de diferentes fontes internas e externas de inovação, mas de forma ineficiente, de tal modo que não seja capaz de absorver as tecnologias mais eficientes da indústria.

De acordo com a Tabela 4, pode-se verificar que 34 variáveis de entrada apresentaram interações e estiveram conectadas a camada oculta H1:10, sendo as variáveis IN_MEQP, TT_AMBIENTAL=Média, CA_CODIFICADO=Baixa, TT_FLEX=Baixa, TT_NORMAS=Baixa aquelas que apresentaram maiores coeficientes de impacto de interação. Nesse caso, a complexidade do resultado inovativo vinculado à variável RECEITARf tende a ser afetada pela alta concentração dos investimentos em máquinas e equipamentos, se comparado a outros esforços inovativos, como IN_P&D, cujo coeficiente foi 49% menor. Cavalcante e Avellar (2021), a partir de outro enfoque metodológico, já haviam identificado uma relação entre essas variáveis no que se refere ao comportamento inovativo dos setores criativos brasileiros. No entanto, o resultado diverge das evidências internacionais, que apontam o P&D interno como um aspecto central do desempenho da indústria criativa em termos de implementação de inovações. É o caso do Reino Unido, em que atividades de PD estão associadas a setores mais complexos (Bakhshi e Mcvittie, 2009) e da Alemanha, cuja complexidade do esforço inovativo supera determinados setores tradicionais da indústria (Müller et al., 2009).

Também se observa que a necessidade de redução de impacto ambiental contribui para a complexidade observada (TT_AMBIENTAL). Isso porque as inovações devem apresentar uma trajetória aderente à demanda ou às normas e regulações institucionais, que consistem em mecanismos de seleção e difusão do produto criativo. Setores criativos ligados a engenharia e arquitetura do patrimônio histórico, beleza e perfumaria, insumos para produção têxtil, produção de artesanato e artefatos a base de recursos naturais, que estão sujeitas a normas legais, geralmente, formam clusters e redes setoriais de compartilhamento. Machado et al. (2013) encontraram evidências acerca da formação desse tipo de *cluster* para o Brasil. Em estudo que analisou 16 países da Europa, Boix et al. (2015) apontaram que esse tipo de *cluster* é alimentado por uma gama complexa de economias de localização e urbanização, externalidades de variedade internas ao local e outras economias externas decorrentes de sinergismo, redes complementares e clusters vizinhos. Apesar de utilizarem uma abordagem analítica diferente, as evidências desses autores fornecem *insights* relevantes para compreender como aspectos institucionais atuam na complexidade inovativa setorial.

Atuar em determinadas trajetórias tecnológicas exige das empresas esforços capazes de minimizar as incertezas do processo inovativo, bem como estratégias adaptativas aos condicionantes impostos pela trajetória tecnológica operada pela empresa, de maneira que os investimentos de curto prazo compensem o esforço inovativo empreendido. Nesse caso, é possível que as firmas que atribuem média importância a trajetória de impacto ambiental concentrem seus esforços na aquisição de bens de capital capazes de minimizar a geração de resíduos, por exemplo. Entretanto, um esforço inovativo desta natureza associado a um baixo grau de conhecimento codificado pode não gerar as capacidades dinâmicas necessárias à absorção da tecnologia, o que resulta em ganhos de receita inferiores ao esperado.

Conforme a Tabela 4, também se verifica que a baixa codificação da base de conhecimento e aprendizado existente nos setores da indústria criativa impacta inversamente a RECEITARef. Este resultado sugere que a baixa importância atribuída a fontes formais de conhecimento no processo de aprendizado das empresas, em associação com as demais variáveis, implica em uma receita menor. Destaca-se que o nível de sofisticação da base de conhecimento é importante para a construção de aptidões dinâmicas e organizacionais no âmbito da firma, o que as tornam mais suscetíveis à apropriabilidade do conhecimento e, concomitantemente, à implementação de inovações, conforme explicação de Nelson (2006) para as diferenças existentes entre empresas.

A simulação evidencia que empresas que operam em uma trajetória de baixa de flexibilidade produtiva reduzem a complexidade do resultado inovativo. Este resultado chama a atenção para a relevância da eficiência produtiva como essencial para o êxito do processo inovativo. O próprio processo de aprendizado, que não garante *ex-ante* o sucesso de uma inovação, pode ampliar a estrutura de custos das firmas, conforme Malerba (1992). Desse modo, faz-se necessário que as firmas atenuem o impacto desses custos, com uma maior flexibilidade produtiva.

