



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ECONOMIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA RURAL (PPGER)

JAMILE INGRID DE ALMEIDA SALVIANO

**SINERGIAS ENTRE O PROGRAMA AGROAMIGO E A AGRICULTURA
FAMILIAR NO SEMIÁRIDO DO BRASIL, NO PERÍODO DE 2005 A 2024**

FORTALEZA

2026

JAMILE INGRID DE ALMEIDA SALVIANO

SINERGIAS ENTRE O PROGRAMA AGROAMIGO E A AGRICULTURA FAMILIAR NO
SEMIÁRIDO DO BRASIL, NO PERÍODO DE 2005 A 2024

Tese apresentada ao Programa de Pós-Graduação em Economia Rural da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutora em Economia Rural. Área de concentração: Políticas Públicas e Desenvolvimento Rural Sustentável.

Orientador: Prof. Dr. José de Jesus Sousa Lemos.

FORTALEZA

2026

JAMILE INGRID DE ALMEIDA SALVIANO

SINERGIAS ENTRE O PROGRAMA AGROAMIGO E A AGRICULTURA FAMILIAR NO
SEMIÁRIDO DO BRASIL NO PERÍODO DE 2005 A 2024

Tese apresentada ao Programa de Pós-Graduação
em Economia Rural da Universidade Federal do
Ceará, como requisito parcial à obtenção do título
de Doutora em Economia Rural. Área de
concentração: Políticas Públicas e
Desenvolvimento Rural Sustentável.

Orientador: Prof. Dr. José de Jesus Sousa Lemos.

Aprovada em: 24/04/2026.

BANCA EXAMINADORA

Documento assinado digitalmente
 **JOSE DE JESUS SOUSA LEMOS**
Data: 24/04/2026 11:32:10-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. José de Jesus Sousa Lemos (Orientador)
Universidade Federal do Ceará (UFC)

Documento assinado digitalmente
 **KILMER COELHO CAMPOS**
Data: 29/04/2026 11:04:19-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Kilmer Coelho Campos
Universidade Federal do Ceará (UFC)

Documento assinado digitalmente
 **FILOMENA NADIA RODRIGUES BEZERRA**
Data: 28/04/2026 20:49:43-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Filomena Nádia Rodrigues Bezerra
Universidade Federal do Ceará (UFC)

Documento assinado digitalmente
 **MARIA ODETE ALVES**
Data: 24/04/2026 16:47:36-0300
Verifique em <https://validar.iti.gov.br>

Dra. Maria Odete Alves (Membro externo)
Banco do Nordeste do Brasil (BNB)

Documento assinado digitalmente
 **AIRTON SABOYA VALENTE JUNIOR**
Data: 28/04/2026 12:02:32-0300
Verifique em <https://validar.iti.gov.br>

Dr. Airton Saboya Valente Junior (Membro externo)
Banco do Nordeste do Brasil (BNB)

A Deus, as minhas filhas, Maria Alícia e Maria
Júlia, e ao meu esposo, Luiz Augusto.

AGRADECIMENTOS

Agradeço a Deus, que me sustentou e guiou em cada passo desta jornada.

As minhas filhas, Maria Alícia e Maria Júlia, que iluminam minha vida e dão sentido a todas as minhas conquistas.

Ao meu esposo, Luiz Augusto, pelo amor, apoio e parceria constante.

Ao meu querido professor orientador, Dr. José de Jesus Sousa Lemos, o maior incentivador da minha vida acadêmica, por desempenhar sua profissão com excelência, além do ser humano cheio de bondade e de solicitude. Agradeço pelo acolhimento desde 2019, apoio, orientação, confiança, ensinamentos, conselhos e paciência fornecidos durante a elaboração deste trabalho, o qual sempre se mostrou presente e disposto a compartilhar seu conhecimento.

À banca examinadora, Prof. Dr. Kilmer, Profa. Dra. Nádia, Dra. Maria Odete e Dr. Airton Saboya, que prontamente aceitou o convite para avaliar esta tese, e colaborar com valiosas contribuições para o seu aprimoramento.

Ao corpo docente do Programa de Pós-graduação em Economia Rural da Universidade Federal do Ceará (PPGER/UFC), pela dedicação, incentivo à pesquisa e contribuição à comunidade científica.

À Universidade Federal do Ceará (UFC), instituição que contribuiu efetivamente para a minha formação acadêmica, desde a Graduação em Economia na FEAAC, passando pelo Mestrado e, hoje, com a finalização do Doutorado em Economia Rural.

Ao Banco do Nordeste do Brasil (BNB), instituição na qual sou funcionária, e, em especial ao Escritório Técnico de Estudos Econômicos do Nordeste (ETENE), pela colaboração na disponibilização dos dados necessários para o desenvolvimento desta pesquisa.

Registro, ainda, meus agradecimentos aos colegas de trabalho, especialmente da Agência de Viçosa do Ceará (CE) e da Gerência de Reestruturação de Ativos do Ceará (GERAT-CE), onde tive a honra de trabalhar com pessoas incríveis, comprometidas, colaborativas e dedicadas ao desenvolvimento do Nordeste. Destaco, em particular, André, Uilton, Ney, Aliny e Conceição, além dos Gerentes Nonato e Lamec, cuja compreensão, flexibilização de horários, amizade e apoio foram fundamentais para a realização desta tese.

E, por fim, aos meus colegas e companheiros da UFC, especialmente ao Ediglê, Ana Cristina, Milena, Elizama e Érika, pelas experiências compartilhadas, aprendizados e por contribuírem para tornar a jornada mais leve e enriquecedora. A todos aqueles que tive a oportunidade de conhecer durante minha passagem pelo Doutorado em Economia Rural.

“Se a educação sozinha não transforma a sociedade, sem ela tampouco a sociedade muda”
(FREIRE, 2000, p. 67).

RESUMO

Este estudo investiga sinergias entre os recursos do Agroamigo e o desempenho da agricultura de sequeiro no Semiárido, com foco nas lavouras de arroz, de feijão, de mandioca e de milho predominantes na região, e sensíveis às variações climáticas. São avaliados os estados da Bahia, do Ceará, do Maranhão, de Pernambuco e do Piauí, por concentrarem, na área de atuação do BNB, o maior número de operações e de recursos em 2024. Os objetivos da pesquisa são: i) avaliar a expansão territorial e a dinâmica dos contratos e dos recursos financeiros, além da relevância econômica; ii) aferir as relações entre variáveis que influenciam a produção agrícola; e iii) comparar o Índice de Produtividade (INPR) e o Valor da Produção Agregado por hectare (VPA), antes e depois da implantação do Programa. Utilizam-se dados do BNB e do IBGE. Estimam-se estatísticas descritivas, Taxas Geométricas de Crescimento (TGC), Vetores Autorregressivos (VAR), Redes Neurais Artificiais (RNA), Análise Fatorial (AF) e testes de paridade de amostras. As variáveis incluem número de contratos, valor contratado, valor médio e salário mínimo anual, além de indicadores de produtividade e de valor da produção por hectare. Definem-se dois grupos: Controle (1985 a 2004), período anterior de acesso ao Programa; e Experimental (2005 a 2024), período posterior a sua implantação. Estimam-se o INPR e o VPA para avaliar mudanças estruturais e produtivas associadas ao Agroamigo. Os resultados evidenciam a expansão do Programa, com aumento do número de contratos, de aproximadamente 18 mil para quase 688 mil, e do volume total de recursos contratados, em torno de R\$ 60 bilhões. Contudo, o crescimento real foi limitado comparativamente ao salário mínimo. Observou-se ampla cobertura no Semiárido e interdependência entre as lavouras, influenciada por fatores estruturais e tecnológicos. O INPR apresentou boa capacidade explicativa, com destaque para Ceará, Pernambuco e Maranhão. Os impactos foram heterogêneos, com ganhos de renda no Ceará e de produtividade no Maranhão, além de resultados desfavoráveis nos demais estados. A conclusão geral é a de que o Agroamigo contribuiu para a dinamização produtiva da agricultura familiar no Semiárido, embora seus efeitos dependam das condições estruturais e climáticas locais para transformar esses ganhos em acréscimo de renda, como é esperado nas atividades agrícolas em geral.

Palavras-chave: semiárido; índice de produtividade; taxas geométricas de crescimento; vetores autorregressivos; redes neurais artificiais.

ABSTRACT

This study investigates synergies between Agroamigo resources and the performance of rain-fed agriculture in the Semi-Arid Region, focusing on rice, beans, cassava, and corn crops, which are predominant in the region and sensitive to climatic variations. The states of Bahia, Ceará, Maranhão, Pernambuco, and Piauí are evaluated, as they account for the largest number of operations and resources in 2024 within the BNB's area of operation. The objectives of the research are: i) to evaluate territorial expansion, contract dynamics, and financial resources, as well as economic relevance; ii) to assess the relationships between variables that influence agricultural production; and iii) to compare the Productivity Index (INPR) and Aggregate Production Value per hectare (VPA) before and after the implementation of the Program. and Experimental (2005–2024), the period following its implementation. The INPR and VPA are estimated to assess structural and productive changes associated with Agroamigo. The results show the program's expansion, with the number of contracts increasing from approximately 18,000 to nearly 688,000 and total funding reaching approximately R\$60 billion. However, real growth was limited compared to the minimum wage. Extensive coverage was observed in the Semi-Arid region, along with interdependence among crops, influenced by structural and technological factors. The INPR demonstrated good explanatory power, particularly in Ceará, Pernambuco, and Maranhão. The impacts were mixed, with income gains in Ceará and productivity gains in Maranhão, but unfavorable results in the other states. The overall conclusion is that Agroamigo contributed to boosting the productivity of family farming in the Semi-Arid region, although its effects depend on local structural and climatic conditions to translate these gains into increased income, as is expected in agricultural activities in general.

Keywords: semi-arid; productivity index; geometric growth rates; autoregressive vectors; artificial neural networks.

LISTA DE FIGURAS

Figura 1 – Delimitação atual do Semiárido brasileiro.....	42
Figura 2 – Estrutura da Rede Neural Artificial com uma camada oculta.....	57
Figura 3 – Distribuição espacial das quantidades de contratos e dos valores totais contratados pelo Agroamigo em 2024.....	79
Figura 4 – Distribuição espacial dos valores médios dos contratos do Agroamigo em 2024.....	80

LISTA DE GRÁFICOS

Gráfico 1	– Evolução dos valores médios dos contratos contraídos do Agroamigo em todos os estados inseridos no Programa entre os anos de 2005 e 2024.....	76
Gráfico 2	– Quantidade de contratos do Agroamigo em cada estado em 2024.....	77
Gráfico 3	– Valor total de contratos do Agroamigo em cada estado em 2024.....	78

LISTA DE QUADROS

Quadro 1 – Definição dos tipos de clima de acordo com o Índice de Aridez.....	39
Quadro 2 – Total de municípios no semiárido brasileiro e participação relativa por estado.....	41
Quadro 3 – Descrição das variáveis da base de dados.....	47
Quadro 4 – Intervalos da estatística KMO para a adequação da Análise Fatorial.....	64

LISTA DE TABELAS

Tabela 1	– Evolução na quantidade de municípios que captaram recursos do Agroamigo entre 2005 e 2024.....	73
Tabela 2	– Quantidade de contratos, valores totais de contratos, valores médios anuais dos contratos, salário mínimo anual e valor médio dos contratos em salários mínimos no período de 2005 a 2024 (*).....	74
Tabela 3	– Distribuição dos contratos e valores reais aplicados pelo Programa Agroamigo por estado em 2024.....	77
Tabela 4	– Total de municípios no Semiárido brasileiro e participação relativa dos municípios com Agroamigo no Semiárido, em 2024.....	81
Tabela 5	– Resultados da AF para a construção do Índice de Produtividade (INPR) nos estados analisados entre 1985 e 2024.....	84
Tabela 6	– Teste t de amostras emparelhadas nos estados analisados antes e depois do acesso ao Agroamigo.....	86

SUMÁRIO

1	INTRODUÇÃO.....	16
1.1	O problema e sua importância.....	16
1.2	Objetivos.....	18
<i>1.2.1</i>	<i>Objetivo geral.....</i>	<i>18</i>
<i>1.2.2</i>	<i>Objetivos específicos.....</i>	<i>19</i>
1.3	Estruturação do trabalho.....	19
2	Referencial teórico, contextualização analítica e evidências empíricas.....	20
2.1	Agricultura familiar e a institucionalização do PRONAF.....	20
2.2	Microcrédito produtivo orientado no Brasil: evolução e atuação do Banco do Nordeste do Brasil (BNB).....	27
2.3	O Programa Agroamigo.....	31
<i>2.3.1</i>	<i>Efeitos econômicos do Agroamigo: evidências empíricas na literatura.....</i>	<i>35</i>
2.4	O Semiárido e a agricultura de sequeiro.....	38
3	METODOLOGIA.....	46
3.1	Área de estudo.....	46
3.2	Base de dados e descrição das variáveis.....	46
3.3	Técnicas estatísticas e econométricas aplicadas à pesquisa.....	50
<i>3.3.1</i>	<i>Estatísticas descritivas e Taxa Geométrica de Crescimento (TGC).....</i>	<i>50</i>
<i>3.3.2</i>	<i>Estrutura híbrida VAR-RN para inpro modelagem e previsão.....</i>	<i>51</i>
<i>3.3.2.1</i>	<i>Modelo Vetorial Autorregressivo (VAR).....</i>	<i>53</i>
<i>3.3.2.2</i>	<i>Redes Neurais Artificiais (RNA).....</i>	<i>54</i>
<i>3.3.3</i>	<i>Análise Fatorial (AF) com extração por componentes principais.....</i>	<i>61</i>
<i>3.3.4</i>	<i>Teste t de Student.....</i>	<i>65</i>
3.4	Procedimentos metodológicos.....	66
<i>3.4.1</i>	<i>Procedimentos metodológicos para atingir o primeiro objetivo específico.....</i>	<i>66</i>
<i>3.4.2</i>	<i>Procedimentos metodológicos para atingir o segundo objetivo específico.....</i>	<i>68</i>
<i>3.4.3</i>	<i>Procedimentos metodológicos para atingir o terceiro objetivo específico.....</i>	<i>72</i>
4	RESULTADOS E DISCUSSÃO.....	73
4.1	Resultados obtidos para o primeiro objetivo específico.....	73
4.2	Resultados obtidos para o segundo objetivo específico.....	81
4.3	Resultados obtidos para o terceiro objetivo específico.....	86

5	CONSIDERAÇÕES FINAIS.....	90
	REFERÊNCIAS	94
	APÊNDICE A – DESEMPENHO DE RNA NA ESTIMAÇÃO DAS VARIÁVEIS.....	104
	APÊNDICE B – ARQUITETURA DE RNA PARA OS ESTADOS ANALISADOS.....	105
	APÊNDICE C – RESULTADOS DOS ERROS DE PREVISÃO NOS GRUPOS DE TREINAMENTO E TESTE PARA OS ESTADOS ANALISADOS.....	122
	APÊNDICE D – RESULTADOS DOS TESTES DE ACURÁCIA DO MODELO DE RNA NA ESTIMAÇÃO DAS VARIÁVEIS NOS ESTADOS ANALISADOS.....	123
	APÊNDICE E – IMPORTÂNCIA DAS VARIÁVEIS EXPLICATIVAS NAS PREVISÕES POR RNA PARA OS ESTADOS ANALISADOS.....	124
	APÊNDICE F – EVOLUÇÃO DOS VALORES OBSERVADOS E PREVISTOS NOS ESTADOS ANALISADOS UTILIZANDO O MODELO RNA.....	133
	APÊNDICE G – INPR E VPA OBSERVADOS E PREVISTOS NOS ESTADOS ANALISADOS ANTES E DEPOIS DO AGROAMIGO.....	145

1 INTRODUÇÃO

1.1 O problema e sua importância

A agricultura familiar exerce um papel estratégico na economia do Brasil, sobretudo na geração de emprego e de renda, e na ocupação dos membros das famílias, além de contribuir expressivamente para o abastecimento do mercado interno com produtos agroalimentares diversificados e matérias-primas (Cruz *et al.*, 2021; Ferreira *et al.*, 2022; Lemos *et al.*, 2020). Contudo, esse segmento produtivo, historicamente, enfrenta obstáculos significativos relacionados ao acesso a políticas públicas, a recursos produtivos e a infraestrutura.

Nesse sentido, o Programa Nacional de Fortalecimento da Agricultura Familiar (Pronaf) é um instrumento de política pública voltado ao fomento e ao desenvolvimento da agricultura familiar. De acordo com Marioni *et al.* (2016), o programa surgiu em um cenário onde os problemas de crédito desses agricultores eram principalmente de custo e escassez dos recursos. Diante disso, a oportunidade de acesso ao crédito direcionado a um grupo específico de produtores seria decisiva para dinamizar esse setor produtivo.

Ao viabilizar recursos financeiros para custeio, investimento e comercialização, o Pronaf possibilita a modernização das atividades, o aumento da produtividade e a melhoria da gestão pelos agricultores. Essa dinâmica contribui para melhorar a qualidade de vida dos beneficiários, gerando efeitos multiplicadores na economia local, por meio da circulação de bens e serviços. Destaca-se que políticas dessa natureza são especialmente relevantes em regiões marcadas por vulnerabilidades socioeconômicas, como na região Semiárida (Lemos, 2020; Silveira; Montenegro; Pereira, 2024).

Os programas de microcrédito têm adquirido relevância ao oferecer soluções adaptadas às especificidades dessa região climática. O Banco do Nordeste do Brasil (BNB), por meio do Programa Agroamigo, destaca-se nesse campo ao proporcionar crédito produtivo orientado a agricultores familiares localizados predominantemente no Semiárido brasileiro, especialmente aqueles enquadrados no Grupo B do Pronaf, combinando financiamento com acompanhamento técnico.

Alves *et al.* (2017) evidenciam que, no período de 2010 a 2020, 90,2% dos contratos e 67,7% do valor contratado na área de atuação do BNB foram contraídos por usuários do Grupo B no âmbito do Pronaf. De acordo com o BNB (2025a), em 2012 ampliou-se a abrangência do microcrédito para as demais linhas do Pronaf, resultando em uma mudança significativa para o Programa, que passou a operar em duas modalidades: Agroamigo Crescer, destinado aos

agricultores familiares enquadrados no Grupo B; e Agroamigo Mais, direcionado aos agricultores familiares contemplados pelas demais linhas de crédito do Pronaf (Grupo Variável), exceto aquelas pertencentes aos Grupos A e A/C¹. Ressalte-se que se trata do maior programa de microcrédito produtivo rural do Brasil e da América do Sul.

A produção agrícola está inserida em um contexto multifatorial, sendo influenciada por condições climáticas, como a instabilidade pluviométrica e o aumento das temperaturas, e por fatores econômicos, como o desempenho da produtividade e renda agrícola nos municípios. Esses aspectos são especialmente relevantes na agricultura de sequeiro praticada no Semiárido, modalidade produtiva que utiliza apenas a água da chuva, e é altamente sensível às variações climáticas.

Para Lessa *et al.* (2024), essas limitações estimulam os agricultores que cultivam nesse ambiente a elaborarem capacidade adaptativa de produção agrícola, a qual envolve o uso de terras em parceria, o arrendamento e a cessão, a diversificação da produção e o consórcio de culturas na unidade familiar.

Nesse cenário, destacam-se as lavouras de arroz, de feijão, de mandioca e de milho, culturas alimentares que ocupam majoritariamente os agricultores familiares no Semiárido. Além de fundamentais para a segurança alimentar, essas culturas representam as principais atividades agrícolas regionais, sendo, portanto, estratégicas para avaliar a efetividade do microcrédito rural como política de mitigação das vulnerabilidades socioeconômicas e climáticas.

Os recursos disponibilizados por meio do Agroamigo constituem um instrumento relevante de política pública, ao promover a inclusão produtiva e o fortalecimento das atividades agropecuárias. Entretanto, os efeitos concretos dessa política sobre a agricultura de sequeiro ainda permanecem pouco investigados. A literatura evidencia uma lacuna no que se refere à avaliação dos impactos do Programa sobre a produtividade e a renda agrícola nesse regime produtivo.

A investigação da relação entre o microcrédito rural, por meio do Agroamigo, e a produção agrícola das lavouras de sequeiro mostra-se relevante, uma vez que essas culturas predominam no Semiárido e dependem de políticas públicas de apoio. Como um importante

¹ O Grupo Variável do Pronaf inclui diferentes linhas de crédito, como o Pronaf Agroindústria, Pronaf Mais Alimentos, Pronaf Mulher, Pronaf Jovem, entre outros, com exceção do Pronaf Grupo A e A/C. O Pronaf Grupo A tem como público-alvo os agricultores assentados pelo Programa Nacional de Reforma Agrária (PNRA), bem como os beneficiários do Programa de Cadastro de Terras e Regularização Fundiária (PCRF) e do Programa Nacional de Crédito Fundiário (PNCF). Já o Pronaf Grupo A/C é destinado especificamente aos agricultores assentados pelo PNRA e aos beneficiários do PNCF.

instrumento de financiamento da agricultura familiar, analisar seus efeitos sobre indicadores de produtividade e de renda permite avaliar sua efetividade no fortalecimento desse segmento.

Diante do exposto, este estudo busca compreender de que forma os recursos financeiros do Agroamigo interagem com o desempenho das lavouras de sequeiro, especialmente no que se refere à produtividade e ao valor da produção por hectare.

O Programa Agroamigo completou duas décadas de atuação em 2025. Considerando esse marco histórico, a presente pesquisa foi delineada visando responder às seguintes questões norteadoras:

- a) Como evoluíram as quantidades de contratos e os valores médios, nos estados atendidos pelo Agroamigo entre 2005 e 2024?
- b) De que maneira os recursos liberados pelo Agroamigo interagiram com as variáveis que definem as produções agrícolas de sequeiro registradas nos principais estados beneficiados pelo Programa?

As hipóteses que fundamentam este estudo estão delineadas sequencialmente. A primeira hipótese sustenta a existência de relações temporais e espaciais entre as variáveis produtividade e valor da produção por hectare, as quais influenciam o desempenho das lavouras de sequeiro cultivadas de forma consorciada pelos agricultores familiares no Semiárido. A segunda hipótese postula que o Agroamigo exerceu influência sobre essas variáveis agrícolas, contribuindo para o aumento da produtividade e da renda agrícola nos estados beneficiados, ao longo das duas últimas décadas.

1.2 Objetivos

Nesta subseção, são detalhados os objetivos definidos na introdução, os quais foram norteadores para responder aos questionamentos da presente tese.

1.2.1 *Objetivo geral*

Analisar a evolução do Programa Agroamigo e sua interação com as variáveis determinantes da produção agrícola nos principais estados beneficiados do Semiárido brasileiro, no período de 2005 a 2024.

1.2.2 *Objetivos específicos*

- a) avaliar a evolução do Agroamigo entre 2005 e 2024, considerando a sua expansão territorial, a dinâmica dos contratos e dos recursos financeiros, a participação dos municípios no Semiárido e a relevância econômica do Programa para os agricultores familiares;
- b) aferir as relações entre as variáveis que definem a produção agrícola nos principais estados beneficiados pelo Programa Agroamigo;
- c) comparar a relação entre o Índice de Produtividade (INPR) e o Valor da Produção Agregado por hectare (VPA), desenvolvidos no âmbito desta pesquisa, considerando os períodos anterior e posterior ao acesso dos estados ao Programa Agroamigo.

1.3 Estruturação do trabalho

Além desta introdução, o presente trabalho está estruturado da seguinte forma: a segunda seção apresenta a fundamentação teórica e as evidências empíricas relacionadas ao tema; a terceira seção descreve a área de estudo, a base de dados, as variáveis utilizadas e as estratégias empíricas adotadas; na quarta seção, são explanados os resultados e discussões; e a quinta seção apresenta as considerações finais da pesquisa.

2 REFERENCIAL TEÓRICO, CONTEXTUALIZAÇÃO ANALÍTICA E EVIDÊNCIAS EMPÍRICAS

O referencial teórico está organizado em quatro subseções. Inicialmente, abordam-se a agricultura familiar e o Pronaf. Em seguida, discute-se o microcrédito, com destaque para a atuação do Banco do Nordeste do Brasil (BNB). Posteriormente, apresenta-se o Programa Agroamigo e suas evidências na literatura. Por fim, analisam-se as características do Semiárido nordestino e da agricultura de sequeiro na região.

2.1 Agricultura familiar e a institucionalização do PRONAF

No Brasil, os estabelecimentos classificados como agricultura familiar representam 76,8% do total de unidades agropecuárias, com presença marcante em todas as regiões do País. Apesar de ocuparem proporções relativamente menores, com 24,3% da área agrícola e 22,9% do valor bruto da produção, concentram a maior parte da força de trabalho no meio rural. Aproximadamente 13,8 milhões de pessoas trabalham nesses estabelecimentos familiares (IBGE, 2025). Esses números evidenciam que a agricultura familiar representa um dos pilares da produção agropecuária brasileira, sendo responsável por grande parte dos alimentos consumidos internamente.

Na Região Nordeste, esse segmento permanece como a principal forma de organização da produção e do trabalho no meio rural. De acordo com o IBGE (2019), em 2017, 79,2% dos estabelecimentos rurais da Região eram classificados como de agricultura familiar, o que significa que, a cada 100 estabelecimentos recenseados no campo, pelo menos 79 eram predominantemente administrados por famílias.

Entre os diversos conceitos de agricultura familiar, o estudo realizado em 2000, no âmbito do convênio de cooperação técnica entre a Organização das Nações Unidas para a Alimentação e Agricultura (FAO) e o Instituto Nacional de Colonização e Reforma Agrária (INCRA), define o termo a partir de três características: a gestão da unidade produtiva e os investimentos nela realizados são feitos por indivíduos que mantêm entre si laços de sangue ou casamento; a maior parte do trabalho é executada pelos membros da família; e a propriedade dos meios de produção (embora nem sempre da terra) pertence à família, sendo transmitida internamente pelos responsáveis na unidade produtiva (INCRA/FAO, 2000).

A Política Nacional da Agricultura Familiar, instituída pela Lei nº 11.326/2006 e regulamentada pelo Decreto nº 9.064/2017, estabeleceu os conceitos, princípios e instrumentos

direcionados a esse segmento. A Lei da Agricultura Familiar passou a reconhecer essa atividade como profissão e setor produtivo, definindo, como agricultores familiares, aqueles produtores que não detenham, a qualquer título, área maior do que quatro módulos fiscais; utilizem predominantemente mão de obra da própria família; tenham renda familiar predominantemente originada de atividades econômicas vinculadas ao próprio estabelecimento ou empreendimento; e o administrem com sua família (Brasil, 2006; 2017).

A literatura destaca que existe uma expressiva heterogeneidade, tanto entre as unidades produtivas quanto entre os perfis de produtores que compõem o universo da agricultura familiar (Aquino; Alves; Vidal, 2020; Guanziroli *et al.*, 2014). Essa diversidade também se observa entre municípios e regiões, em grande medida, devido às diferenças no módulo fiscal.

Definido pelo INCRA para cada município, o módulo fiscal é uma unidade de medida expressa em hectares e estabelecido com base em fatores como o tipo de exploração predominante, a renda agropecuária e as condições de produção locais, conforme a Lei nº 6.746/1979. Esse parâmetro é utilizado pela Lei nº 8.629, de 25 de fevereiro de 1993, alterada pela Lei nº 13.465 de 2017, como referência para classificar os estabelecimentos rurais.

Portanto, como o valor do módulo fiscal varia territorialmente, isso permite que produtores com áreas semelhantes sejam enquadrados de formas distintas, dependendo da região em que estejam inseridos, o que reforça a heterogeneidade estrutural da agricultura familiar no País.

Em consonância com a literatura sobre agricultura familiar e com a classificação do IBGE, Lemos *et al.* (2020) utilizam a distinção entre Unidades Agrícolas Familiares (UAF) e Unidades Agrícolas Patronais (UAP). Esses autores destacam que as UAF se caracterizam pela diversificação de atividades, como agricultura, criação de animais e extrativismo, diferenciando-se das UAP, as quais, em geral, são voltadas à produção em larga escala, com especialização em culturas comerciais ou pecuária intensiva em capital e uso de mão de obra contratada. Além disso, as UAF tendem a pressionar menos os recursos naturais, sobretudo o solo, atuando como unidades produtivas, ao gerar excedentes comercializáveis e renda, e como unidades de consumo, ao atenderem ao autoconsumo familiar, fortalecendo também o vínculo dos agricultores com o território onde vivem e desejam permanecer.

A agricultura familiar, marcada pelo uso intensivo de mão de obra familiar e pela diversidade de culturas, enfrenta limitações estruturais e de acesso aos recursos. Nesse contexto, o crédito rural surge como um instrumento estratégico para promover a inclusão produtiva, aumentar a renda e reduzir desigualdades no campo.

A discussão sobre o investimento do crédito rural na agricultura brasileira tem sido frequente na pauta dos estudos econômicos e sociais, especialmente em relação à desigualdade na aplicação dos recursos entre as regiões do País.

Saboya Júnior e Sousa (2005), ao investigarem a descentralização das aplicações do crédito rural entre 2001 e 2004, identificaram uma concentração dos financiamentos nas regiões Sul e Sudeste, embora o Nordeste concentre a maioria dos estabelecimentos da agricultura familiar. Essa assimetria regional revela desafios persistentes na efetivação das políticas públicas de crédito, especialmente quanto à equidade territorial e ao atendimento das populações mais vulneráveis.

Monteiro e Lemos (2019) examinaram a distribuição dos recursos do Pronaf entre 1999 e 2014, constatando que os valores médios dos contratos do Programa são maiores nas regiões mais desenvolvidas do País. O Nordeste apresentou o menor valor médio de contratos, seguido do Norte, evidenciando que as regiões mais pobres recebem menos recursos por contrato. Essa distribuição desigual reforça a necessidade de políticas que promovam uma alocação mais equitativa dos recursos, visando fortalecer a agricultura familiar em todas as regiões do País.

Búrigo *et al.* (2021) destacam que, entre 2003 e 2014, houve concentração na distribuição de crédito do Pronaf para custeio e investimento pecuário e agrícola, em que a bovinocultura, a suinocultura e a avicultura foram as principais atividades que receberam crédito de custeio pecuário, ao passo que a aquisição de animais e a compra de máquinas e equipamentos foram as principais modalidades financiadas com investimentos pecuário e agrícola, respectivamente, nesse período.

De acordo com Vieira (2017), existem diferenças significativas nas práticas produtivas, econômicas e sociais observadas nas áreas rurais, evidenciando uma heterogeneidade entre as regiões, com origem no processo de modernização da agricultura. Esse processo abrange desde agricultores que incorporaram inovações tecnológicas até aqueles que ainda desempenham atividades agrícolas de caráter tradicional, entendidas como práticas baseadas em baixo nível de mecanização, uso predominante de técnicas convencionais, reduzida incorporação de insumos modernos e forte dependência das condições naturais. Com efeito, os tipos de agricultores familiares se distinguem pelo modo como utilizam as técnicas agrícolas e pelo acesso à terra e às políticas públicas.

Nunes *et al.* (2014) observam que as políticas agrícolas implementadas no Nordeste foram as mesmas adotadas na região Centro-Sul, apesar das significativas diferenças climáticas e de desenvolvimento, desconsiderando especificidades regionais, como o clima semiárido e a

escassez hídrica. Diante disso, a reprodução dessas políticas no Nordeste contribuiu para a formação de dois modelos distintos de agricultura familiar: um com altos níveis tecnológicos e integrado aos mercados; e outro caracterizado pela predominância do trabalho familiar, menor inserção mercantil e maior dependência de rendas não agrícolas, como aposentadorias e transferências de programas sociais.

Machado *et al.* (2024) afirmam que a concentração de recursos destinados aos agricultores na Região Sul é explicada por alguns fatores, como a forte presença e atuação de cooperativas, maior uso do seguro rural, emprego de métodos avançados de produção, a disponibilização de garantias ao setor financeiro, disponibilidade de terras, melhor infraestrutura, agropecuaristas mais capitalizados e maior orientação técnica, além de ser uma das principais regiões produtoras e exportadoras de *commodities*, tais como carne bovina e suína, frango, milho e soja.

Embora o setor agropecuário brasileiro tenha demonstrado, nas últimas décadas, ensaios de mudanças caracterizadas pela modernização e pelo aumento da tecnologia e, por consequência, aumento da produtividade, a Região Nordeste não acompanhou esse processo iniciado nos anos 1960, o que gerou disparidades em relação a outras regiões (Vieira, 2017). Para Bianchini (2016), entre os principais fatores que dificultam o desenvolvimento da agricultura familiar no Nordeste, destacam-se a baixa capitalização, a escassez de tecnologias, as dificuldades no escoamento da produção para mercados mais dinâmicos e o acesso limitado a linhas de crédito.

O segmento da agricultura familiar apresenta uma ampla diversidade social, econômica e territorial, sendo um dos principais pilares do desenvolvimento rural do país. De forma a fomentar essa base produtiva e ampliar o acesso ao crédito, o governo brasileiro instituiu, em 1996, o Programa Nacional de Fortalecimento da Agricultura Familiar (Pronaf).

Para Aquino e Schneider (2015), a criação do Pronaf consiste em um dos marcos mais importantes das políticas públicas voltadas para o meio rural do Brasil, pois representa um instrumento relevante de apoio à agricultura familiar e contribui significativamente para o aumento da produção agropecuária do País.

O Pronaf foi criado através do Decreto nº 1.946/1996 e regulamentado pela Resolução nº 2.310/1996. Em 2000, o Ministério do Desenvolvimento Agrário (MDA) passou a ser o órgão responsável pela gestão do Programa. Posteriormente, com a extinção do MDA, as atribuições foram incorporadas ao Ministério da Agricultura, Pecuária e Abastecimento (MAPA), através da Secretaria de Agricultura Familiar e Cooperativismo (SAF). Em 2023, o MDA foi recriado como Ministério do Desenvolvimento Agrário e Agricultura Familiar, por

meio da Medida Provisória nº 1.154, com sua estrutura organizacional definida pelo Decreto nº 11.338.

Conforme Brasil (2025), o Pronaf é uma política de crédito rural subsidiado que financia investimentos e custeio da produção, oferecendo juros mais baixos a uma determinada classe de agricultores. O Programa é operacionalizado por agentes financeiros (bancos), e conta com a articulação de instituições como órgãos de assistência técnica, sindicatos e secretarias de agricultura.

De acordo com Alves (2025), o conceito de Agricultura Familiar adotado pelo Pronaf foi baseado no documento FAO/INCRA, de 1994, adaptado à realidade brasileira, que classificou os agricultores familiares em três grupos: consolidados (aqueles com maior integração aos mercados, acesso a políticas públicas e uso de tecnologias); em transição (produtores com inserção parcial nesses circuitos); periféricos (agricultores considerados economicamente inviáveis).

Conforme observado por Magalhães *et al.* (2006), os agricultores familiares com maior capital e capacidade de oferecer garantias passaram a ser os principais beneficiários dos financiamentos, especialmente nas linhas voltadas ao investimento, concentrando uma parcela significativa dos recursos disponíveis.

Na implementação inicial do Programa, os agricultores periféricos, concentrados majoritariamente no Nordeste, foram excluídos do acesso ao crédito, resultando em forte concentração dos financiamentos nas regiões Sul e Sudeste, historicamente mais capitalizadas (Aquino; Bastos, 2015).

Esse desequilíbrio gerou descontentamento no movimento sindical rural, pressionando o governo a promover mudanças no desenho institucional do Pronaf. Assim, ao longo dos anos, ajustes e segmentações foram incorporados ao programa com o objetivo de contemplar a diversidade da agricultura familiar brasileira.

Apesar da importância reconhecida do Pronaf e dos esforços de desconcentração de recursos, Aquino e Schneider (2015) afirmam que o crédito subsidiado não é distribuído de forma equitativa entre as distintas categorias da agricultura familiar, priorizando agricultores familiares produtores de *commodities* das regiões Sul e Sudeste, com pouca contribuição para a diversificação econômica e convivência com o Semiárido na Região Nordeste, em que a baixa diversificação das atividades contribui para a exposição às variações climáticas e aos preços de mercado. Segundo os autores, diante dessas limitações estruturais, seria necessário não apenas o aumento do crédito, mas a alteração da lógica de operação do Programa.

A metodologia do Pronaf é operacionalizada por meio do Plano Safra, principal

instrumento de execução das políticas públicas voltadas à agricultura familiar no Brasil. Esse plano, elaborado anualmente pelo MDA, define os valores dos recursos disponíveis, as taxas de juros, os limites de financiamento e as diretrizes prioritárias conforme os ciclos de produção agrícola (Brasil, 2023).