Ainda de acordo com a Tabela 4, pode se constatar que entre os quatro tipos de inovações analisados, as inovações organizacionais (RI_ORG) corresponderam ao resultado inovativo com maior número de interações sinápticas positivas (9). Esse número de relações é igualmente observado nas linhas cinzas conectadas ao conjunto de camadas ocultas da rede (Bias, H(1:1), H(1:2), H(1:4), H(1:5), H(1:8), H(1:9), H(1:10), H(1:12)), conforme a Figura 3. Desse conjunto de camadas ocultas, aquela que apresentou maior capacidade de afetar a implementação de inovações organizacionais nos setores da indústria criativa corresponde ao neurônio H1:2, cujas interações sinápticas aumentam em 57,7% a probabilidade de um setor portador de criatividade implementar inovações dessa natureza.

A Tabela 4 reporta que as variáveis IN_CONHECIMENTOEXT, IN_PD, CA_SKILL=Baixa e IN_TREI foram as mais relevantes para definir o peso sináptico do neurônio H1:2, que afeta diretamente a implementação de inovações organizacionais. Nesse caso, a complexidade do resultado inovativo vinculado a variável RI_ORG tende a ser explicada, sobretudo, pelo esforço inovativo das empresas em dinâmicas de aprendizado. Das variáveis de esforço inovativo vinculadas à fonte de inovação das empresas, constatou-se que os dispêndios com aquisição de conhecimentos externos através da contratação de projetos de P&D e a geração de P&D interna foram as mais relevantes. Esses processos de P&D podem auxiliar a empresa a desenvolver habilidades para introduzir novos processos entre suas rotinas, o que afeta diretamente da gestão organizacional.

Esses resultados são aderentes as definições de inovação organizacional de Cohen e Levinthal (1989), em que a aplicação de conhecimentos assimilados durante o processo de P&D podem resultar em oportunidades tecnológicas capazes de sustentar o aperfeiçoamento ou a captura de novas capacidades empresariais. É possível que as inovações organizacionais implementadas nos setores da indústria criativa possam seguir tanto a direção inter-organizacional, em que a cooperação em projetos de P&D resultem na formação de redes ou *offshoring*, como intra-organizacional, cujas inovações ser *just-in-time* ou gestão da cadeia de insumos criativos. Benghozi e Salvador (2016) observaram que em setores criativos digitais, o comportamento inovativo é fortemente afetado pela combinação desse tipo de variável, cujo resultado das inovações residem na direção organizacional e marketing, com novos modelos de comercialização.

Outro aspecto relevante para a complexidade das inovações organizacionais consiste nas habilidades dos trabalhadores (CA_SKILL e IN_TREI). Este é um resultado esperado e condizente com as evidências registradas na literatura. Diversos estudos apontam os programas de treinamento e as habilidades como preponderantes para a constituição de uma “classe criativa” de profissionais capazes de conduzir a implementação de inovações setoriais. Nesse linha, destacam-se os resultados dos trabalhos de Cavalcante e Avellar (2021) para o Brasil; Protogerou et al. (2017) para 10 países europeus; e, Chaston (2008), Bakhshi e McVittie (2009) para o Reino Unido.

Outro importante resultado obtido pela análise de redes neurais consiste na baixa complexidade do resultado inovativo, em termos da implementação de inovações de produto (RI_PROD), que apresentou apenas 7 interações sinápticas com as camadas ocultas. Contudo, para identificar as interações que contribuíram para a baixa complexidade, optou-se por discutir as 6 relações sinápticas negativas ligadas aos neurônios H(1:1), H(1:2), H(1:5), H(1:8), H(1:9) e H(1:11), conforme a Tabela 4 e a Figura 3. Desses, o neurônio H(1:8) apresentou o maior peso negativo (76,3%) para interações ocorridas entre 21 variáveis de entrada.

Com base na Tabela 4, é possível perceber que as variáveis que mais contribuíram para a baixa complexidade do resultado inovativo correspondente a implementação de inovações de produto nos setores da indústria criativa são FI_BOLSAS, CA_CODIFICADO=Baixa, TT_FLEX=Baixa, CA_INTERACAO=Baixa e IN_D&E. Esses resultados sinalizam que o financiamento à inovação a partir de bolsas de pesquisa na empresa importou para a baixa complexidade da variável RI_PROD. É possível que este tipo de política de fomento não tenha apresentado resultados satisfatórios para os setores da indústria criativa, talvez por suas atividades não terem relação direta com projetos de P&D. Políticas dessa natureza deveriam criar mecanismos de contratação dos bolsistas e melhor atrelar a bolsa às atividades técnicas.

Ademais, verificou-se que a baixa importância atribuída a codificação do conhecimento, da flexibilidade produtiva e da interação também foram relevantes para este resultado. Essa evidência aponta que a pouca sistematização dos processos de aprendizado no interior das empresas, associada com ao baixo desenvolvimento de capacidades empresariais contribui para o baixo grau de complexidade das inovações de produto implementadas. Também se aponta que a terceirização dos esforços inovativos pela aquisição de projetos industriais e outras preparações técnicas contribui para o baixo grau de complexidade identificado na rede neural. Este resultado ajuda a explicar o baixa participação das inovações de produto no resultado inovativo verificado na análise anterior em divergência a evidência de Lee e Drever (2013).

Por meio da Figura 4 é possível identificar as variáveis explicativas mais importantes para determinar o grau de complexidade do resultado inovativo dos setores da indústria criativa da economia brasileira, no conjunto das variáveis RECEITA_{rf}, RI_MKT, RI_ORG, RI_PROC e RI_PROD. A importância de uma variável independente é uma medida de quanto o valor previsto pelo modelo estimado por rede neural muda para os diferentes valores apresentados pela variável independente em cada caso setorial analisado (Tabela 4).

para um padrão inovativo de baixo impacto, em que a complexidade do resultado inovativo pode estar associada ao porte das empresas e a competição setorial, para além das sinapses internas.

No geral, a inovação organizacional demonstrou-se mais complexa, dentre as analisadas. Contribuíram para esse resultado o desenvolvimento de P&D interno, bem como a formação de uma base de conhecimento codificado advindas de cooperação com outros atores do sistema setorial de inovação e a qualificação dos trabalhadores envolvidos com os projetos de inovação. Esse resultado é convergente com os padrões inovativos reportados na literatura, estando vinculado, especialmente, aos setores criativos que se utilizam da criatividade científica para inovar.

Outro resultado interessante corresponde a baixa complexidade das inovações de produtos implementadas na indústria criativa, cujas interações originárias, apesar de demonstrarem um certo grau de sofisticação, são essencialmente externas à firma. As interações sinápticas detectadas sugerem que a baixa flexibilidade organizacional se constitui em um elemento crítico para a difusão de novos produtos no mercado. Finalmente, é possível destacar que a complexidade do resultado inovativo na indústria criativa é fortemente sensível ao desenvolvimento de P&D interno, bem como o acesso a programas de apoio público à inovação, compatível com as evidências internacionais.

Os estudos industriais com redes neurais ainda são incipientes, sobretudo, na indústria criativa. No entanto, os resultados gerados por esse procedimento empírico podem ser usados para explorar as estratégias relevantes para a mudança das condições inovativas das empresas, com base na identificação das interações e combinações de capacidades importantes para se operar determinadas trajetórias tecnológicas. Ademais, a simulação realizada fornece *insights* relevantes aos formuladores de políticas, pois apontam o peso que determinados programas de apoio público à inovação fornecem para a complexidade do resultado inovativo setorial. Apesar de estatisticamente robustos, os resultados devem ser analisados com cautela, em decorrência da limitação da base de dados, que permitiu o desenvolvimento de uma aplicação em nível setorial. Em estudos futuros, expandir a pesquisa para o nível da firma poderá melhorar a compreensão sobre a complexidade da indústria criativa. No futuro, a comparação das simulações com métodos paramétricos também é desejável.

Referências

- ALLEN, P. M. A Complex Systems Approach To Learning in Adaptive Networks. *International Journal of Innovation Management*, v. 05, n. 02, p. 149–180, 2001.
- ANDRIANI, P. et al. Innovation systems by nonlinear networks. *Nonlinear Dynamics*, v. 44, n. 1–4, p. 263–268, 2006.
- ARTHUR, U. B. The theory of complexity in economics: other foundations of economic thinking. *Terra Economicus*, v. 13, n. 2, p. 15–37, 2015.
- BAKHSHI, H.; FREEMAN, A.; HIGGS, P. *A Dynamic Mapping of the UK's Creative Industries*. Londres: NESTA, January, 2013.
- BAKHSHI, H.; MCVITTIE, E. Creative supply-chain linkages and innovation: Do the creative industries stimulate business innovation in the wider economy? *Innovation: Management, Policy and Practice*, v. 11, n. 2, p. 169–189, 2009a.
- BENGHOZI, P. J.; SALVADOR, E. How and where the R&D takes place in creative industries? Digital investment strategies of the book publishing sector. *Technology Analysis and Strategic Management*, v. 28, n. 5, p. 568–582, 2016.
- BOCCARDELLI, P. Creative Industrie. In: *The Palgrave Encyclopedia of Strategic Management*. London, UK: Palgrave Macmillan UK, 2016. p. 2016.
- BOIX, R.; HERVÁS-OLIVER, J. L.; MIGUEL-MOLINA, B. DE. Micro-geographies of creative industries clusters in Europe: From hot spots to assemblages. *Papers in Regional Science*, v. 94, n. 4, p. 753–772, 2015.
- CAVALCANTE, T.; AVELLAR, A. P. M. DE. Indústria criativa: um survey da produção científica indexada em uma abordagem meta-fatorial. III Encontro de Economia Industrial e Inovação. *Anais*. São Paulo, SP: Bluche, 2018.
- Padrões inovativos na indústria criativa: evidências setoriais para o BrasilAnpec. *Anais*. Brasília, DF: ANPEC, 2020.
- Padrões Setoriais Da Indústria Criativa Brasileira. V EVncontro Nacional de Economia Industrial e