A partir da safra 1999/2000, o público beneficiário do Pronaf foi estratificado por grupos com critérios diferenciados de acesso ao crédito, como renda bruta anual, predominância do trabalho familiar e uso da terra. Essa estrutura direciona os beneficiários às linhas de crédito específicas, alinhando melhor a demanda, o endividamento e a capacidade de pagamento, permitindo o financiamento de atividades ligadas à agregação de valor, armazenamento, comercialização e industrialização da produção (Brasil, 2023).

Segundo Maia e Pinto (2015), a segmentação dos beneficiários do Pronaf segundo a renda teve como objetivo evitar que os agricultores mais pobres concorressem diretamente com os mais estruturados pelos mesmos recursos. Com exceção do grupo A, os demais grupos foram definidos com base nos rendimentos anuais auferidos pelos agricultores familiares. Essa divisão permitiu ajustar as condições de pagamento à capacidade financeira de cada grupo, promovendo maior inclusão e acesso ao crédito.

Uma das mudanças mais significativas ocorreu em 2000, com a criação do Grupo B, voltado a agricultores familiares em situação de maior vulnerabilidade, concentrados principalmente no Nordeste. Nos primeiros anos de sua implementação, o Pronaf B era financiado com recursos do Tesouro Nacional e, a partir de 2004, a principal fonte de financiamento passou a ser o FNE. Na safra 2005/2006, o FNE já respondia por 94,0% dos recursos do programa, reduzindo a participação do Tesouro Nacional para apenas 6,0%. Atualmente, o FNE é a única fonte de financiamento do Pronaf B (Alves, 2025).

Em 2003, o Governo Federal ampliou os limites de renda do Pronaf, flexibilizou os critérios de acesso, extinguiu a exigência de aval solidário e passou a adotar propostas simplificadas de crédito. Essas mudanças resultaram em um rápido crescimento dos contratos no Nordeste, que passou de pouco mais de 80 mil em 2003 para mais de 400 mil em 2005. Em 2006, os mais pobres tornaram-se maioria entre os tomadores de crédito (Magalhães *et al.*, 2006).

Por outro lado, Abramovay *et al.* (2013) e Schröder (2012) destacam que os projetos financiados apresentavam pouca diversidade, concentrando-se na pecuária, com baixo incentivo à inovação e à diversificação produtiva. Além disso, a ausência de mecanismos de controle e responsabilização contribuiu para uma cultura de inadimplência, resultando na suspensão temporária de financiamentos em diversos municípios a partir de 2008. Os autores

também observam que a concentração dos recursos das demais linhas do Pronaf, em segmentos mais consolidados da agricultura familiar, contribuiu para a manutenção de uma estrutura agrária desigual, especialmente no Nordeste.

Conforme o Manual de Crédito Rural (MCR) (Banco, 2025), os beneficiários do Pronaf são classificados nos seguintes grupos:

- a) Grupo A: composto por agricultores familiares assentados pelo Programa Nacional de Reforma Agrária (PNRA), ou beneficiários do Programa Nacional de Crédito Fundiário (PNCF) que não contrataram operações de investimento do Programa de Crédito Especial para a Reforma Agrária (ProCera);
- b) Grupo B: constituído por agricultores familiares, inclusive quilombolas, trabalhadores rurais e indígenas, que possuam renda bruta familiar nos últimos 12 meses de produção normal, que antecedem a solicitação da Declaração de Aptidão ao Pronaf (DAP), não superior a R\$50.000,00 (cinquenta mil reais) e que não contratem trabalho assalariado permanente;
- c) Grupo A/C: formado por agricultores familiares assentados pelo PNRA ou beneficiários do PNCF que tenham contratado a primeira operação no Grupo A e que não tenham contratado financiamento de custeio, exceto no próprio Grupo A/C; e
- d) Grupo V (Renda Variável): demais beneficiários.

O Pronaf oferece apoio financeiro a atividades agropecuárias e não agropecuárias, considerando como públicos beneficiários: agricultores familiares, assentados da reforma agrária, comunidades quilombolas, pescadores artesanais, aquicultores, piscicultores, extrativistas, silvicultores, ribeirinhos e povos indígenas. As atividades não agropecuárias incluem turismo rural, produção artesanal, agronegócio familiar e outras formas de prestação de serviços no meio rural, desde que compatíveis com a natureza da exploração e com o trabalho familiar (Banco Central do Brasil, 2025).

Além disso, a expansão do Programa ocorreu com a criação de linhas voltadas a finalidades específicas, como o Pronaf Produtivo Orientado, Pronaf Microcrédito Produtivo Rural (Grupo B), Pronaf Custeio, Pronaf Mais Alimentos, Pronaf Agroindústria, Pronaf Floresta, Pronaf Semiárido, Pronaf Mulher, Pronaf Jovem, Pronaf Industrialização e Pronaf Agroecologia, dentre outros.

Conforme Brasil (2023), a partir da criação do Pronaf, a agricultura familiar teve mais apoio e sua produção passou a ser vista como elemento impulsionador da economia do país. Entre os programas que atuam conjuntamente com a agricultura familiar destacam-se:

- a) Programa de Aquisição de Alimentos (PAA): instituído pela Lei nº 10.696/2003, em que o governo adquire alimentos dos agricultores familiares e doa parte para pessoas em risco alimentar, por meio de instituições reconhecidas, além de realizar formação de estoques;
- b) Merenda Escolar: no Programa Nacional de Alimentação Escolar (PNAE) os recursos federais são repassados, em caráter suplementar, aos estados, Distrito Federal e municípios, para a aquisição de gêneros alimentícios destinados à alimentação escolar. A Lei nº 11.947/2009 determina que, no mínimo, 30% desses recursos sejam utilizados na aquisição de produtos da agricultura familiar;
- c) Zoneamento Agrícola de Risco Climático: é um instrumento de política agrícola cujo objetivo é minimizar os riscos relacionados aos fenômenos climáticos, como a escassez de água, permitindo a cada município identificar a melhor época de plantio das culturas;
- d) Proagro Mais: programa que visa amortizar operações de custeios agrícola e indenizar parcela da renda que seria gerada no caso de ocorrer um evento adverso da natureza que afete as lavouras. De outra parte, o Proagro Mais Investimento assegura cobertura para pagamento de parcelas de investimento agropecuário, aos agricultores que possuem uma operação de custeio agrícola coberto pelo Proagro Mais; e
- e) Programa de Garantia de Preços para a Agricultura Familiar (PGPAF): consiste na concessão de bônus aos agricultores que contraírem financiamento de investimento ou custeio, quando o preço de mercado do produto financiado estiver abaixo do custo de produção.

Ao reconhecer a importância econômica e social da agricultura familiar, o Pronaf contribuiu para sua consolidação no Brasil e para a ampliação da autonomia dos agricultores. Essa lógica de inclusão também se reflete em políticas voltadas ao enfrentamento da pobreza e da exclusão financeira. Nessa perspectiva, aborda-se a seguir o microcrédito, voltado aos pequenos empreendedores.

2.2 Microcrédito produtivo orientado no Brasil: evolução e atuação do Banco do Nordeste do Brasil (BNB)

O termo microcrédito é usado com vários significados na literatura, indicando,

muitas vezes, produtos e formas de concessão de crédito distintos. Por isso, é importante destacar os principais aspectos que o caracterizam como uma modalidade específica de crédito, o crédito produtivo e orientado, que o diferencia do crédito tradicional, conforme explicitado em Barone *et al.* (2002) e Ribeiro e Carvalho (2006):

- a) Crédito produtivo: o microcrédito visa apoiar atividades produtivas de pequenos negócios, mantidos por pessoas de baixa renda, não se destinando, portanto, ao financiamento do consumo;
- b) Crédito orientado: o acompanhamento é realizado pelo agente de crédito, profissional que acompanha o tomador antes, durante e depois de contraído o empréstimo;
- c) Sistema de garantias: uso do aval ou fiança solidária, em que grupos de tomadores compartilham a responsabilidade pelos créditos concedidos.

A principal diferença entre microcrédito produtivo e microcrédito produtivo orientado é a metodologia de concessão do crédito. O microcrédito produtivo orientado é baseado no relacionamento direto com os empreendedores, realizado pelo agente de crédito, profissional capacitado para análise de empréstimos e orientação do empreendedor (Silva, 2007).

O marco histórico da difusão do microcrédito ocorreu em Bangladesh, na década de 1970, de uma experiência iniciada pelo economista Muhammad Yunus, fundador do Grameen Bank e ganhador do Prêmio Nobel da Paz em 2006, o qual iniciou um trabalho de concessão de crédito aos menos favorecidos com taxas baixas de juros.

De acordo com Yunus (2001), o microcrédito é um programa de mudança social, que permite aos mais pobres exercerem as suas habilidades e capacidades de produzir. Na forma tradicional de concessão de empréstimos, as instituições financeiras impõem exigências que acabam por excluir essa parcela da população, uma vez que o Sistema Financeiro Nacional a considera de maior risco e de alto custo operacional.

Nesse contexto, essa modalidade de crédito passa a ser compreendida como um instrumento de política pública para o desenvolvimento social. Constanzi (2002) ressalta a relevância dessas políticas, ao promoverem a emancipação econômica, e ao se diferenciarem de abordagens assistencialistas de combate à pobreza, pois possibilitam que indivíduos excluídos do mercado financeiro tradicional tenham acesso ao crédito, e possam investir em atividades econômicas viáveis, geradoras de emprego e renda.

O Banco Interamericano de Desenvolvimento (BID) define o microcrédito como um pequeno crédito concedido em larga escala por uma entidade financeira a pessoas físicas ou

jurídicas, cuja principal fonte de renda sejam as vendas provenientes da realização de atividades empresariais de produção de bens e serviços (BID, 2008).

De acordo com Silveira *et al.* (2024), as principais características dos programas bem-sucedidos de microcrédito são a criação de grupos de pessoas que tomam emprestado juntas e se responsabilizam conjuntamente pelo pagamento das dívidas, o contato direto dos agentes com a realidade dos clientes, os empréstimos de baixos valores e progressivos, de acordo com a adimplência e a flexibilidade das formas dos pagamentos, diante de choques exógenos.

Segundo Mota e Santana (2011), o respaldo financeiro está na confiança entre os componentes do grupo, pois, se um faltar com o compromisso de pagar seu débito, todo o grupo será penalizado. Dessa forma, acredita-se que o número de inadimplentes seja reduzido, uma vez que cada membro do grupo responde como um fiador dos demais. Além disso, existem ações peculiares a fim de atingir o público-alvo, como a busca constante para minimizar a burocracia e a ausência de garantias reais.

No Brasil, o microcrédito passou por diversas transformações até se tornar uma política pública estruturada. A experiência pioneira ocorreu na União Nordestina de Assistência a Pequenas Organizações (UNO), criada em 1973, com o objetivo de apoiar micro e pequenos empreendimentos da Região Nordeste. Segundo Bijos (2004), os recursos iniciais vieram de doações internacionais, posteriormente incrementados por outras linhas de crédito. Em Pernambuco e na Bahia, formou dezenas de profissionais especialistas em crédito para o setor informal e, durante muitos anos, foi a principal referência para a expansão dos programas de microcréditos na América Latina.

Em 1986, foram criados o Banco do Microcrédito, no Paraná, e o Promicro, no Distrito Federal. Em 1987, surgiu o Centro de Apoio aos Pequenos Empreendimentos Ana Terra (Ceape/RS), organização não-governamental considerada a primeira instituição formal em microcrédito no País, com apoio de órgãos internacionais, como o Banco Interamericano de Desenvolvimento (BID) e a Inter-American Foundation (IAF) (Santiago, 2008).

Na década de 1990, iniciou-se o processo de expansão do setor de microfinanças no País, com o surgimento de diversas políticas públicas, estimuladas pela estabilização monetária ocorrida a partir de 1994, com o Plano Real, contribuindo para o aumento expressivo da demanda por microcrédito, e para a construção de uma regulação desse setor no Brasil (Amaral, 2005).

Segundo Silva (2007), a primeira experiência de microcrédito como ação pública de microcrédito produtivo orientado foi o Prorenda-CE, criado a partir de um acordo bilateral

entre o governo do Ceará e o governo alemão, sendo operacionalizado de 1990 a 1997. O objetivo principal era contribuir para a geração de emprego e renda através dos financiamentos.

Em 1994 foi criado o Programa de Geração de Emprego e Renda (Proger), pelo Conselho Deliberativo do Fundo de Amparo ao Trabalhador (Codefat), com o objetivo de conceder crédito, e de oferecer capacitação gerencial e acompanhamento técnico aos micros e pequenos empreendimentos, formais e informais (Silva, 2007). Segundo Goldmark, Pockross e Vechina (2002), o Banco Nacional de Desenvolvimento Econômico e Social (BNDES) criou, em 1996, o Programa de Crédito Produtivo Popular (PCPP), que tinha o objetivo de disponibilizar linhas de crédito baratas e de longo prazo para instituições de microcrédito brasileiras.

Em 2005, o Governo Federal criou o Programa Nacional do Microcrédito Produtivo Orientado (PNMPO), estabelecido pela Lei nº 11.110, reformulado pela Lei nº 13.636/2018, e nº 13.999/2020, com o objetivo de apoiar e financiar atividades produtivas, principalmente por meio de recursos para o microcrédito produtivo orientado; e oferecer apoio técnico às instituições, com vistas ao fortalecimento destas para a prestação de serviços aos empreendedores populares. O PNMPO destina-se às pessoas naturais e jurídicas empreendedoras de atividades produtivas urbanas e rurais, com renda bruta anual de até R\$ 360 mil, conforme o limite estabelecido para a microempresa. No ano de 2010, foi incluído no programa o microcrédito rural destinado a agricultores de baixa renda (Brasil, 2005; 2018).

O Banco do Nordeste do Brasil (BNB), instituído pela Lei Federal nº 1.649/1952, caracteriza-se como banco público de desenvolvimento regional, com atuação voltada ao Nordeste brasileiro, historicamente marcado por prolongados períodos de seca. A instituição exerce papel central na execução de políticas públicas, destacando-se como principal operadora do microcrédito produtivo orientado na região, com atuação pioneira e decisiva para ampliar o acesso financeiro de populações em áreas semiáridas e com baixo Índice de Desenvolvimento Humano (IDH).

No âmbito do financiamento ao desenvolvimento regional, o BNB atua como agente operador do Fundo Constitucional de Financiamento do Nordeste (FNE), principal instrumento da Política Nacional de Desenvolvimento Regional (PNDR), destinado a apoiar atividades produtivas, e reduzir desigualdades econômicas e sociais. Por meio dessas ações, o Banco contribui para a ampliação do acesso ao crédito e para a dinamização das economias locais, especialmente em áreas mais vulneráveis (BNB, 2025b).

Na década de 1990, o BNB ampliou sua atuação com microcrédito produtivo, contando com os recursos oriundos do Fundo de Amparo ao Trabalhador (FAT), no âmbito do

Programa de Geração de Emprego e Renda (Proger). O Banco implantou comitês do Proger na região Nordeste, em parceria com governos locais, como instâncias consultivas para concessão de crédito às iniciativas empreendedoras que operassem com o fito de promover um desenvolvimento sustentável (Aquino; Silva, 2022).

No ano de 1998, o BNB criou o Programa de Microcrédito Crediamigo, destinado a microempreendedores informais urbanos e, em 2005, implantou o Programa de Microcrédito Rural, Agroamigo, que atende agricultores familiares no âmbito do Pronaf (Aquino; Silva, 2022).

O Crediamigo é, atualmente, uma referência nacional, além de ser considerado o maior programa de microcrédito da América Latina. Incentiva e apoia a geração de trabalho e renda, principalmente entre microempreendedores informais de menor renda, operando com recursos internos e do FNE (BNB, 2025a).

De acordo com Farranha (2005), o Crediamigo é considerado uma das únicas iniciativas mundiais bem-sucedidas organizadas por um banco estatal. A metodologia do aval solidário o consolidou como o maior programa de microcrédito produtivo orientado do País.

Em 2018, do total aplicado em microcrédito, 91% (R\$ 9,359 bilhões) foram originários de bancos públicos (Banco da Amazônia, Banco do Brasil, Banco do Nordeste e Caixa Econômica Federal), correspondendo a 89,8% dos contratos firmados. O BNB foi responsável pelo maior volume de aplicações (87% do total) e de contratos (85,7% do total). Dentre os bancos públicos, o BNB concentrou 95,7% do valor contratado (Alves; Santos, 2022).

Entre as iniciativas voltadas ao fortalecimento da agricultura familiar, destaca-se o Programa Agroamigo, que há duas décadas atua por meio do crédito produtivo orientado. A seguir, são detalhadas as suas principais características e os impactos econômicos apontados na literatura.

2.3 O Programa Agroamigo

O Agroamigo é o Programa de Microcrédito Rural do BNB, criado em 2005, a partir da experiência bem-sucedida do Crediamigo. Inspirado nessa iniciativa urbana, foi concebido como uma proposta adaptada às realidades das comunidades rurais, com o objetivo de atender agricultores familiares da área de atuação do Banco que apresentavam renda abaixo da linha de pobreza, especialmente aqueles enquadrados no Grupo B do Pronaf.

O Programa constitui uma iniciativa voltada ao fortalecimento da agricultura familiar no âmbito do Pronaf, adotando a metodologia do Programa Nacional de Microcrédito

Produtivo Orientado (PNMPO), baseada na orientação técnica e acompanhamento dos agricultores. Sua missão é contribuir para o desenvolvimento do setor mediante a concessão de microcrédito rural, promovendo a inclusão produtiva, a diversificação de atividades e a melhoria da qualidade de vida dos beneficiários. Como visão, busca tornar-se referência mundial em microfinanças rurais, gerando renda e produção de alimentos de forma sustentável (BNB, 2025a).

Maia e Pinto (2015) afirmam que o Agroamigo é uma releitura das políticas de microcrédito do Pronaf B, criado para melhorar a aplicação e qualificação do crédito para agricultura familiar. Essa proposta justifica-se a partir da verificação de que a prática de financiamentos para esse público, no modelo tradicional, não se mostrou adequada, ocasionando elevados níveis de inadimplência e pouca efetividade na mudança de cenário em relação às famílias envolvidas.