Inovação. *Anais*. Belo Horizonte, MG: ABEIN, 2021.

CAVES, R. E. *Creative industries: Contracts between art and commerce*. New York, NY: Harvard University Press, 2000.

CHASTON, I. Small creative industry firms: A development dilemma? *Management Decision*, v. 46, n. 6, p. 819–831, 2008.

CUNNINGHAM, S. From cultural to creative industries: theory, industry and policy implications. *International Journal of Cultural Studies*, v. 9, n. 3, p. 317–331, 2002.

DCMS. *Creative industries mapping document*. London, UK: DCMS, UK Government., 1998.

DOSI, G. Sources , Procedures , and Microeconomic Effects of Innovation. *Journal of economic literature*, v. 26, n. 3, p. 1120–1171, 1988.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. *Ciencia da Informação*, v. 35, n. 1, p. 25–30, 2006.

FIANI, R. Teoria dos custos de transação. In: KUPFER, D.; HASENCLEVER, L. (Eds.). *Economia Industrial*. 2. ed. Rio de Janeiro, RJ: Elsevier, 2013. p. 171–181.

FLEW, T. Defining Creative Industries International Conference on Cultural Policy Research. *Anais*. Wellington, New Zealand.: Queensland University of Technology Paper, 2002.

FLEW, T.; CUNNINGHAM, S. Creative industries after the first decade od debate. *The information society*, v. 26, n. 2, p. 113–123, 2010.

FOSTER, J. From simplistic to complex systems in economics. *Cambridge Journal of Economics*, v. 29, n. 6, p. 873–892, 2005.

GALA, P. *Complexidade econômica*. Rio de Janeiro, RJ: Contraponto, 2017.

GALUK, M. B. et al. Innovation in Creative Economy Micro-Enterprises: a Multiple Case Study. *RAM. Revista de Administração Mackenzie*, v. 17, n. 5, p. 166–187, 2016.

HARTLEY, J. *Creative industries*. Oxford: Blackwell Publishing, 2005.

HAYKIN, S. *Redes neurais: princípios e prática*. 2. ed. Porto Alegre, RS: Bookman, 2001.

HOWKINS, J. *The Creative Economy: How People Make Money from Ideas*. London, UK: Penguin Books, 2013.

JEFFCUTT, P. Management and the creative industries 1. *Studies in Cultures, Organizations and Societies*, v. 6, n. 2, p. 123–127, 2000.

LAZZERETTI, L.; BOIX, R.; CAPONE, F. Do creative industries cluster? Mapping creative local production systems in Italy and Spain. *Industry and Innovation*, v. 15, n. 5, p. 549–567, 2008.

LEE, N.; DREVER, E. The Creative Industries, Creative Occupations and Innovation in London. *European Planning Studies*, v. 21, n. 12, p. 1977–1997, 2013.

MACHADO, A. F. et al. Creative Industries in Brazil: Analysis of Specifics Cases for a Country in Development. *Theoretical Economics Letters*, v. 08, n. 07, p. 1348–1367, 2018.

MACHADO, A. F.; SIMÕES, R. F.; DINIZ, S. C. Urban Amenities and the Development of Creative Clusters: The Case of Brazil. *Current Urban Studies*, v. 01, n. 04, p. 92–101, 2013.

MACLEAN, D. Dynamic Capabilities, Creative Action, and Poetics. *Revista de Administração de Empresas*, v. 57, n. 3, p. 264–272, 2017.

MALERBA, F.; ORSENIGO, L. Technological Regimes and Sectoral Patterns of Innovative Activities. *Industrial and Corporate Change*, v. 6, n. 1, p. 83–118, 1997.

MANGEMATIN, V.; SAPSED, J.; SCHÜBLER, E. Disassembly and Reassembly: An Introduction to the Special Issue on Digital Technology and Creative Industries. *Technology Forecasting and Social Change*, v. 83, p. 1–9, 2014.

MOLINA, B. DE M.; HERVÁS-OLIVER, J. L.; BOIX, R. D. Understanding innovation in creative industries: knowledge bases and innovation performance in art restoration organisations. *Innovation: Organization and*

- Management*, v. 21, n. 3, p. 421–442, 2019.
- MÜLLER, K.; RAMMER, C.; TRÜBY, J. The role of creative industries in industrial innovation. *Innovation: Management, Policy and Practice*, v. 11, n. 2, p. 148–168, 2009.
- MURTGATH, F. Neural networks and related massively parallel methods for statistics: a short review. *Int Statistic Review*, v. 62, n. 1, p. 275–288, 1994.
- NATHAN, M.; LEE, N. London. v. 0095, 2015.
- NELSON, R. *Por que as firmas diferem e qual é a importância disso? As Fontes do Crescimento Econômico*. Campinas, SP: Unicamp, 2006.
- PENROSE, E. *The Theory of the Growth of the Firm*. Oxford: Oxford university press., 2009.
- POTTS, J. et al. Social network markets: A new definition of the creative industries. *Journal of Cultural Economics*, v. 32, n. 3, p. 167–185, 2008.
- POUTANEN, P.; SOLIMAN, W.; STÄHLE, P. The complexity of innovation: an assessment and review of the complexity perspective. *European Journal of Innovation Management*, v. 19, n. 2, p. 189–213, 2016.
- PROTOGEROU, A.; KONTOLAÏMOU, A.; CALOGHIROU, Y. Innovation in the European creative industries: a firm-level empirical approach. *Industry and Innovation*, v. 24, n. 6, p. 587–612, 2017.
- ROBERT, V.; YOGUEL, G.; LERENA, O. The ontology of complexity and the neo-Schumpeterian evolutionary theory of economic change. *Journal of Evolutionary Economics*, v. 27, n. 4, p. 761–793, 2017.
- RUBENSON, D. L.; RUNCO, M. A. The economics of creativity, and the psychology of economics: A reply to Brenner, Diamond, Fuller, and Simonton. *New Ideas in Psychology*, v. 10, n. 2, p. 173–178, 1992.
- SANTOS, A. M. DOS et al. Usando redes neurais artificiais e regressão logística na predição da Hepatite A. *Revista Brasileira de Epidemiologia*, v. 8, n. 2, p. 117–126, 2005.
- SIMONTON, D. K. The Psychology of Creativity: A Historical Perspective. *History of Creativity Research*, p. 1–32, 2001.
- SMITH, M. *Neural network for statistical modelling*. New York, NY: Van Nostrand Reinhold, 1993.
- STONEMAN, P. Soft Innovation Outside the Creative Industries: Food, Pharmaceuticals, and Financial Services. In: STONEMAN, P. (Ed.). *Soft Innovation: Economics, Product Aesthetics, and the Creative Industries*. Cambridge, UK: Oxford Scholarship, 2010. p. 1–2.
- STRUMSKY, D.; LOBO, J.; TAINTER, J. A. Complexity and the productivity of innovation. *Systems Research and Behavioral Science*, v. 27, n. 5, p. 496–509, 2010.
- TEECE, D. J. Explicating dynamic capabilities: the nature and microfoundations of (sustainable) enterprise performance. *Strategic Management Journal*, v. 28, n. 2, p. 1319–1350, 2007.
- WIDROW, B.; HOFF, M. E. J. Adaptive switching circuits IRE WESCON Convention Record. *Anais*. 1960.
- WILDBERGER, A. Modeling the infrastructure industries as complex adaptive systems. In: Proceedings of the Simulators International CV. *Anais*. Boston, MA: Soc Comp Simulat Int, 1998.
- YU-HUA, L.; JIN-YAN, T.; YAO-YING, H. Evaluation of knowledge complementary degree for creative industry cluster based on BP neural networks. International Conference on Management Science and Engineering. *Annual Conference Proceedings*, p. 41–46, 2011.

Apêndices

Tabela 1: Sumário da simulação de complexidade do resultado inovativo da indústria criativa

Ação	Estatísticas	Resultado	
Treinamento	Soma dos quadrados do erro	8,749	
	Erro relativo médio geral	0,204	
	Previsões percentuais incorretas para dep. categóricas	RECEITARf 20,00%	
	Erro relativo para dependentes de escala	RI_MKT	0,097
		RI_ORG	0,195
		RI_PROC	0,183
RI_PROD		0,145	
Teste	Soma dos quadrados do erro	5,8078	
	Erro relativo médio geral	0,712	
	Previsões percentuais incorretas para dep. categóricos	RECEITARf 20,00%	
	Erro relativo para dependentes de escala	RI_MKT	0,897
		RI_ORG	1,469
		RI_PROC	0,208
RI_PROD		0,447	

Fonte: Elaborado pelos autores.