De acordo com Bianchini (2016), o predomínio do Pronaf B sempre foi no Nordeste, mas com um número elevado de operações e alta inadimplência na Região, mostrava-se necessário conjugar a realidade vivenciada pelos tomadores à viabilidade do crédito, e ampliar o atendimento das demandas, considerando que esse público requeria um tratamento especial. Como resultado, desenvolveu-se uma metodologia específica de microcrédito no meio rural para fomentar a geração de renda e ocupação das camadas mais carentes, de forma a reduzir a inadimplência.

A maior quantidade de agricultores familiares brasileiros encontra-se agrupada na categoria Pronaf B, cujos integrantes, em geral, apresentam baixo nível de educação formal, dispõem de pouca ou nenhuma terra para produção, operam com estrutura produtiva precária e aufera renda familiar muito baixa. Essa população concentra-se, sobretudo, no Nordeste, mais especificamente no Semiárido, onde esses agricultores estão submetidos a condições agroecológicas particulares que tendem a afetar o desempenho das atividades agropecuárias (Alves *et al.*, 2017).

Aquino, Alves e Vidal (2020) destacam que esses produtores possuem uma limitada disponibilidade de recursos hídricos, pouca ou nenhuma assistência técnica regular e ausência de equipamentos mecanizados para o desenvolvimento de suas atividades. Essa realidade torna-os especialmente vulneráveis às adversidades climáticas que, historicamente, afetam o Semiárido nordestino, reforçando a necessidade de crédito acessível e de políticas estruturantes para mitigar suas fragilidades socioeconômicas.

Segundo Alves *et al.* (2017), as particularidades do Nordeste e dos agricultores enquadráveis no Pronaf B revelam a magnitude do problema social com o qual se deparam as

instituições de desenvolvimento nordestinas. O desafio particular é do BNB, pela responsabilidade de administrar e operacionalizar o Pronaf B em toda a sua área de atuação, que em 2004 já abrigava 91% dos clientes do Pronaf.

Dessa forma, inicialmente, o Agroamigo foi direcionado aos agricultores familiares de pequeno porte, especialmente os enquadrados no Grupo B do Pronaf, público prioritário na estratégia de inclusão produtiva do Programa. É importante destacar que esse grupo compõe um segmento social heterogêneo, caracterizado por múltiplas carências no campo produtivo (Silva; Ciríaco; Aquino, 2025).

A partir de 2012, impulsionado pelos resultados positivos acumulados e pelas mudanças promovidas pela Resolução BACEN nº 4056/2012, a abrangência do Programa foi ampliada para as demais categorias do Pronaf, o que representou um marco no fortalecimento do microcrédito rural na Região (BNB, 2025). A principal fonte de recursos provém do FNE, complementado por outras fontes como o FAT, poupança rural, orçamento geral da União e as exigibilidades bancárias.

O público-alvo é composto por agricultores familiares que comprovem essa condição mediante apresentação de Declaração de Aptidão ao Pronaf (DAP) ativa ou inscrição no Cadastro da Agricultura Familiar (CAF). Com a ampliação, o Agroamigo passou a operar com duas modalidades metodológicas: o Agroamigo Crescer, direcionado a agricultores enquadrados no Grupo B do Pronaf, com renda bruta anual de até R\$ 50 mil; e o Agroamigo Mais, voltado a agricultores do Grupo Variável, cuja renda anual não ultrapasse R\$ 360 mil (BNB, 2025c).

O financiamento destina-se a atividades agrícolas, pecuárias e demais empreendimentos não agropecuários, no meio rural, tais como turismo rural, artesanato, comércio e serviços. O objetivo é promover o aumento e a diversificação da produção, a agregação de valor e a comercialização dos produtos, tendo como foco na melhoria dos níveis de renda das famílias rurais (BNB, 2025c).

Schröder (2012) destaca que o Agroamigo é uma inovação institucional e instrumental, pois, além de ofertar os recursos de forma orientada para manter um baixo índice de inadimplência, volta-se à estruturação das unidades familiares, à diversificação da renda e à integração do microcrédito com outras ações governamentais, ampliando o acesso dos agricultores a serviços bancários, a canais de comercialização e a sustentabilidade dos empreendimentos.

De acordo com BNB (2025a), a operacionalização do Agroamigo é realizada em parceria com o Instituto Nordeste Cidadania (INEC), uma Organização da Sociedade Civil de

Interesse Público que tem sua atividade regulamentada pela Lei nº 9.790/1999, sob a coordenação do Banco, que é responsável por estabelecer a metodologia, supervisionar a execução e garantir o cumprimento dos termos da parceria.

Segundo Alves (2025), a metodologia do Agroamigo foi desenvolvida para fortalecer o vínculo entre o BNB e os agricultores, permitindo a identificação prévia de suas demandas financeiras e garantindo um atendimento mais adequado. Os princípios do Programa incluem: atendimento presencial na comunidade, por profissional capacitado; diagnóstico da unidade produtiva; orientação e acompanhamento dos empreendimentos financiados; análise de crédito com base não apenas em aspectos financeiros, mas também familiares; concessão gradativa e sucessiva de financiamentos; oferta de serviços complementares ao crédito.

A operacionalização do Agroamigo segue um fluxo específico: o atendimento é conduzido por um agente de crédito, geralmente um técnico agrícola da própria comunidade, garantindo maior proximidade com os agricultores. A concessão do crédito ocorre de forma gradual e sequencial, com procedimentos diferenciados: no Agroamigo Crescer, não há exigência de garantias reais; no Agroamigo Mais, aplicam-se garantias conforme as normas do Pronaf (Alves, 2025).

Abramovay *et al.* (2012) explicam que o papel do assessor de crédito é de fundamental importância para o sucesso do Agroamigo, o que se deve às múltiplas funções que esses agentes exercem na operacionalização, tendo em vista que organizam a clientela, transmitem-lhes as regras básicas, elaboram as propostas de crédito e zelam pela recuperação dos recursos emprestados mediante a manutenção dos pagamentos em dia.

O Agroamigo gera impactos diretos e indiretos na realidade socioeconômica, nas áreas de sua atuação, como geração de empregos, aumento na massa salarial e incrementos na arrecadação tributária, no Valor Bruto da Produção (VPH) e no Valor Adicionado (VA) à economia, sendo uma estratégia efetiva de desenvolvimento sustentável.

Em 2024, a estimativa dos impactos das contratações do Agroamigo, com base em dados produzidos pelo próprio BNB, alcançou R\$ 8,6 bilhões, resultando na geração ou manutenção de 132,9 mil empregos diretos e indiretos. Esses dados representam um aumento de R\$ 1,9 bilhão na massa salarial. Além disso, houve incremento de R\$ 449,8 milhões na arrecadação tributária, R\$ 9,4 bilhões no VPH e R\$ 4,1 bilhões no VA da economia (BNB, 2025a).

Esses resultados evidenciam a importância do Programa para o fortalecimento da agricultura familiar nordestina. Em 2024, o Agroamigo ultrapassou o montante acumulado de R\$ 41,7 bilhões em valores financiados desde a sua criação, totalizando mais de 8,1 milhões de

operações contratadas, com uma carteira ativa de R\$ 13,2 bilhões e mais de 1,6 milhão de clientes com operações de crédito (BNB, 2025a).

Portanto, o Agroamigo representa uma conquista significativa para o desenvolvimento rural na área de atuação do BNB, ao promover a redução das desigualdades no campo e o desenvolvimento social e econômico por meio do incentivo à produção. Ao longo de duas décadas, tem transformado a realidade rural, beneficiando milhões de pessoas ao ampliar o acesso ao financiamento, o que permite aos produtores fortalecer suas atividades.

A seguir, abordam-se os efeitos econômicos do Programa, a partir das evidências empíricas disponíveis na literatura.

2.3.1 Efeitos econômicos do Agroamigo: evidências empíricas na literatura

Diversos estudos tiveram como enfoque o Agroamigo, conduzidos com distintos objetivos e aplicados a diferentes recortes geográficos, com vistas a mensurar seus efeitos econômicos. Para compreender os objetivos e as técnicas de análise mais utilizadas nos estudos desenvolvidos recentemente, nesta tese foi realizada uma revisão de literatura. Ademais, os trabalhos examinados nesta seção contribuem para o fortalecimento da fundamentação empírica das variáveis adotadas na presente pesquisa.

Para construção desta análise da literatura, foram seguidas algumas etapas. Inicialmente, delimitou-se o conjunto de bases de dados consultadas no Portal de Periódicos da CAPES, contemplando estudos revisados por pares disponíveis nas bases SciELO (*Scientific Electronic Library Online*) e Scopus. Em seguida, definiu-se o período de análise, abrangendo os 15 anos compreendidos entre 2010 e 2025. Por último, estabeleceu-se o termo de busca utilizado: “efeitos econômicos do Agroamigo”.

Abramovay *et al.* (2012) analisaram os efeitos do Agroamigo nos cinco primeiros anos de atuação, entre 2005 e 2010, constatando que o desempenho do Programa influenciou positivamente os níveis de produção dos beneficiários e sua inserção nos mercados agropecuários. Esse efeito é mais evidente entre agricultores com mais tempo de participação, que apresentaram cerca de 18% a mais da produção agropecuária em relação aos novos integrantes. Além disso, o impacto foi mais expressivo na agricultura, alcançando aumento de 28% na produção.

Os autores observaram que os efeitos positivos sobre a atividade agropecuária e a riqueza são mais acentuados entre os clientes da região não-semiárida, embora os beneficiários do semiárido não apresentem desempenho inferior. Constataram ainda que, apesar dos efeitos

positivos do Programa sobre os níveis de produção, a renda gerada por essas atividades permanece insuficiente para retirar essas famílias da condição de pobreza (Abramovay *et al.*, 2012).

Oliveira, Silva e Costa (2021), ao analisarem a concentração do Programa por municípios e estados do Nordeste no período de 2005 a 2013, encontraram em seus resultados que Alagoas e Sergipe demonstraram os maiores níveis de concentração da carteira. Ademais, calcularam o Índice de Volume Emprestado pelo Agroamigo (IVEA) e observaram que há municípios com carência de atuação do Programa, sugerindo a necessidade de direcionar esforços para melhor distribuição ou ampliação de recursos nesses municípios.

Nunes *et al.* (2015) examinaram o Agroamigo no Rio Grande do Norte e concluíram que o Programa prioriza financiamentos de investimento voltados a atividades tradicionais, em detrimento do custeio. O estudo também aponta para baixa diversificação das atividades apoiadas, com reduzida participação de iniciativas distintas da agricultura familiar tradicional, como aquelas relacionadas ao processamento de produtos agropecuários. Os resultados indicam efeitos positivos na agricultura familiar, mas enfatizam a necessidade de ampliação dos recursos destinados pelo Programa ao Estado.

Almeida e Oliveira (2015) fazem uso de um modelo de Análise Envoltória de Dados (DEA) para avaliar a equidade dos repasses destinados às famílias residentes em áreas rurais do Nordeste em 2010. Os resultados indicam que a oferta do crédito para localidades mais necessitadas se mostra insuficiente, devendo haver a ampliação de recursos para essas áreas. Além disso, o estudo mostrou que os municípios que registraram maior flutuação em relação à média história de chuvas, receberam montantes maiores de recursos, sugerindo que os repasses são direcionados mais intensamente para os municípios com um ambiente climático mais favorável, visando a estimular as atividades agropecuárias.

Duarte *et al.* (2017) analisaram os municípios que compõem o Cariri Central com dados de 2016, aplicando a metodologia Propensity Score Matching (PSM). Os resultados mostram que os beneficiários do Agroamigo apresentam valor bruto da produção, em média, R\$ 490,65 superior em relação aos não beneficiários, destacando que o acesso ao crédito tende a elevar a produção e a produtividade dos agricultores, o que indica a efetividade do Programa nesses municípios.

Alves *et al.* (2017) investigaram o perfil dos beneficiários em termos de produção, em que os resultados revelaram um cenário de pobreza e baixa estrutura produtiva entre agricultores enquadrados no Agroamigo Crescer. Contudo, houve melhora na escolaridade, visto que os filhos dos beneficiários têm nível de educação formal superior ao dos pais,

indicando um impacto intergeracional positivo e condições mais favoráveis no mercado de trabalho, com reflexo na renda familiar.

Costa *et al.* (2018) verificaram os efeitos heterogêneos do Agroamigo na produção e produtividade por trabalhador beneficiado. Os resultados indicam impacto positivo e estatisticamente significativo de 51% sobre o valor bruto da produção e de 43,6% no valor da produção por hectare para aqueles que têm maior probabilidade de receber o tratamento. Os impactos foram mais intensos para os agricultores em situação mais vulnerável, como mulheres, analfabetos e famílias com menor condição socioeconômica. Os autores concluíram que o Programa intensifica a produção dos pequenos produtores, porém recomendam a ampliação do crédito para famílias rurais menos favorecidas.

Aquino, Alves e Vidal (2020) realizaram um balanço da primeira década de existência do Agroamigo, ou seja, entre 2005 e 2014, com base em revisões bibliográficas sobre os impactos do Programa. Os resultados indicam que o Agroamigo alcançou objetivos relevantes em sua operacionalização, contabilizando mais de 2,4 milhões de operações de crédito no período, com valor superior a R\$ 5,6 bilhões e taxa de inadimplência superior a 95%. Os autores destacam ainda alguns entraves a sua atuação, como a permanência do viés setorial pecuário e baixa diversificação das atividades financiadas, concluindo que a primeira década foi marcada por avanços e continuidade, destacando a necessidade de incentivo às atividades inovadoras, e não apenas às agropecuárias.

Guedes, Almeida e Oliveira (2021) avaliaram o efeito do Agroamigo, entre 2005 e 2015, sobre o valor da produção agropecuária dos municípios nordestinos. Os resultados evidenciam que o volume de empréstimos produziu um efeito positivo sobre a produção pecuária, potencializado nos municípios com mais de sete anos de exposição ao Programa. Entretanto, para a atividade agrícola, não foram encontrados efeitos estatisticamente significativos. Além disso, considerando apenas a produção da pecuária, foram confrontados os valores totais concedidos e os benefícios gerados, concluindo que ocorreu uma taxa de retorno de 52% no agregado, o que indica que o Agroamigo apresenta custo-benefício favorável, sendo um instrumento de proteção para assegurar a produção e estimular o crescimento da atividade.

No semiárido baiano, Jesus *et al.* (2023) investigaram a expansão do Agroamigo entre 2005 e 2022, utilizando estatística descritiva e análise comparativa com base em dados do IBGE e do BNB. Os resultados indicam crescimento contínuo de sua atuação no período, com destaque, em 2022, para a concentração da maior parte dos financiamentos na região semiárida e na pecuária.

Silva, Colen e Melo (2024) realizaram uma avaliação dos impactos do crédito nas

condições socioeconômicas dos beneficiários, com o objetivo de identificar melhorias em sua qualidade de vida. Os resultados indicaram que aqueles com maior tempo de exposição ao programa apresentaram melhorias significativas em aspectos como infraestrutura sanitária, aquisição de bens, acesso a mercados e aumento da renda familiar. Clientes mais antigos relataram melhores condições comerciais e maior diversificação produtiva. Ainda assim, os autores apontam a necessidade de estimular a diversificação das atividades financiadas, atualmente fortemente concentradas na bovinocultura. Ademais, recomendam maior integração com políticas públicas, de modo a fortalecer os canais de comercialização, aumentar a sustentabilidade e promover a inclusão financeira.

Considerando as evidências apontadas na literatura e os resultados de estudos anteriores sobre o Agroamigo, observa-se que, apesar de sua relevância como instrumento de inclusão produtiva e de fortalecimento da agricultura familiar, os efeitos dessa política sobre a produção agrícola e a mitigação dos impactos climáticos ainda não foram suficientemente explorados por meio de análises empíricas. Identifica-se, assim, uma lacuna na literatura, especialmente no que diz respeito à agricultura de sequeiro, sistema predominante na região semiárida e dependente das condições climáticas.

Diante disso, o presente estudo de doutorado propõe analisar a evolução do Agroamigo e sua interação com variáveis produtivas e climáticas nos municípios atendidos pelo Agroamigo. A principal contribuição desta tese consiste na oferta de evidências sobre o impacto do Programa na agricultura de sequeiro, investigando seu papel na melhoria da produtividade e no valor da produção frente às adversidades climáticas.

Uma vez que a maior parte dos municípios atendidos pelo Agroamigo está localizada nas regiões mais vulneráveis do semiárido brasileiro, apresenta-se, a seguir, um breve panorama dessa região climática.

2.4 O Semiárido e a agricultura de sequeiro

O Semiárido é um clima caracterizado por forte insolação, por temperaturas elevadas, por umidade relativa do ar muito baixa e por um regime de chuvas marcado pela escassez, irregularidade e concentração das precipitações em um curto período, apresentando reservas de água insuficientes em seus mananciais (Moura *et al.*, 2007).

De acordo com Lemos (2020), há regiões semiáridas nas Américas, Oceania, Ásia e África. No continente sul-americano existem três grandes áreas semiáridas: Guajira, que se estende pela Venezuela e Colômbia; uma área que cobre parte da Argentina, Chile e Equador;

e a terceira área localiza-se no Nordeste brasileiro, sendo o maior semiárido do mundo em termos de extensão e de densidade demográfica.

As áreas de clima semiárido são classificadas com base no Índice de Aridez, segundo a metodologia de Thornthwaite (1948), que relaciona a precipitação total à evapotranspiração potencial, ou seja, mede o equilíbrio entre a água da chuva e a evaporação do solo e transpiração das plantas, influenciadas pelo calor e pelos ventos. Se chover menos do que a capacidade do solo e das plantas de reter água, surgem problemas em escala crescente. Este fenômeno é denominado balanço hídrico (Lemos, 2020).

Na Equação (1), a seguir, mostra-se como é estimado o Índice de Aridez (IAR) de Thornthwaite, a partir das informações sobre a precipitação anual de chuvas, em milímetros (CHU), e a evapotranspiração anual, também aferida em milímetros (EVP). O resultado alcançado é multiplicado por 100, de modo que o IAR seja aferido em percentuais. Calculado dessa forma, o índice indica o percentual das águas das chuvas que caíram, em um determinado ano, em uma área específica, que ficaram retidos no solo, proporcionando-lhe umidade. O Quadro 1 apresenta as caracterizações para a definição dos climas das regiões.

$$\text{IAR} = (\text{CHU}/\text{EVP}).100 \quad (1)$$

Quadro 1 - Definição dos tipos de clima de acordo com o Índice de Aridez

Regiões de acordo com o tipo de clima	Índice de Aridez (IAR) (%)
Hiperárido	$\text{IAR} < 5$
Árido	$5 \leq \text{IAR} < 20$
Semiárido	$20 \leq \text{IAR} < 50$
Subúmido e Seco	$50 \leq \text{IAR} < 65$
Subúmido e Úmido	$65 \leq \text{IAR} < 100$
Úmido	$\text{IAR} \geq 100$

Fonte: United Nations (2011).