Tabela 2: Classificação do modelo em relação a RECEITARf

Amostra	Predito			
	Abaixo	Acima	Correto	
Treinamento	Abaixo	7	4	63,60%
	Acima	0	9	100,00%
	Overall Percent	35,00%	65,00%	80,00%
Teste	Abaixo	2	1	66,70%
	Acima	0	2	100,00%
	Overall Percent	40,00%	60,00%	80,00%

Fonte: Elaborado pelos autores.

Tabela 3: Modelo de rede neural do grau de complexidade do resultado inovativo - *output*

Camadas Ocultas	Variável Dependente					
	RECEITARf		RI_MKT	RI_ORG	RI_PROC	RI_PROD
	Abaixo	Acima				
Bias	0,086	0,392	-0,363	0,138	0,18	0,423
H(1:1)	-0,037	0,109	-0,263	0,354	0,563	-0,033
H(1:2)	0,216	-0,04	0,1	0,577	0,416	-0,165
H(1:3)	0,002	-0,14	-0,538	-0,06	-0,172	0,191
H(1:4)	0,25	-0,261	0,057	0,125	0,407	0,679
H(1:5)	-0,143	0,08	0,73	0,411	0,541	-0,205
H(1:6)	0,247	0,234	0,444	-0,292	0,171	0,231
H(1:7)	0,134	-0,264	-0,435	-0,557	0,221	0,339
H(1:8)	0,042	0,048	0,297	0,474	0,465	-0,763
H(1:9)	-0,061	-0,066	0,409	0,322	-0,68	-0,246
H(1:10)	0,422	-0,356	0,215	0,239	-0,357	0,449
H(1:11)	0,176	-0,183	0,014	-0,284	-0,271	-0,479
H(1:12)	0,068	0,046	-0,061	0,155	-0,437	0,506
Positivas	10	6	8	9	8	7
Negativas	3	7	5	4	5	6

Fonte: Elaborado pelos autores.

Tabela 4: Modelo de rede neural do grau de complexidade do resultado inovativo - *input*

Variável	Camada Oculta											
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)
(Bias)	0,260	0,052	-0,36	0,028	0,124	-0,233	0,169	0,286	-0,223	0,355	0,544	0,483
CA_TACITO=Alta	-0,071	-0,414	0,377	0,01	-0,436	0,506	-0,099	0,39	0,124	-0,306	-0,338	0,429
CA_TACITO=Média	-0,197	-0,436	0,25	0,241	-0,012	0,332	-0,386	-0,285	-0,257	0,202	0,266	0,394
CA_CODIFICADO=Alta	0,36	-0,146	-0,039	0,168	0,183	-0,386	-0,181	0,331	0,464	0,126	0,088	0,24
CA_CODIFICADO=Baixa	0,395	-0,313	-0,031	0,315	-0,09	0,346	0,442	-0,51	-0,436	0,491	-0,127	-0,301
CA_CODIFICADO=Média	0,179	0,056	0,535	0,514	0,107	-0,186	-0,423	0,185	-0,136	0,239	0,31	-0,205
CA_INTERACAO=Alta	-0,224	-0,345	0,29	-0,191	-0,134	0,43	-0,333	0,381	-0,324	0,296	0,054	-0,154
CA_INTERACAO=Baixa	0,319	-0,078	0,131	-0,426	0,199	-0,404	-0,454	-0,457	0,132	-0,412	-0,137	-0,398
CA_INTERACAO=Média	0,442	-0,257	0,008	-0,609	0,233	0,11	0,375	0,339	0,386	-0,365	0,147	-0,151
CA_SUBCONTRATAcao=Alta	-0,524	-0,078	0,437	0,15	-0,19	0,147	0,343	-0,369	0,291	-0,044	0,156	0,172
CA_SUBCONTRATAcao=Baixa	-0,362	0,323	0,426	0,244	-0,098	-0,413	-0,618	-0,093	0,078	0,204	0,239	-0,5
CA_SUBCONTRATAcao=Média	0,408	-0,205	0,316	-0,278	0,519	0,336	-0,136	-0,078	0,381	0,224	-0,226	0,333
CA_UNIVERSIDADE=Alta	-0,451	-0,317	-0,133	-0,106	0,05	0,565	0,2	0,199	0,017	-0,076	-0,069	0,471
CA_UNIVERSIDADE=Baixa	-0,134	0,028	-0,084	-0,216	-0,063	0,118	-0,315	0,17	-0,291	-0,421	-0,146	0,142
CA_UNIVERSIDADE=Média	0,093	0,023	0,124	0,293	0,534	0,118	-0,1	0,52	0,301	0,252	0,425	0,139
CA_SKILL=Alta	0,07	0,045	-0,397	0,433	0,008	-0,05	-0,047	-0,318	0,171	-0,304	0,362	-0,317
CA_SKILL=Baixa	0,096	0,372	0,114	-0,252	-0,4	0,517	-0,48	0,289	-0,097	0,104	0,158	-0,369
CA_SKILL=Média	0,193	-0,054	0,134	-0,21	-0,42	-0,107	-0,141	-0,239	0,507	-0,295	0,008	-0,014
TT_CUSTO=Alta	-0,01	0,145	0,072	0,453	-0,379	0,302	-0,526	-0,31	0,24	0,35	-0,397	-0,044
TT_CUSTO=Baixa	-0,205	-0,21	-0,425	0	0,185	-0,048	-0,498	0,149	-0,201	0,177	-0,194	-0,233
TT_CUSTO=Média	-0,201	-0,275	-0,461	0,122	-0,008	0,341	0,452	0,418	-0,269	-0,25	0,232	0,482
TT_CAPACIDADE=Alta	0,005	0,177	0,046	-0,405	-0,126	0,008	-0,443	0,367	-0,332	0,304	-0,239	0,446
TT_CAPACIDADE=Média	-0,291	0,161	0,507	-0,405	-0,325	0,198	-0,093	0,175	-0,064	-0,026	0,468	-0,115
TT_FLEX=Alta	-0,104	-0,356	0,268	-0,595	0,156	0,006	0,097	0,237	-0,26	-0,122	-0,057	0,08
TT_FLEX=Baixa	0,119	-0,009	0,384	-0,191	0,011	-0,012	-0,048	-0,502	-0,059	0,428	0,36	0,097
TT_FLEX=Média	0,322	-0,105	0,455	0,156	0,092	0,237	0,366	0,087	0,155	-0,018	-0,254	-0,131
TT_NMERCADOS=Alta	0,199	-0,464	0,046	0,482	0,178	0,386	0,101	0,102	-0,142	0,334	0,216	0,14
TT_NMERCADOS=Baixa	0,052	-0,242	0,511	-0,432	-0,46	-0,201	-0,451	-0,427	0,103	0,211	0,467	0,353
TT_NMERCADOS=Média	-0,145	-0,07	-0,361	0,044	-0,439	0,115	-0,437	-0,078	0,238	0,152	-0,039	0,04
TT_AMBIENTAL=Alta	-0,005	-0,102	0,241	-0,578	-0,286	0,345	0,261	0,184	-0,096	-0,398	-0,107	-0,252
TT_AMBIENTAL=Baixa	0,331	0,321	0,038	0,128	0,214	0,001	0,096	0,22	-0,249	-0,393	0,216	0,277
TT_AMBIENTAL=Média	0,469	-0,234	-0,186	-0,096	-0,26	-0,108	-0,029	-0,339	-0,026	0,541	0,416	-0,079
TT_NORMAS=Alta	-0,287	-0,162	-0,375	-0,188	0,283	0,003	0,001	-0,376	0,424	-0,166	0,41	-0,136
TT_NORMAS=Baixa	0,288	-0,161	0,044	-0,224	0,048	0,114	-0,597	0,198	-0,382	0,378	0,05	-0,346
TT_NORMAS=Média	-0,349	-0,336	-0,145	-0,087	0,472	0,472	-0,221	-0,311	-0,072	-0,233	-0,419	-0,185
FLIFISCAL	0,162	-0,557	0,458	-0,036	-0,591	0,017	-0,232	-0,57	-0,289	-0,112	-0,038	0,242

Tabela 4: 5 Modelo de rede neural do grau de complexidade do resultado inovativo - *input*