As piores situações em relação a essa escala estão nos climas hiperáridos e áridos, em que o IAR é menor do que 20, significando uma capacidade de retenção de água por parte do solo inferior a 20% daquela que é precipitada. Em seguida tem-se as áreas situadas nos climas semiáridos em que o IAR varia entre 20% e 50%. Os demais limites de capacidades de retenção se referem aos climas subúmido e seco, subúmido e úmido e estritamente úmido.

O Nordeste brasileiro é caracterizado por quadros climáticos extremos, com longos

períodos de estiagem seguidos por chuvas intensas, compondo o binômio seca-chuva. As chuvas irregulares são concentradas em três a quatro meses no início de cada ano e, em períodos de seca, são bastante reduzidas (300 a 500mm a.a.) (IBGE, 2006).

Lemos (2020) destaca que, no Semiárido nordestino, predominam temperaturas médias anuais elevadas, entre 23°C e 27°C, evaporação de 2.000 mm a.a., insolação média anual de 2.800 horas e regime pluviométrico irregular, com chuvas mal distribuídas, abaixo de 800mm anuais e umidade relativa do ar em torno de 50%, o que resulta em balanço hídrico negativo em boa parte dos anos.

Portanto, a variabilidade climática é uma das principais características do Nordeste brasileiro, constituindo-se em uma das principais adversidades enfrentadas por aqueles que vivem nessa região, principalmente pelos que exercem atividades agrícolas baseadas em lavouras de sequeiro.

Além disso, tal região concentra alguns dos menores indicadores socioeconômicos do país, com altos índices de pobreza e exclusão. Nesse sentido, a agricultura familiar, embora vulnerável, é essencial para a geração de renda e emprego na Região, e a compreensão dessa realidade social é fundamental para propor estratégias de desenvolvimento rural sustentável.

As populações que sobrevivem no Semiárido brasileiro, reconhecida nesta condição pelo Governo Federal, recebem tratamento diferenciado das políticas públicas. A primeira delimitação do espaço territorial a ser beneficiado com ações governamentais de defesa contra os efeitos da seca foi estabelecida pela Lei nº 175/1936, conhecida como “Polígono das Secas”. Posteriormente essa delimitação foi revisada pelo Decreto Lei nº 9.857/1946, e pela Lei nº 1.348/1951, com o intuito de amenizar os efeitos da seca no Nordeste do País.

Dentre as políticas desenvolvidas para o Semiárido, destaca-se o Fundo Constitucional de Financiamento do Nordeste (FNE), que objetiva contribuir para o desenvolvimento econômico e social do Nordeste através de programas de financiamento aos setores produtivos, em consonância com o Plano Regional de Desenvolvimento, sendo operado exclusivamente pelo Banco do Nordeste do Brasil (BNB).

Em 2017, o Ministério da Integração Nacional, sob cuja jurisdição estão subordinados a Superintendência do Desenvolvimento do Nordeste (SUDENE) e o seu Conselho Deliberativo (CONDEL), emitiu a Resolução nº 115/2017, contendo os seguintes critérios para definir os municípios do Semiárido: pluviometria média anual igual ou inferior a 800 mm; índice de aridez igual ou inferior a 50; e percentual diário de déficit hídrico igual ou superior a 60%, considerando todos os dias do ano (Brasil, 2017).

A Resolução CONDEL/SUDENE nº 176/2024, redefiniu a delimitação dessa região

climática ao aprovar o Relatório Final da Delimitação do Semiárido (2024). Atualmente, o Semiárido brasileiro abrange 1.477 municípios, constituindo a maior região semiárida do mundo em extensão territorial e população. O Quadro 2 apresenta a nova delimitação, com o total de municípios por estado e sua participação relativa no Semiárido.


Quadro 2 - Total de municípios no Semiárido brasileiro e participação relativa por estado

Delimitação do Semiárido Brasileiro			
Estados	Total de Municípios	Municípios no Semiárido	Relação Semiárido/Estado (%)
Alagoas	102	42	41,2
Bahia	417	287	68,8
Ceará	184	175	95,1
Maranhão	217	16	7,4
Paraíba	223	198	88,8
Pernambuco	185	142	76,8
Piauí	224	216	96,4
Rio Grande do Norte	167	148	88,6
Sergipe	75	30	40,0
NORDESTE	1794	1254	69,9
Minas Gerais	853	217	25,4
Espírito Santo	78	6	7,7
BRASIL	5570	1477	26,5

Fonte: Elaboração própria, baseado em CONDEL/SUDENE (2024).

A Figura 1, na sequência, mostra onde estão localizados os municípios que fazem parte do Semiárido, oficialmente reconhecido nas delimitações feitas pelo Conselho Deliberativo da SUDENE, em 2024.

Figura 1 – Delimitação atual do Semiárido brasileiro



Fonte: CONDEL/SUDENE (2024).

Observa-se, no Quadro 2 e na Figura 1, que a maior parte desse território se encontra na Região Nordeste, onde cerca da metade dos nove estados possui mais de 85% de sua área caracterizada como semiárida. Segundo o IBGE (2022), essa região contava com cerca de 58 milhões de habitantes em 2022, dos quais uma parcela significativa reside no semiárido.

O Semiárido brasileiro, que abrange a maior parte do Nordeste, apresenta condições naturais desafiadoras para a produção agrícola, como chuvas irregulares, altas temperaturas e solos com baixa fertilidade. Apesar dessas limitações, a região abriga milhões de agricultores familiares que dependem da terra para sua subsistência.

A agricultura de sequeiro, que depende exclusivamente da água das chuvas, constitui a forma predominante de cultivo no Semiárido. Nesse contexto, a produção agrícola apresenta elevada instabilidade, uma vez que, na ausência de irrigação, as culturas completam seu ciclo dependendo integralmente da regularidade e suficiência das chuvas. Assim, a instabilidade climática torna essa prática muito vulnerável, exigindo técnicas adaptativas, como

plantio em épocas estratégicas e uso de sementes resistentes à seca.

De fato, conforme Quaranta (2013), o regime de sequeiro nas regiões semiáridas é uma atividade sujeita a altos riscos de perdas de safra, devido à acentuada variabilidade pluviométrica. Diante desse contexto, o autor ressalta a necessidade de adoção de sistemas de produção que priorizem o uso eficiente da água, que, associados a técnicas específicas de cultivo, possibilitam o aproveitamento mais eficaz da limitada umidade disponível no solo.

De modo geral, a escassez hídrica e a seca são associadas aos problemas encontrados no semiárido, sobretudo devido às diferenças marcantes de precipitação anual entre regiões e aos efeitos da seca sobre a redução das produtividades das lavouras e das áreas cultivadas. Além disso, as chuvas apresentam distribuição irregular, e grande parte da água não é aproveitada devido à evaporação e ao escoamento superficial. Contudo, em alguns casos, os impactos da restrição hídrica podem ser total ou parcialmente mitigados, dependendo das condições de distribuição das chuvas e das técnicas adotadas no sistema produtivo.

Nesse sentido, a EMBRAPA (2011) argumenta que o principal problema do semiárido não está propriamente na quantidade de chuvas e sim na forma como elas se distribuem no tempo e no espaço, uma vez que um único trimestre chega a registrar até 90% da precipitação anual. Assim, ao longo de um ciclo produtivo, muitas vezes a quantidade de chuva precipitada seria suficiente para uma colheita satisfatória, caso fosse melhor distribuída. Entretanto, a concentração da precipitação em poucos eventos, ainda que volumosos, compromete o desenvolvimento das culturas e inviabiliza uma produção e colheita adequadas.

Volumes de chuvas abaixo ou acima das necessidades hídricas dos cultivos causam queda nas áreas colhidas e produtividades das lavouras, cultivadas em regime de sequeiro. Em consequência, afetam a produção e o valor da produção dessas culturas, que impactam tanto na segurança alimentar quanto na geração de renda dos agricultores do Semiárido nordestino (Thornton *et al.*, 2008).

Para Mendes (2010), apesar dos grandes avanços técnicos no Semiárido, o bem-estar econômico e social continua dependente do clima, sendo bastante provável que essa dependência continue no futuro. A adaptação à instabilidade climática consiste em um dos maiores desafios para a produção e o cultivo das culturas agrícolas.

No Nordeste, os sistemas de sequeiro costumam utilizar consórcios de culturas, como caju/feijão, caju/mandioca, mamona/milho e feijão/milho. Apesar da difusão de práticas agroecológicas, esses consórcios normalmente são cultivados em sistemas conhecidos como agricultura toco, com revezamento itinerante de áreas, prática limitada pelo pequeno tamanho das propriedades familiares. O consórcio de culturas contribui para a redução de riscos

climáticos².

As lavouras analisadas neste estudo, arroz, feijão, mandioca e milho, destacam-se pela importância para a agricultura familiar no Semiárido, pois são cultivadas em diversos municípios nordestinos tanto para subsistência como para venda de eventuais excedentes. Essas culturas se adaptam bem ao clima local, desempenham papel central na segurança alimentar e geram renda mesmo em sistemas produtivos de baixa tecnologia. Assim, sua análise permite compreender de forma representativa a dinâmica e os desafios da produção agrícola na região.

Ressalta-se que, a produção de arroz no Semiárido apresenta significativa variação espacial, influenciada pela disponibilidade de recursos hídricos e pela estrutura produtiva local, e geralmente ocorre em sistemas irrigados ou em várzeas fluviais. Quando realizado em sequeiro, apresenta baixa produtividade e alto risco climático, mas ainda assim possui grande importância nas comunidades rurais com pouca disponibilidade de irrigação.

Embora o cultivo de arroz seja predominante nas regiões Sul e Centro-Oeste do País, alguns estados nordestinos mantêm produções relevantes. Em 2024, a produção regional totalizou 359.360 toneladas, das quais Maranhão e Piauí responderam por aproximadamente 72,5% (IBGE, 2025). Essa concentração reflete a combinação de condições edafoclimáticas mais favoráveis ao cultivo, aliadas à maior consolidação dos sistemas produtivos nesses estados.

O feijão é uma das principais culturas alimentares do Brasil. No semiárido, é cultivado em praticamente todas as propriedades familiares, devido a boa tolerância à seca e ao ciclo curto, que permite flexibilidade no plantio, embora dependa das chuvas e das temperaturas. De acordo com o IBGE (2025), Bahia, Ceará e Pernambuco foram os principais produtores do Nordeste em 2024, com 162.794, 80.778 e 59.045 toneladas de feijão, respectivamente. A produtividade apresentou grande variação entre os estados, registrando 280 kg/ha na Bahia e 250 kg/ha no Rio Grande do Norte, valores significativamente inferiores à média nacional, que supera 1.000 kg/ha (CONAB, 2025).

Em 2024, a produção de feijão em todo o Semiárido foi de cerca de 350 mil toneladas, cultivadas em uma área superior a um milhão de hectares. A maior parte dessa produção concentra-se na safra do período chuvoso, entre fevereiro e junho, com predomínio da agricultura de sequeiro (EMBRAPA, 2025).

A mandioca se destaca por sua rusticidade e resistência à seca, possuindo elevada capacidade de adaptação ao solo e às condições climáticas do Semiárido. A cultura é cultivada

² De acordo com Hernani, Souza e Cecco (2021), o regime de consórcio baseia-se no cultivo concomitante de diferentes culturas na mesma área, ao mesmo tempo. Essa diversificação possibilita ao agricultor a redução de riscos causadas pelas irregularidades climáticas.

tanto em pequenas propriedades quanto em sistemas produtivos estruturados, desempenhando papel fundamental na subsistência das famílias rurais, além de sua importância econômica como matéria-prima para produtos alimentícios e industriais (EMBRAPA, 2025).

Em 2024, o Ceará liderou a produção nordestina de mandioca, com 817.857 toneladas, seguido pela Bahia e por Pernambuco, com 806.471 e 649.589 toneladas, respectivamente. No mesmo período, Bahia, Paraíba e Pernambuco registraram produtividades médias entre 10.000 e 12.000 kg/ha, resultando em uma produção regional estimada em cerca de 800 mil toneladas (IBGE, 2025).

O milho, embora altamente demandante de água, é amplamente cultivado no Semiárido, especialmente em rotação com o feijão. No entanto, sua produtividade em sequeiro sofre grande variabilidade, fortemente condicionada à distribuição das chuvas. Segundo a EMBRAPA (2025), a cultura possui várias utilizações, desde a alimentação animal até a indústria de alta tecnologia, e tem importância especial em regiões de baixa renda, como o Nordeste, onde tem produção significativa tanto na agricultura de subsistência quanto no agronegócio.

Em 2024, Bahia, Maranhão e Piauí foram os principais produtores de milho no Nordeste, com 2.631.104, 2.384.065 e 1.667.634 toneladas, respectivamente (IBGE, 2025). A produtividade média regional variou entre 600 e 800 kg/ha, muito abaixo da média nacional, que ultrapassa 5.000 kg/ha (CONAB, 2025).

As culturas de feijão e milho são consideradas lavouras temporárias, com ciclo inferior a um ano, já a mandioca tem um ciclo mais longo, que pode durar até dezoito meses. Essas lavouras são replantadas em cada ano agrícola, sendo prática comum entre os agricultores a reserva de sementes de feijão e milho, bem como de estacas de mandioca, para os plantios subsequentes, com seleção das sementes e mudas mais produtivas (Lemos, 2020).

Por fim, é preciso ressaltar que a baixa produtividade das lavouras no semiárido decorre principalmente da irregularidade das chuvas, da limitada tecnologia e da fragilidade do apoio técnico e financeiro disponível aos produtores, evidenciando a necessidade de políticas públicas de inovação, acesso ao crédito e adoção de técnicas adaptadas à Região.

Com base no referencial teórico, na contextualização analítica e nas evidências empíricas, a seção seguinte apresenta a metodologia da pesquisa e os procedimentos adotados na análise.

3 METODOLOGIA

Nesta seção, apresentam-se as estratégias metodológicas que fundamentam o alcance dos objetivos propostos na presente tese. Ademais, em cada subseção, descrevem-se a área de estudo, a base de dados e as variáveis utilizadas, as técnicas estatísticas e econométricas, bem como os procedimentos metodológicos adotados.

3.1 Área de estudo

Este estudo abrange os estados da Bahia, Ceará, Maranhão, Pernambuco e Piauí, considerando exclusivamente os municípios inseridos na área de atuação do Banco do Nordeste do Brasil (BNB), em cada um desses estados, que são atendidos pelo Programa Agroamigo.

A delimitação geográfica justifica-se pelo fato de esses estados concentrarem, simultaneamente, o maior número de operações contratadas e o maior volume de recursos aplicados pelo Agroamigo em 2024, respondendo, respectivamente, por 23,7% (Bahia), 12% (Ceará), 10,4% (Maranhão), 11,7% (Pernambuco) e 11% (Piauí) do total de recursos contratados no período. Em conjunto, essas unidades federativas concentraram aproximadamente 69% do volume total de recursos aplicados pelo Programa no referido ano. Considerando os municípios atendidos em 2024, a amostra é composta por 1.208 municípios, distribuídos da seguinte forma: Bahia (400 municípios), Ceará (184), Maranhão (217), Pernambuco (183) e Piauí (224).

Ressalte-se que o número de municípios atendidos pelo Agroamigo, em cada estado que compõe o espaço amostral da pesquisa, varia ao longo do período analisado, uma vez que, embora a delimitação espacial da amostra considere os municípios atendidos em 2024, a análise temporal abrange todos os municípios beneficiados nesses estados entre 2005 e 2024, correspondendo aos 20 anos de atuação do Programa.

3.2 Base de dados e descrição das variáveis

A pesquisa utiliza dados secundários provenientes do Programa Agroamigo, entre 2005 e 2024, disponibilizados pelo BNB, e da Pesquisa Agrícola Municipal (PAM), fornecidos pelo Instituto Brasileiro de Geografia e Estatística (IBGE), abrangendo o período de 1985 a 2024. A partir dessas fontes, são extraídas informações sobre as variáveis agrícolas, que possivelmente influenciaram a alocação dos recursos oriundos do Agroamigo.

Os valores nominais foram corrigidos, utilizando o Índice Geral de Preços (IGP-DI) da Fundação Getúlio Vargas (FGV), tendo como período de referência dezembro de 2024. O Quadro 3 apresenta as variáveis utilizadas nesta pesquisa, assim como suas respectivas fontes.

Quadro 3 – Descrição das variáveis da base de dados

Definição e unidade de medida	Fonte	Período
Número de contratos do Agroamigo	BNB (2025)	2005 a 2024
Valor contratado pelo Agroamigo (R\$)	BNB (2025)	2005 a 2024
Valor médio anual de contratos do Agroamigo (R\$)	BNB (2025)	2005 a 2024
Salário mínimo anual (R\$)	IBGE (2025)	2005 a 2024
Produtividade da terra no cultivo de arroz, feijão, mandioca e milho (kg/ha)	PAM/IBGE (2025)	1985 a 2024
Valor da produção por hectare de arroz, feijão, mandioca e milho (R\$/ha)	PAM/IBGE (2025)	1985 a 2024

Fonte: Dados compilados a partir de BNB (2025a) e IBGE (2024).

No que se refere às variáveis relacionadas ao Agroamigo, o número de contratos reflete a abrangência do microcrédito em termos de beneficiários, enquanto o valor contratado expressa o volume de recursos efetivamente disponibilizado nos municípios ao longo do período analisado. O valor médio anual de contratos do Agroamigo possibilita compreender o montante médio de recursos por operação, permitindo avaliar a intensidade financeira do crédito concedido no âmbito do Programa. Em conjunto, essas variáveis permitem avaliar o potencial do crédito como instrumento de fortalecimento da capacidade produtiva nos estados analisados.

Os valores médios anuais contratados pelo Agroamigo são relacionados ao salário mínimo anual, com o objetivo de avaliar a variação do poder de compra real dos valores contratados, ao longo das últimas duas décadas. Com esse procedimento, busca-se reduzir distorções decorrentes de efeitos inflacionários, tendo em vista que os valores monetários foram atualizados para 2024, usando o IGP-DI como indexador. Dessa forma, torna-se possível captar a evolução do crédito em termos reais, permitindo uma análise mais consistente da capacidade de investimento proporcionada pelo Programa, ao longo dos 20 anos da sua atuação.

A dimensão da área disponível para a produção agrícola permite compreender as possibilidades produtivas dos agricultores familiares, que decidem, para cada ano, as áreas que irão plantar com as lavouras de que dispõem, contudo, essas decisões são condicionadas,

sobretudo, pela limitada disponibilidade de terra. Assim, assume-se neste estudo que a instabilidade associada ao tamanho da área agrícola disponível é um fator gerador de instabilidade na atividade de sequeiro dos agricultores, em geral, e daqueles que tiveram acesso ao Agroamigo nos municípios analisados.

Nesse contexto, a produtividade da terra das lavouras analisadas corresponde à razão entre produção (kg) e área colhida (ha), refletindo o nível tecnológico empregado. Na agricultura de sequeiro, essa variável depende de fatores parcialmente controláveis pelos agricultores, como a qualidade das sementes, as técnicas de cultivo e o acesso a insumos agrícolas.

Ressalte-se que o controle desses fatores enfrenta limitações estruturais, como restrições financeiras, que dificultam o acesso a tecnologias mais eficientes, e a dependência das condições climáticas, em um contexto de chuvas escassas e elevadas temperaturas. Isso ocorre porque o regime de sequeiro não dispõe de tecnologias de irrigação, que lhe garantiriam maior eficiência técnica, conforme a teoria neoclássica de produção.

Além disso, as tecnologias de cultivo são, em grande parte, rudimentares, baseadas em variedades de baixo valor genético e em práticas tradicionais, como o uso do fogo na limpeza das áreas, que compromete a fertilidade do solo e agrava a vulnerabilidade produtiva. Dessa forma, essas instabilidades típicas do semiárido interagem com essas limitações e, assim, pressupõe-se que esses fatores geram oscilações significativas na produtividade da terra ao longo do tempo.

O valor da produção por hectare (VPH), que corresponde à razão entre o valor da produção (R\$) e a área colhida (ha) de cada lavoura, é utilizado nesta pesquisa como uma *proxy* da renda bruta dos agricultores familiares, mas pode também ser considerada renda líquida, tendo em vista que esse segmento de agricultores apresenta, em geral, custos relativamente reduzidos, ou quase nulos, concentrados principalmente na aquisição de insumos básicos. Como utilizam a própria força de trabalho, não têm despesas com mão de obra contratada. Esse conjunto de fatores permite confirmar que o VPH está muito próximo da renda líquida familiar.

Ademais, os preços de culturas como arroz, feijão, mandioca e milho variam ao longo dos anos, em decorrência de instabilidades de mercado e da variabilidade climática, fatores exógenos ao controle dos produtores. Assim, o VPH reflete flutuações associadas a mudanças nas áreas colhidas, na produtividade e nos preços, de modo que valores mais elevados por hectare indicam, em termos relativos, uma melhor situação econômica do agricultor ao longo do período estudado.

Por definição, o valor da produção de um produto agrícola “i” (VP_i), em

determinado período, corresponde ao produto entre a quantidade produzida (QD_i) e o seu preço médio anual (PR_i), conforme a seguinte expressão:

$$VP_i = (QD_i).(PR_i) \quad (2)$$

Definido dessa forma, o valor da produção constitui na receita bruta anual proporcionada pela produção e venda do produto. Dividindo-se ambos os lados da Equação (2) pela área colhida (AR_i), mensurada em hectares (ha), chega-se ao seguinte resultado:

$$(VP_i)/ha = VPH = [(QD_i)/ha].(PR_i) \quad (3)$$

A relação $(QD_i)/ha$, representa, por definição, a produtividade do fator terra ou, simplesmente, a produtividade da terra. Tomando o logaritmo natural da Equação (3) e derivando-a em relação ao tempo (T), obtém-se:

$$d\log(VPH)/dT = d\log[(QD_i)/ha]/dT + d\log(PR_i)/dT \quad (4)$$

Conceitualmente, a derivada de uma variável aleatória em relação ao tempo corresponde à sua taxa geométrica de crescimento instantânea (Wooldridge, 2016). Assim, a Equação (4) indica que a taxa de crescimento do valor da produção por hectare (VPH) de uma atividade agrícola é determinada pela soma da taxa de crescimento da produtividade da terra e da taxa de crescimento do preço.

Sabe-se que os agricultores somente podem interferir na produtividade através do uso de melhores sementes, da adoção de técnicas adequadas de cultivo ou do recebimento de assistência técnica em tempo hábil. Contudo, não possuem controle sobre a variabilidade climática, tampouco sobre os preços dos produtos que produzem e vendem, uma vez que atuam em mercados competitivos, sendo tomadores de preços ou ajustadores de quantidades, deparando-se, assim, com uma curva de demanda infinitamente elástica em relação ao preço (Varian, 2019).

Portanto, os resultados econômicos das atividades agrícolas dependem da eficiência técnica (maior produtividade por unidade de área) e dos preços de mercado dos produtos comercializados. Nesse sentido, a conversão da produção física em valores monetários torna-se fundamental para a avaliação do desempenho econômico das lavouras.

3.3 Técnicas estatísticas e econométricas aplicadas à pesquisa

Esta subseção apresenta as técnicas estatísticas e econométricas utilizadas no estudo. São empregadas estatísticas descritivas, Taxas Geométricas de Crescimento (TGC) e o modelo Vetorial Autorregressivo (VAR), estimado por Redes Neurais Artificiais (RNA). Além disso, utiliza-se a Análise Fatorial (AF) e aplica-se o teste t de Student.

3.3.1 Estatística descritiva e Taxa Geométrica de Crescimento (TGC)

A estatística descritiva tem por objetivo caracterizar e sintetizar as características principais observadas em um conjunto de dados, permitindo uma melhor compreensão do seu comportamento do conjunto de dados (Fávero *et al.*, 2009). Neste estudo, estimam-se as médias aritméticas, os valores mínimos, máximos, os desvios-padrões e os coeficientes de variação das variáveis estudadas.

A Taxa Geométrica de Crescimento (TGC) permite aferir os percentuais de incremento ou de redução média anual das variáveis analisadas ao longo do período estudado. Para estimar a TGC, parte-se do modelo apresentado na Equação (5):

$$Y_{it} = \beta_i \cdot e^{(\rho T + \epsilon_{it})} \quad (5)$$

Tomando-se o logaritmo natural (base “e”) da Equação (5), obtém-se ao seguinte resultado:

$$\log(Y_{it}) = \log(\beta_i) + \rho T + \epsilon_{it} \quad (6)$$

Derivando-se a Equação (6) em relação ao tempo “T”, obtém-se a TGC, conforme demonstrado a seguir:

$$d\{\log(Y_{it})\}/dT = \rho \quad (7)$$

Na Equação (6), o coeficiente “ $\log\beta_i$ ” é o parâmetro log-linear do modelo que afere o valor da variável $\log(Y_{it})$ no período inicial (período zero), no i-ésimo município. A constante “e” se refere à base dos logaritmos naturais, cujo valor é de aproximadamente 2,718. A variável “T” ($T = 0, 1, 2, \dots, n$) representa o tempo que, nesta pesquisa, corresponde aos anos analisados.

O coeficiente angular “ ρ ” será multiplicado por 100 e interpretado como a TGC anual (em % a.a.) de Y_{it} .

De acordo com Wooldridge (2016), o termo aleatório (ϵ_{it}) é o erro que, por hipótese, tem distribuição normal com média zero, variância constante (homoscedasticidade) e ausência de autocorrelação ao longo do período analisado. Uma vez atendidas essas pressuposições, a Equação (5), após experimentar a modificação mostrada na Equação (6), pode ser estimada utilizando o método dos Mínimos Quadrados Ordinários (MQO). Tomando-se o modelo de tendência linear especificado na Equação (7) estima-se o coeficiente β e avalia-se a existência de mudança estrutural na evolução das variáveis.

Ressalta-se que, valores da TGC estatisticamente diferentes de zero e positivos indicam que as variáveis apresentam comportamento sustentável ao longo dos anos. Quando estatisticamente diferentes de zero e negativos, sinalizam que não são sustentáveis. Por sua vez, valores da TGC estatisticamente iguais a zero (não significantes), implicam afirmar que as variáveis são estáveis, sem tendência significativa de crescimento ou declínio no período analisado.

A estatística t , calculada como a razão entre o coeficiente estimado e seu respectivo erro-padrão, avalia se o parâmetro difere estatisticamente de zero. O p -valor expressa o grau de evidência empírica contra a hipótese nula, constituindo critério formal para a tomada de decisão nos testes de significância. O coeficiente de determinação (R^2 ajustado), indica a proporção da variação da variável dependente que é explicada pelos regressores (Greene, 2018; Wooldridge, 2016). Essas estatísticas são amplamente empregadas na econometria aplicada para avaliar a significância individual dos coeficientes e a qualidade do ajuste global do modelo.

Seguindo a prática consolidada na literatura, a hipótese nula deve ser rejeitada por meio de p -valor com no máximo 10% de significância ou, de forma equivalente, quando o valor absoluto da estatística t exceder o valor crítico correspondente (Gujarati; Porter, 2011).

3.3.2 Estrutura híbrida VAR–RNA para modelagem e previsão

A escolha metodológica desta pesquisa foi orientada pelas características dinâmicas e interdependentes das variáveis analisadas, uma vez que, em razão dessa complexidade, diversos modelos econométricos tradicionais não se mostraram adequados para responder aos objetivos propostos.

O modelo clássico de regressão linear, embora amplamente empregado, pressupõe exogeneidade dos regressores, ou seja, assume que as variáveis explicativas não são

influenciadas pela variável dependente. Contudo, na dinâmica econômica real, as variáveis interagem de forma simultânea, o que pode gerar correlação entre os regressores e o termo de erro, violando pressupostos do método dos Mínimos Quadrados Ordinários (MQO) e comprometendo a consistência das estimativas. Além disso, séries econômicas frequentemente são não estacionárias, o que torna inadequado o uso desse modelo, podendo produzir relações aparentes ou enganosas (Gujarati; Porter, 2011).

Modelos univariados de séries temporais, como ARIMA, são reconhecidos pela capacidade preditiva em séries isoladas, mas não captam causalidade temporal entre variáveis, sendo insuficientes para analisar fenômenos interdependentes. De forma semelhante, modelos de dados em painel, sejam de efeitos fixos ou aleatórios, embora eficazes para capturar heterogeneidade entre unidades espaciais, tratam de maneira limitada a dinâmica temporal e pressupõem relações estruturais que nem sempre refletem a evolução de longo prazo das variáveis (Wooldridge, 2016).

Diante dessas limitações, torna-se necessária a adoção de uma abordagem capaz de incorporar simultaneamente a dinâmica temporal e a interdependência entre as variáveis analisadas. Nesta pesquisa, utiliza-se o Modelo Vetorial Autorregressivo (VAR) como ferramenta econométrica, considerando a hipótese de que existam relações temporais e espaciais entre as variáveis.

De forma específica, essa escolha se justifica porque os agricultores familiares, ao cultivarem lavouras, em grande parte voltadas para a segurança alimentar, fazem-no em áreas consorciadas. Sendo assim, haverá interferências entre as produções e, em decorrência, entre as produtividades dessas lavouras. Além disso, os agricultores, ao tomarem suas decisões de cultivo, consideram os resultados mais recentes das suas atividades. Isso sugere a presença de comportamento autorregressivo nessas decisões, em linguagem econométrica.

Os vetores autorregressivos são estimados por meio de Redes Neurais Artificiais (RNA), empregadas na previsão das variáveis analisadas. Essa estratégia preserva a estrutura multivariada do VAR, ao mesmo tempo em que incorpora a flexibilidade das RNA, que capta relações não lineares e interdependências entre as séries temporais, ao contrário do que faz a análise econométrica convencional. Assim, a combinação dessas metodologias possibilita previsões mais robustas e aderentes à dinâmica dos sistemas agrícolas.

Dessa forma, utilizam-se duas abordagens complementares nesta pesquisa: um modelo econométrico linear, o Modelo Vetorial Autorregressivo (VAR), e um modelo de previsão computacional não linear, baseado em Redes Neurais Artificiais (RNA). Na sequência, descrevem-se as características desses modelos.

3.3.2.1 Modelo Vetorial Autorregressivo (VAR)

O Modelo Vetorial Autorregressivo (VAR) é uma das especificações dos modelos multivariados aplicados a séries temporais, amplamente reconhecido na literatura e utilizado para análises envolvendo intervenções, ciclos econômicos, avaliação de programas e previsão de séries temporais, sendo particularmente pertinente em estudos que analisam dinâmicas de médio e longo prazo (Gujarati; Porter, 2011; Stock; Watson, 2019).

Diferentemente dos modelos univariados, o modelo admite que o comportamento presente de cada variável seja explicado tanto por suas próprias defasagens quanto pelas defasagens das demais variáveis do sistema, característica relevante em análises econômicas nas quais os fenômenos apresentam relações de interdependência e retroalimentação. Além disso, parte do pressuposto de que todas as variáveis do sistema são endógenas, evitando a imposição de uma estrutura causal prévia, como ocorre, por exemplo, em sistemas de equações simultâneas (Sims, 1980; Enders, 2014, Gujarati; Porter, 2011).

Ressalta-se que alguns conceitos são cruciais ao entendimento necessário para a elaboração de modelo de previsão, tal como se propõe nesta pesquisa. Um processo estocástico ou aleatório é definido como uma coleção de variáveis aleatórias ordenadas no tempo. De modo geral, deve ser estacionário, ou seja, apresentar média e variância constantes no tempo, enquanto a covariância não depende do tempo em si, mas apenas da distância temporal, do intervalo ou da defasagem entre dois períodos (Gujarati; Porter, 2011).

Morettin e Tolo (2006) mencionam que as séries temporais possuem características específicas, dentre as quais se destacam: a tendência, indicando que, ao longo do tempo, a série pode apresentar uma direção definida (crescente ou decrescente); ciclos e sazonalidade, que podem ser de curta ou longa duração; e o erro, conhecido como “ruído aleatório” ou “ruído branco”, que contempla as variações naturais da série e não pode ser modelado.

Enders (2014) afirma que o VAR é especialmente adequado para sistemas em que as variáveis se influenciam mutuamente ao longo do tempo, permitindo lidar com endogeneidade, explorar defasagens e estimar respostas dinâmicas a choques. Wooldridge (2016) destaca que o modelo oferece maior flexibilidade analítica, uma vez que sua estrutura matricial permite a realização de previsões multivariadas, análise de funções impulso-resposta e testes de estabilidade.

Embora o VAR clássico pressuponha que todas as variáveis sejam incluídas com o mesmo número de defasagens, a literatura econométrica reconhece que restrições podem ser impostas à estrutura dinâmica do modelo. Assim, não é necessário manter todas as defasagens,

especialmente quando estas não contribuem de forma significativa para a explicação ou previsão das séries (Sims, 1980; Enders, 2014; Stock; Watson, 2019). Ademais, o termo autorregressivo se deve à aparência do valor defasado da variável dependente no lado direito e o termo vetor deve-se ao fato de que se está lidando com um vetor de duas (ou mais) variáveis.

De forma geral, o modelo VAR de ordem p pode ser expresso conforme a Equação a seguir:

$$Y_t = c + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + \epsilon_t \quad (8)$$

Onde Y_t é um vetor ($n \times 1$) contendo as n variáveis do modelo no tempo t ; c é um vetor ($n \times 1$) de constantes; $A_1, A_2, \dots, A_p$ é uma matriz ($n \times n$) de coeficientes associadas às defasagens; Y_{t-1} representa os valores das variáveis no período anterior ($t-1$), influenciando diretamente Y_t e assim por diante até Y_{t-p} , dependendo do número de defasagens incluídas no modelo; p é o número de defasagens incluídas no modelo e ϵ_t é um vetor ($n \times 1$) de termos de erro, assumido como ruído branco.

Embora os modelos lineares permaneçam fundamentais para a análise estrutural e interpretação econômica das relações entre variáveis, a presença de não linearidades e a elevada variabilidade observada nas séries agrícolas impõem limitações à sua capacidade explicativa e preditiva. Nesse sentido, a adoção de abordagens complementares torna-se relevante para ampliar a capacidade de modelagem e previsão dessas dinâmicas.

3.3.2.2 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) têm sido amplamente utilizadas na modelagem de séries temporais, especialmente na presença de relações não lineares. Nos últimos anos, a literatura aplicada tem avançado no uso dessas técnicas para representar padrões complexos que não são adequadamente captados por modelos lineares tradicionais.

Diversos estudos indicam que modelos híbridos ou totalmente baseados em redes neurais apresentam desempenho superior na previsão de séries (Zhang, 2003; Sanjeev; Bhardwaj, 2022; Phesa; Woyessa; Mbatha, 2022). Awe e Dias (2022) demonstram que as RNA superam o modelo ARIMA na previsão da produção agrícola, enquanto Wang *et al.* (2024) evidenciam sua capacidade de captar sazonalidade e eventos extremos, como secas e precipitações intensas.

Em abordagens multivariadas, a integração entre modelos autorregressivos e redes neurais amplia a capacidade analítica ao permitir a representação simultânea de relações lineares e não lineares. Estudos recentes também incorporam algoritmos de otimização das arquiteturas de RNA, ampliando seu desempenho preditivo (Feitosa; Lemos, 2025).

As RNA fazem parte da inteligência artificial computacional e são utilizadas na previsão de séries temporais, uma vez que conseguem modelar padrões complexos sem impor uma forma funcional rígida, mesmo em contextos nos quais as variáveis mudam ao longo do tempo (Lee *et al.*, 2017).

De acordo com Feitosa e Lemos (2025), as RNA são algoritmos computacionais que agregam conhecimento ao identificar padrões e correlações nos dados, sendo treinadas por meio da experiência. O modelo consiste em centenas de neurônios artificiais (ou nós) interconectados em camadas hierárquicas, onde cada neurônio tem uma função de saída e a conexão entre os nós tem um peso, constituindo a memória da rede, sendo por meio desses pesos que se reflete o grau de influência que uma célula exerce sobre a outra.