Variável	Camada Oculta											
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)
FLSUBVENCAO	-0,392	0,095	0,185	-0,207	-0,191	0,032	-0,053	0,048	-0,3	0,25	0,027	0,471
FLPED	0,098	-0,514	-0,202	0,33	-0,395	0,422	0,157	0,064	0,282	-0,055	0,305	0,038
FLFINEXCLUSIVO	-0,098	-0,277	0,329	-0,506	-0,456	-0,374	-0,093	0,16	0,236	-0,409	0,382	-0,365
FLBOLSAS	-0,041	-0,434	0,316	-0,165	-0,188	-0,257	-0,311	-0,542	0,219	0,028	0,03	-0,258
FLCAPRISCO	-0,284	-0,558	-0,295	-0,562	0,012	-0,474	-0,215	0,408	0,03	0,195	-0,055	0,328
FLOUTROS	0,181	-0,304	0,069	-0,381	0,075	-0,095	0,214	-0,218	0,048	0,108	0,013	0,158
IN_P&D	-0,507	0,423	0,176	-0,086	-0,168	0,134	0,573	0,446	-0,015	0,288	-0,454	0,284
IN_P&DEXT	0,369	-0,465	-0,504	0,374	0,279	0,28	-0,186	0,26	-0,358	-0,256	-0,348	-0,117
IN_CONHECIMENTOEXT	0,288	0,517	-0,148	-0,346	0,454	0,379	0,503	-0,096	-0,583	0,006	0,427	-0,053
IN_MEQP	0,237	-0,026	0,103	0,453	0,171	0,169	0,048	-0,012	-0,117	0,578	-0,011	0,272
IN_TREI	0,366	0,335	0,434	0,165	-0,422	-0,233	0,233	0,318	0,433	0,102	-0,138	-0,069
IN_MKT	-0,58	0,139	-0,013	-0,376	0,376	-0,306	0,161	-0,283	0,625	-0,048	-0,11	0,008
IN_D&E	-0,055	-0,003	0,245	0,18	-0,063	-0,296	0,035	-0,452	0,159	-0,268	0,323	0,335

Fonte: Elaborado pelos autores.

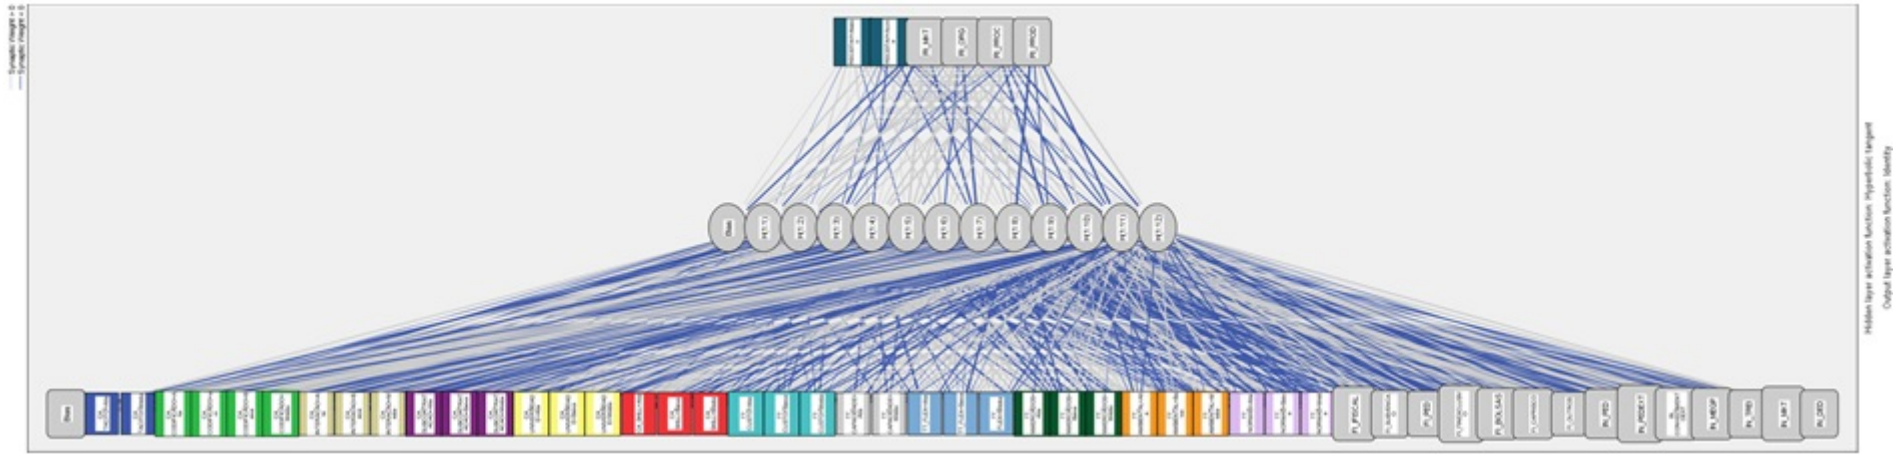


Figure 3: Rede neural artificial para a complexidade do resultado inovativo na indústria criativa
 Fonte: Elaborado pelos autores.