As RNA são inspiradas no funcionamento do cérebro humano, compostas por unidades de processamento (neurônios artificiais) interligadas por conexões (pesos sinápticos) entre si, nos quais se armazena o conhecimento adquirido no processo de aprendizagem, permitindo fazer generalizações com base em conhecimento previamente acumulado. Dessa forma, cada neurônio recebe sinais de entrada, os processa por meio de uma função de ativação e produz uma saída, que alimenta outros neurônios (Sharda; Patil, 1992).

O desempenho preditivo da RNA é condicionado a um conjunto de decisões de modelagem, tais como número de camadas ocultas, número de neurônios, funções de ativação, definição da arquitetura da rede, algoritmo de treinamento, tamanho da amostra, divisão entre conjuntos de treino e teste e escolha das métricas de avaliação.

a) Função de ativação

Na estrutura da RNA as entradas em neurônios j em camadas ocultas podem ser linearmente combinadas a partir da Equação (9):

$$Z_j = b_j + \sum w_{ij} Y_i \quad (9)$$

Em que w_{ij} representam os pesos sinápticos associados às conexões e b_j o termo de ajuste.

Esses parâmetros são estimados na etapa de aprendizagem, com base nos dados observados da série temporal em análise. Na camada oculta, a Equação (9) é modificada por meio de uma função de ativação não linear, sendo adotada, neste estudo, a tangente hiperbólica, por ser amplamente utilizada na literatura, conforme apresentado na Equação (10) a seguir:

$$S(Z) = 1 / (1 + e^{-Z}) \quad (10)$$

A Equação (10), por sua vez, serve de entrada para a camada seguinte, constituindo uma estratégia que tende a reduzir os efeitos de valores extremos de entrada, proporcionando um melhor funcionamento da rede e, por consequência, um melhor ajustamento.

Assim, os modelos neurais incorporam a não linearidade das variáveis por meio das funções de ativação de cada neurônio da rede e da sua estrutura em camadas sucessivas. Portanto, a função de ativação define como um neurônio transforma o sinal de entrada em sinal de saída.


b) Arquitetura da rede

A arquitetura da rede adotada nesta pesquisa é do tipo Multilayer Perceptron (MLP), que constitui o modelo mais utilizado em aplicações de previsão. De acordo com Miranda, Jaramillo e Peñuela (2021), a combinação entre capacidade de representação não linear e um processo de treinamento eficiente mantém o MLP como uma ferramenta robusta para modelagem, o que explica o interesse em estudos recentes que retomam essa arquitetura para pesquisas em séries temporais.

Uma MLP típica possui uma camada de entrada (*input layer*), que recebe as variáveis explicativas (em modelos causais) ou os valores defasados da própria série (em séries temporais); uma ou mais camadas ocultas (neurônios ocultos), onde ocorre o processamento não linear; e a camada de saída (*output layer*), que produz o resultado final, ou seja, a previsão (Zhang; Patuwo; Hu, 1998).

A Figura 2 ilustra o que seria um exemplo de uma estrutura da RNA com n entradas, uma camada oculta, onde se processam as análises, e uma saída. Os coeficientes associados às variáveis de entrada correspondem aos pesos, selecionados através de um algoritmo de aprendizagem.

Figura 2 - Estrutura da Rede Neural Artificial com uma camada oculta



Fonte: Elaboração própria, com base em Miranda, Jaramillo e Peñuela (2021).

O algoritmo de treinamento da rede MLP utilizado neste estudo é o *backpropagation* (retropropagação de erros), que realiza uma passagem direta para gerar previsões e, em seguida, retropropaga o erro pelas camadas da rede, calculando os gradientes de cada peso por meio da regra da cadeia. Esses gradientes orientam o ajuste iterativo dos parâmetros por métodos de otimização, aprimorando progressivamente o desempenho da rede (Liu; Cocea, 2017; Renner *et al.*, 2024; Tolstikhin *et al.*, 2021).

Desse modo, o *backpropagation* utiliza o gradiente descendente e estima o erro nas camadas intermediárias, assim como o efeito que estes erros causam no erro da camada de saída, sendo este calculado e, na sequência, é retropropagado para as camadas anteriores, permitindo o ajuste dos pesos proporcionais aos valores das conexões entre as camadas.

Portanto, o treinamento de uma rede consiste em ajustar os pesos das conexões de forma a minimizar uma função de erro baseada na Soma dos Erros ao Quadrado, definida na Equação (11):

$$E = \frac{1}{2} \sum_{i=n+1}^N (y_i - a_i)^2 \quad (11)$$

Em que ai é a saída produzida pela rede e o termo $1/2$ apenas simplifica o cálculo das derivadas no algoritmo de treinamento.

Assim, o treinamento da RNA é dividido em duas etapas: *forward*, que propaga os sinais por toda a rede, da camada de entrada até a saída, gerando as previsões e o erro associado; e *backward*, etapa em que os erros são retropropagados da saída para a entrada, promovendo o ajuste dos pesos da rede (Braga; Toneto Jr., 2000).

Em síntese, a retropropagação dos erros realiza os ajustes de pesos nas camadas intermediárias, minimizando o erro entre as séries temporais previstas e observadas. Dessa forma, as RNA funcionam como modelos de regressão não lineares, em que o treinamento de uma rede neural é, na prática, um problema de minimização não linear sem restrições.

c) Processo de treinamento da rede neural

Antes do treinamento, os dados passam por procedimentos de pré-processamento, normalização e definição dos conjuntos de treino e teste. O método de reescalonamento é padronizado, em que as variáveis são transformadas para média igual a zero (0) e desvio padrão igual a um (1). Essa padronização garante estabilidade numérica, pois evita que variáveis em escalas distintas dominem o processo de aprendizado, tendo em vista que as redes neurais são sensíveis à escala dos dados.

Os grupos de treinamento e de teste permitem avaliar a qualidade do ajuste do modelo durante o processo de aprendizagem, bem como sua capacidade de generalização, ou seja, a habilidade de reproduzir padrões fora da amostra.

A amostra de treinamento é utilizada para desenvolver o modelo neural, enquanto a amostra de teste destina-se à avaliação da capacidade de previsão. Os dados são divididos aleatoriamente em dois subconjuntos, sendo 70% das observações destinadas ao treinamento da rede e 30% para o teste do desempenho preditivo, proporção amplamente adotada na literatura (Liu; Cocea, 2017).

De acordo com Kang e Pham (1991), o tamanho da amostra depende da estrutura da rede, do método de treinamento, da complexidade dos padrões e do nível de ruído dos dados, sendo necessárias amostras maiores quanto maior for a complexidade e o ruído. Os autores destacam que RNA pode precisar de menos dados do que modelos lineares, uma vez que funciona bem com menos de cinquenta (50) observações, enquanto modelos Box-Jenkins normalmente requerem amostras superiores a esse limite para um desempenho adequado.

O processo inicia-se com a entrada de dados, na qual são inseridas as covariáveis, que se referem às variáveis explicativas do modelo.

Na camada intermediária, a arquitetura da rede gera automaticamente uma camada oculta composta por um determinado número de neurônios, dentro de um intervalo previamente estabelecido, cujo limite máximo é de cinquenta (50) unidades. Desse modo, realizam-se simulações com diferentes números mínimos de entrada, para cada variável analisada, de forma que o algoritmo avalie diferentes configurações nesse intervalo e selecione aquela que apresentar menor erro de previsão, correspondendo ao número de neurônios ocultos com melhor desempenho preditivo.

A função de ativação adotada na camada oculta é a tangente hiperbólica e a função de erro é a soma dos quadrados, que minimiza o erro quadrático médio entre os valores previstos e observados.

A camada de saída é responsável por fornecer o valor predito pela rede neural em função das entradas, sendo então composta por um neurônio correspondente à variável dependente analisada, isto é, aquela estimada pelo modelo. A função de ativação é a identidade, que caracteriza um modelo de regressão.

A importância relativa das variáveis independentes mede quanto cada variável de entrada contribui para a previsão da variável de saída, considerando a estrutura da rede neural. Os pesos são decompostos e normalizados, de modo que a soma das contribuições para cada variável resposta seja igual a um (1), o que permite a comparação direta entre os preditores.

d) Medidas de avaliação do desempenho do modelo

Realizada a etapa de treinamento, o desempenho do modelo é avaliado por meio de métricas quantitativas, incluindo o coeficiente de correlação de Pearson (r), a Raiz do Erro Quadrático Médio (RMSE), o Erro Absoluto Médio (MAE) e a Porcentagem do Erro Absoluto Médio (MAPE).

O coeficiente de correlação de Pearson (r) mede a intensidade e a direção da relação linear entre valores observados e estimados, variando entre -1 e + 1, de modo que valores próximos de + 1 indicam forte correlação positiva, ou seja, maior capacidade explicativa do modelo, enquanto valores próximos de - 1 indicam forte correlação negativa (Greene, 2018; Stock; Watson, 2019). Esse coeficiente é calculado pela razão entre a covariância das variáveis e o produto de seus desvios-padrão, conforme a Equação (12).

$$r = \frac{\sum_i^N (X_i - X_{med}) \cdot \sum_i^N (Y_i - Y_{med})}{\sqrt{\sum_i^N (X_i - X_{med})^2 \cdot \sum_i^N (Y_i - Y_{med})^2}} \quad (12)$$

As métricas RMSE, MAE e MAPE, apresentadas nas Equações (13), (14) e (15), respectivamente, avaliam a capacidade preditiva do modelo. O RMSE mede a magnitude média dos erros, calculado pela diferença da raiz quadrada média entre os valores previstos e observados, fornecendo uma visão geral da precisão. O MAE expressa a média dos desvios absolutos entre esses valores, indicando o erro médio da previsão. Por fim, o MAPE quantifica o erro em termos percentuais, facilitando a interpretação. Em todos os casos, quanto menores os valores dessas métricas, maior a capacidade preditiva do modelo estimado (Pham *et al.*, 2018; Stock; Watson, 2019; Tripathy; Prusty, 2021; Elsaraiti, 2024).

RMSE

$$= \sqrt{\frac{1}{n} \sum_{i=1}^n (v_{observed} - v_{predicted})^2} \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |v_{observed} - v_{predicted}| \quad (14)$$

MAPE

$$= \frac{1}{n} \sum_{i=1}^n \left| \frac{v_{observed} - v_{predicted}}{v_{predicted}} \right| * 100 \quad (15)$$

Espera-se que os resultados dos testes de erro indiquem desempenho satisfatório da rede, com desvios relativamente moderados entre valores observados e estimados. Ressalta-se que a interpretação dessas métricas considera as diferenças de escala entre as variáveis analisadas, o que pode resultar em erros absolutos mais elevados em determinados indicadores, sem prejuízo da avaliação relativa da acurácia preditiva.

As produtividades médias das lavouras, estimadas através de RNA, são agregadas por meio do método de Análise Fatorial (AF), tendo em vista tratar-se de atividades distintas, em que as médias aritméticas não seriam adequadas para fazer a agregação. Utiliza-se a

metodologia de AF através da técnica de Decomposição em Componentes Principais (DCP). Feitosa e Lemos (2025) demonstram que a combinação entre AF e RNA constitui uma abordagem eficiente para reduzir a dimensionalidade dos dados e a multicolinearidade entre as variáveis.

3.3.3 *Análise Fatorial (AF) com extração por componentes principais*

A Análise Fatorial é uma técnica multivariada de interdependência que busca sintetizar as relações observadas entre um conjunto de variáveis interrelacionadas, identificando fatores comuns (Viali, 2002). O resultado sintetiza o efeito conjunto das variáveis, exigindo a compreensão do impacto coletivo e da contribuição de cada variável para o resultado global.

Segundo Maroco (2007), trata-se de uma técnica de análise exploratória de dados que objetiva avaliar a estrutura das variáveis, de modo a construir uma escala de medida para fatores que, de alguma forma, controlam as variáveis originais. A partir das correlações observadas entre as variáveis originais, a AF estima fatores comuns que não são diretamente observáveis.

O principal objetivo da utilização da Análise Fatorial (AF) nesta pesquisa é atribuir pesos às variáveis de forma estatística, e não arbitrária, com base na interdependência entre elas. Após a preparação dos dados, realizam-se testes de normalidade e linearidade para validar o uso da AF, uma vez que desvios nesses quesitos podem reduzir as correlações entre as variáveis e comprometer a qualidade da solução (Fávero *et al.*, 2009).

O procedimento de análise fatorial estima a participação relativa da variável por meio dos escores fatoriais, na definição do fator. São os coeficientes associados aos escores fatoriais que são transformados em pesos, quando levados para a base unitária. Nesse caso, os pesos gerados são utilizados nas variáveis originais, não nas latentes (Lemos, 2020).

Agrupar as variáveis em função de suas correlações, implica que aquelas que compõem um mesmo fator sejam altamente correlacionadas entre si e fracamente correlacionadas com as variáveis associadas a outros fatores (Fávero *et al.*, 2015). Segundo Johnson e Wichern (2007), um fator representa a combinação linear das variáveis originais, representando dimensões latentes (*constructos*) que resumem ou explicam o conjunto original de variáveis observadas.

A modelagem da análise fatorial pode ser representada através da Equação (16), da seguinte forma:

$$X_i = \alpha_i F + \varepsilon_i \quad (16)$$

Em que X_i é i -ésimo escore da variável analisada; F é o fator aleatório comum para todas as variáveis medidas; ε_i é o componente aleatório. Normalmente, $E(\varepsilon_i) = E(F) = 0$; α_i é a constante chamada de carga fatorial (*loading*), que mede a importância dos fatores na composição de cada variável (correlação).

O modelo considera que p variáveis observáveis ($X_1, \dots, X_p$), extraídas de uma população com vetor de média μ e matriz de covariância Σ , são linearmente dependentes de algumas variáveis não observáveis $F_1, \dots, F_m$, denominadas de fatores comuns, e de p fatores adicionais de variação $\varepsilon_1, \dots, \varepsilon_p$, denominadas de erros ou fatores específicos (Johnson; Wichern, 2007).

A carga fatorial α_i representa o peso da variável i no fator j , ou seja, o grau de correlação entre as variáveis originais e os fatores. Efetuando a padronização de X (média 0 e desvio padrão 1), o modelo fatorial passa a ser descrito, genericamente, por meio da Equação (17):

$$X_i = \alpha_{i1}F_1 + \alpha_{i2}F_2 + \dots + \alpha_{im}F_m + \varepsilon_i \quad (i=1, \dots, p) \quad (17)$$

Neste caso, X_i representa as variáveis padronizadas, α_i as cargas fatoriais, F_m os fatores comuns e ε_i os fatores específicos. De acordo com Maroco (2007), o modelo assume as seguintes premissas: os fatores comuns (F_k) são independentes (ortogonais) e igualmente distribuídos, com média 0 e variância 1 ($k = 1, \dots, m$); os fatores específicos (ε_i) são independentes e igualmente distribuídos, com média 0 e variância ψ_i ($i = 1, \dots, p$); F_k e ε_i são independentes; e o termo ψ_i representa a variância de ε_i , ou seja, $\text{Var}(\varepsilon_i) = \psi_i$.

Os fatores são estimados por combinação linear das variáveis, mostrados na Equação (18):

$$\begin{aligned} F_1 &= d_{11}X_1 + d_{12}X_2 + \dots + d_{1m}X_i \\ F_2 &= d_{21}X_1 + d_{22}X_2 + \dots + d_{2m}X_i \\ &\vdots \\ F_m &= d_{m1}X_1 + d_{m2}X_2 + \dots + d_{mi}X_i \end{aligned} \quad (18)$$

Em que F_m são os fatores comuns, d_{mi} os coeficientes dos escores fatoriais e X_i as

variáveis originais. O escore fatorial resulta da multiplicação dos coeficientes d_{mi} pelo valor das variáveis originais. No caso de mais de um fator, o escore corresponderá às coordenadas da variável em relação aos eixos (fatores).

A comunalidade representa uma estimativa da variância X_i , que é explicada pelos fatores comuns sendo, portanto, um índice da variabilidade total explicada por todos os fatores para cada variável. A análise das comunalidades busca averiguar se alguma variável não compartilha um percentual considerável de variância com os fatores extraídos. Em caso de as comunalidades serem baixas, comparadas às demais, sugere-se reconsiderar a inclusão da respectiva variável na análise fatorial (Fávero; Belfiore, 2017).

Quando da aplicação da AF, assim como em outras técnicas multivariadas, deve-se verificar a premissa da distribuição normal das variáveis e analisar a existência de *outliers* e possíveis vieses na distribuição dos dados, pois esses fenômenos podem distorcer os resultados ao afetarem as estimativas das médias, dos desvios-padrão e, conseqüentemente, das covariâncias e correlações.

Fávero *et al.* (2009) afirmam que, para que seja feita a AF da maneira adequada, é preciso efetuar os seguintes passos: analisar a matriz de correlações, confirmando que não se trata de matriz identidade; verificar a estatística Kaiser-Meyer-Olkin (KMO), cujo valor crítico deve ser maior que 0,5; realizar o teste de esfericidade de Bartlett, em que rejeita a hipótese de matriz de correlação ser identidade a 5% de significância; analisar a matriz anti-imagem; e avaliar o percentual de explicação da variação acumulada dos componentes estimados.

Com base nesses resultados, geram-se os pesos a partir dos componentes, ou dos escores fatoriais. A matriz de correlações deve ser analisada para verificar se existem valores significativos que justifiquem o uso da técnica. Espera-se que variáveis altamente correlacionadas compartilhem o mesmo fator, uma vez que a matriz mede a associação linear entre as variáveis por meio do coeficiente de correlação de Pearson. Assim, se a matriz de correlações não revelar valores superiores a 0,30, há fortes indícios de inadequação da técnica.

A estatística Kaiser-Meyer-Olkin (KMO), apresentada na Equação (19), compara as correlações fracas com as correlações fortes, avaliando se a amostra é adequada ao grau de correlação parcial entre as variáveis. Valores próximos de zero (0) indicam que a AF não é adequada (correlação fraca), enquanto valores próximos de um (1), sinalizam maior adequação da técnica. Os intervalos de análise dos valores da estatística KMO são observados no Quadro 4.

$$KMO = \frac{\sum_{i \neq j} \sum r_{ij}^2}{\sum_{i \neq j} \sum r_{ij}^2 + \sum_{i \neq j} \sum a_{ij}^2} \quad (19)$$

Em que r_{ij} é o coeficiente de correlação simples entre as variáveis; e a_{ij} é o coeficiente de correlação parcial.

Quadro 4 - Intervalos da estatística KMO para a adequação da Análise Fatorial

Estatística KMO	Adequação para a Análise Fatorial
1 – 0,9	Muito boa
0,8 – 0,9	Boa
0,7 – 0,8	Média
0,6 – 0,7	Razoável
0,5 – 0,6	Má
<0,5	Inaceitável

Fonte: Fávero et al (2009).

A aplicação do teste de esfericidade de Bartlett busca analisar a matriz de correlações e verificar a adequação da AF, de forma a avaliar a hipótese de que a matriz das correlações pode ser a matriz identidade com determinante igual a 1 (um).

Os fundamentos técnicos da análise fatorial estão na correlação entre as variáveis que são utilizadas. Para que a técnica seja viável é necessário que a matriz de correlação entre as variáveis não seja uma identidade (Hahn; Riederer; Foster, 2009; Guillaumont; Simonet, 2011).

Caso a matriz seja uma identidade, as interrelações entre as variáveis são iguais a zero (0), o que inviabiliza a aplicação da AF. Assim, se a hipótese nula (H_0 : a matriz de correlações é uma matriz identidade) não for rejeitada, conclui-se que as variáveis não estão correlacionadas e, nesse caso, não seria adequado o uso da técnica. Mas, se a hipótese nula for rejeitada, haverá indícios da existência de correlações significativas entre as variáveis originais, desde que seja atendida a premissa de normalidade multivariada.

Outro requisito da AF consiste na análise da matriz de correlações anti-imagem, que fornece indícios acerca da necessidade de eliminação de variáveis do modelo, ao apresentar os valores negativos das correlações parciais. Espera-se que, quanto maiores os valores da diagonal principal, melhor será a utilização da técnica. Contudo, ressalta-se que uma baixa correlação de determinada variável com as demais não implica, necessariamente, sua exclusão,

uma vez que esta variável pode representar um fator isoladamente.

O método adotado para extração dos fatores é a Decomposição em Componentes Principais (DCP), que considera a variância total dos dados e busca combinações lineares das variáveis observadas que maximizem a variância explicada, entendida como uma medida de dispersão que indica o “quão longe” os seus valores se encontram do valor esperado (Fávero *et al.*, 2009). Assim, quando as variáveis forem altamente correlacionadas, serão combinadas em um fator que explicará a maior parcela da variância amostral. O segundo componente explicará a segunda maior parcela e será não correlacionado ao primeiro, e assim sucessivamente.

A elaboração de um indicador sintético, como o proposto neste trabalho, envolve a necessidade de se trabalhar com várias unidades de medida, o que ocasiona um problema ao consolidar os dados, tornando indispensável sua padronização em uma escala comum. Neste trabalho, adota-se a técnica de Max-Min, ou transformação 0-1, para padronizar o índice estimado.

Os fatores produzidos na fase de extração nem sempre são facilmente interpretados. Nesse sentido, a aplicação de um método de rotação tem como objetivo principal transformar os componentes principais retidos em uma estrutura mais simples, na qual os fatores gerados são independentes e ortogonais, facilitando sua interpretação (Fávero *et al.*, 2009).

De acordo com Matos e Rodrigues (2019), existem dois métodos de rotação dos fatores: ortogonal e oblíquo. Neste estudo, adota-se a rotação ortogonal, por proporcionar uma estrutura de fácil interpretação. Nesse tipo de rotação, os fatores iniciais são transformados em novos fatores independentes, mantendo-se as comunalidades e a proporção da variância total explicada. O método rotacional ortogonal empregado é o Varimax, que busca minimizar o número de variáveis com cargas elevadas em cada fator, no intuito de simplificar a interpretação dos fatores gerados.

3.3.4 *Teste t de Student*

O teste t de Student é amplamente utilizado para a avaliação de diferença estatística entre duas médias dependentes ou independentes, sendo representado por meio da Equação (20)

$$t = \frac{\bar{X}_1 - \bar{X}_2}{EP(\bar{X}_1 - \bar{X}_2)} \quad (20)$$

Em que o numerador consiste na diferença entre as médias dos grupos analisados e

o denominador representa o erro padrão (EP) da diferença entre essas duas médias (Morettin; Bussab, 2014).

Para o caso de variâncias diferentes, o erro padrão pode ser definido diretamente pelas variâncias dos grupos, conforme demonstrado na Equação (21):

$$EP_{(\bar{X}_1 - \bar{X}_2)} = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \quad (21)$$

Em que $EP_{(\bar{X}_1 - \bar{X}_2)}$ é o erro padrão da diferença entre as médias; s_1^2 e s_2^2 são as variâncias do grupo 1 e grupo 2, respectivamente; e n_1 e n_2 são os números de casos no grupo 1 e no grupo 2, respectivamente.

O valor da estatística t obtido após o cálculo é comparado com o valor de t_{critico} tabelado, localizado com o uso dos graus de liberdade e o nível de significância adotado na pesquisa (Morettin; Bussab, 2014).

Os graus de liberdade para o caso de variâncias diferentes podem ser definidos por meio da expressão apresentada na Equação (22):

$$GL = \frac{(a + b)^2}{\frac{a^2}{n_1 - 1} + \frac{b^2}{n_2 - 1}} \quad (22)$$

Onde GL se refere aos graus de liberdade; a é a razão da variância com o número de indivíduos do grupo 1; e b é a razão da variância com o número de indivíduos do grupo 2.

3.4 Procedimentos metodológicos

3.4.1 Procedimentos metodológicos para atingir o primeiro objetivo específico

Conforme discutido na primeira seção, o primeiro objetivo específico deste estudo consiste em analisar a evolução do Agroamigo entre 2005 e 2024, considerando sua expansão territorial, a dinâmica dos contratos e dos recursos financeiros, bem como a participação dos municípios situados no Semiárido e a relevância econômica do Programa para os agricultores familiares.

Para esse fim, utilizam-se estatísticas descritivas, de forma a identificar os

municípios atendidos nos estados da área de atuação do BNB que obtiveram valores extremos quanto ao número de contratos, ao total de recursos captados e aos valores médios contratados. Além disso, busca-se evidenciar padrões de homogeneidade e heterogeneidade na distribuição desses recursos entre os municípios.

Estima-se a Taxa Geométrica de Crescimento (TGC) do número de municípios, em cada estado, que acessaram recursos do Agroamigo nas duas últimas décadas, bem como do total de contratos firmados e dos valores médios dessas operações. Esse procedimento tem como objetivo mensurar a evolução dessas variáveis ao longo do período analisado.

O valor médio contratado pelos municípios beneficiados (VM_{it}) é mensurado pela razão entre o montante dos valores contratados (VC_{it}) e o número de contratos realizados pelo Agroamigo (NC_{it}), conforme a Equação (23).

$$VM_{it} = VC_{it}/NC_{it} \quad (23)$$

Em seguida, estima-se a relação entre os valores médios dos contratos (VM_{it}) e os respectivos salários mínimos anuais, corrigidos para o ano-base de 2024. Essa relação permite avaliar a variação do poder de compra real dos valores contratados ao longo do período analisado.

Para aferir a participação relativa dos municípios do Semiárido na captação dos recursos do programa entre 2005 e 2024, são identificados, em cada estado, o número de municípios beneficiados e os volumes de recursos contratados naqueles oficialmente reconhecidos como integrantes desse regime climático. Computam-se os municípios localizados no Semiárido que são atendidos pelo Agroamigo, em cada unidade federativa analisada.

De forma a avaliar a distribuição espacial dos municípios que acessaram os recursos do Agroamigo, os dados são agregados anualmente por estado. Considerando apenas os municípios efetivamente atendidos pelo Programa em 2024, identificam-se 1.997 municípios.

Esses municípios são distribuídos em quintis e hierarquizados em três categorias: quantidade de contratos, valor total contratado e valor médios dos contratos. O procedimento de classificação é realizado em duas etapas: (i) ordenação dos municípios em ordem crescente de seus respectivos valores; (ii) distribuição dos casos em cinco estratos (quintis) de forma aproximadamente equitativa.

Como o total de municípios (1.997) não é múltiplo de cinco, adotaram-se os seguintes critérios: o primeiro quintil (Q1) corresponde ao grupo de municípios com os menores

valores de número de contratos, volume financeiro contratado e valor médio por contrato, sendo composto por 400; os quintis intermediários (Q2, Q3 e Q4) também são formados por 400 municípios cada; o último quintil (Q5) reúne as unidades com os maiores valores dessas variáveis, sendo composto por 397 municípios, totalizando os 1.997 municípios da área de estudo.

A partir dessa classificação, elaboram-se figuras que representam a distribuição espacial dos municípios por quintis em cada categoria analisada. A partir dessa análise exploratória, observa-se que os estados da Bahia, Ceará, Maranhão, Pernambuco e Piauí concentraram os maiores volumes de operações e recursos do Programa em 2024. Dessa forma, considerando os municípios beneficiados nesses estados nesse ano, a amostra do presente estudo é composta por 1.208 municípios portanto, 60,5% do total de municípios beneficiados pelo programa, distribuídos da seguinte forma: Bahia (400 municípios), Ceará (184), Maranhão (217), Pernambuco (183) e Piauí (224).

Assim, esses estados passam a compor o espaço amostral da análise, permitindo investigar os impactos do Agroamigo nas dinâmicas produtivas em cada unidade federativa analisada. Ressalta-se, contudo, que o número de municípios atendidos em cada estado varia ao longo do período entre 2005 e 2024, uma vez que a delimitação espacial da amostra considera o ano de 2024, enquanto a análise temporal abrange todos aqueles que acessaram o Programa ao longo dos 20 anos de sua atuação.

3.4.2 Procedimentos metodológicos para atingir o segundo objetivo específico

O segundo objetivo específico deste estudo busca aferir as relações entre as variáveis que definem a produção agrícola nos principais estados beneficiados pelo Programa Agroamigo. Para tanto, as variáveis analisadas são produtividade e valor da produção por hectare (VPH), utilizado como proxy da renda agrícola. As lavouras selecionadas são arroz, feijão, mandioca e milho, que se destacam pela importância para a agricultura familiar de sequeiro no Semiárido.

Obtidas as médias anuais por cultura, não se recomenda estimar médias aritméticas de produtividade e de VPH, uma vez que se trata de produtos heterogêneos. Além disso, as lavouras de sequeiro, em geral, são cultivadas de forma consorciada, o que reforça a existência de interações entre essas culturas. Ademais, as variáveis agrícolas influenciam-se mutuamente, apresentam defasagens temporais, respondem a choques climáticos e econômicos e reagem ao crédito ao longo do tempo. Assim, parte-se da premissa de que existem relações temporais e

espaciais entre essas variáveis. Para captar essas sinergias, a agregação das variáveis nos estados selecionados é realizada por meio do Modelo Vetorial Autorregressivo (VAR).

As estruturas dos vetores autorregressivos utilizadas para estimar as produtividades e os VPH das lavouras estão especificadas nas Equações (24) a (31), a seguir.

$$Y1_t = \alpha_0 + \alpha_1 Y1_{(t-1)} + \alpha_2 Y2_t + \alpha_3 Y3_t + \alpha_4 Y4_t + \epsilon_{1t} \quad (24)$$

$$Y2_t = \beta_0 + \beta_1 Y2_{(t-1)} + \beta_2 Y1_t + \beta_3 Y3_t + \beta_4 Y4_t + \epsilon_{2t} \quad (25)$$

$$Y3_t = \lambda_0 + \lambda_1 Y3_{(t-1)} + \lambda_2 Y1_t + \lambda_3 Y2_t + \lambda_4 Y4_t + \epsilon_{3t} \quad (26)$$

$$Y4_t = \rho_0 + \rho_1 Y4_{(t-1)} + \rho_2 Y1_t + \rho_3 Y2_t + \rho_4 Y3_t + \epsilon_{4t} \quad (27)$$

$$X1_t = \alpha_0 + \alpha_1 X1_{(t-1)} + \alpha_2 X2_t + \alpha_3 X3_t + \alpha_4 X4_t + \epsilon_{1t} \quad (28)$$

$$X2_t = \beta_0 + \beta_1 X2_{(t-1)} + \beta_2 X1_t + \beta_3 X3_t + \beta_4 X4_t + \epsilon_{2t} \quad (29)$$

$$X3_t = \lambda_0 + \lambda_1 X3_{(t-1)} + \lambda_2 X1_t + \lambda_3 X2_t + \lambda_4 X4_t + \epsilon_{3t} \quad (30)$$

$$X4_t = \rho_0 + \rho_1 X4_{(t-1)} + \rho_2 X1_t + \rho_3 X2_t + \rho_4 X3_t + \epsilon_{4t} \quad (31)$$

Em que, $Y1_t$ = Produtividade do arroz no ano t ; $Y2_t$ = Produtividade do feijão no ano t ; $Y3_t$ = Produtividade de mandioca no ano t ; $Y4_t$ = Produtividade de milho no ano t ; $X1_t$ = VPH de arroz no ano t ; $X2_t$ = VPH de feijão no ano t ; $X3_t$ = VPH de mandioca no ano t ; e $X4_t$ = VPH de milho no ano t .

Adota-se, portanto, um modelo autorregressivo multivariado estruturado em vetores, no qual cada variável de determinada lavoura é explicada por sua própria defasagem, enquanto as demais culturas são incorporadas de forma contemporânea. Essa especificação permite captar interações simultâneas decorrentes do cultivo consorciado, típico das lavouras de sequeiro.

Os vetores autorregressivos são estimados por meio de Redes Neurais Artificiais (RNA). Para a previsão de cada variável (produtividade e VPH) a rede neural a ser estimada apresenta três neurônios na camada de entrada nos estados do Ceará, Bahia e Pernambuco, correspondentes às variáveis explicativas do modelo, que se referem às lavouras de feijão,

mandioca e milho. Nos estados do Maranhão e Piauí, em que a cultura do arroz é inserida, a rede neural apresenta quatro neurônios na camada de entrada.

A partir da estimação do modelo, são construídos os cenários antes e depois do Agroamigo. Para tanto, definem-se dois grupos de análise: o Grupo de Controle (GC), correspondente ao período *ex ante* (1985 a 2004), quando os municípios ainda não tinham acesso ao Programa; e o Grupo Experimental (GE), referente ao período *ex post* (2005 a 2024), em que os municípios passaram a ser beneficiados pelo Agroamigo.

A comparação desses recortes temporais busca identificar mudanças estruturais ocorridas após a inserção do Agroamigo, identificadas por meio das trajetórias das variáveis ao longo do tempo, como aceleração ou desaceleração da produtividade e renda agrícola nos estados selecionados. Ademais, utiliza-se uma variável *dummy* (D) com a seguinte definição: D = 0 para os valores estimados para o GC; e D = 1 para os valores estimados para o GE.

Com o objetivo de capturar as sinergias entre as produtividades previstas nos grupos GC e GE, constrói-se o Índice de Produtividade (INPR), no qual as produtividades de cada lavoura são agregadas por meio da Análise Fatorial (AF), com extração dos fatores pela Decomposição em Componentes Principais (DCP).

Os escores fatoriais estimados podem assumir valores negativos e positivos. Assim, para construir um índice em escala positiva, adota-se o procedimento descrito na Equação (32), considerando a hipótese de ser gerado apenas um fator.

$$INPR = (X - X_{MÍN}) / (X_{MÁX} - X_{MÍN}) \quad (32)$$

Na Equação (27), o Índice de Produtividade (INPR) varia entre zero (0) e um (1), de modo que valores mais próximos de um indicam maior sinergia entre as variáveis analisadas e os recursos do Agroamigo. Além disso, a fim de facilitar o entendimento, o índice é transformado em valores percentuais, com o maior valor gerado igual a 100, conforme a Equação (33):

$$INPR_{j100} = \left(\frac{IR_j}{IR_{jMÁXIMO}} \right) \times 100 \quad (33)$$

Inicialmente, o Índice de Produtividade (INPR) será estimado para cada estado por meio de Análise Fatorial. Entretanto, caso os pressupostos estatísticos necessários à aplicação dessa técnica não sejam atendidos, será adotado um procedimento alternativo de construção do

índice.

Nesse caso, será realizada a normalização das variáveis, conforme descrito anteriormente na Equação (33), de forma a padronizar os indicadores em uma mesma escala, possibilitando sua comparação e agregação na construção do índice.

A partir dessa normalização, serão obtidos os Índices de Produtividade individuais para cada cultura analisada e, em seguida, será construído o Índice de Produtividade Agregada (INPR), com o objetivo de sintetizar o desempenho conjunto das lavouras consideradas. Esse índice será calculado por meio da média geométrica dos índices parciais, conforme apresentado na Equação (34):

$$INPR_{agregado} = \left(\prod_{i=1}^n IP_i \right)^{\frac{1}{n}} \quad (34)$$

Em que IP_i representa o índice de produtividade da cultura i e n corresponde ao número total de culturas consideradas na análise.

A utilização da média geométrica permite sintetizar o desempenho conjunto das culturas analisadas, equilibrando a contribuição de cada variável no índice final e reduzindo a influência de valores extremos, procedimento amplamente utilizado na construção de indicadores compostos, como no cálculo do Índice de Desenvolvimento Humano (IDH) (OECD, 2008; UNDP, 2024).

Para estimar o Valor da Produção Agregado (VPA), por se tratar de valores monetários, que constituem unidades homogêneas, não há necessidade de construir um índice. Assim, a agregação das rendas das lavouras é obtida a partir da soma linear do VPH de cada cultura analisada, conforme apresentado na Equação (35):

$$VPA_j = VP_{aj} + VP_{fj} + VP_{maj} + VP_{mij} \quad (35)$$

Em que VPA_j é o valor da produção agregado, que consiste na média dos valores de produção no ano j ; VP_{aj} é o valor da produção do arroz no ano j ; VP_{fj} é o valor da produção do feijão no ano j ; VP_{maj} é o valor da produção da mandioca no ano j ; e VP_{mij} é valor da produção do milho no ano j .

3.4.3 Procedimentos metodológicos para atingir o terceiro objetivo específico

O terceiro objetivo específico desta pesquisa consiste em comparar a relação entre o Índice de Produtividade (INPR) e o Valor da Produção Agregado (VPA), considerando os períodos anterior e posterior ao acesso dos estados ao Programa Agroamigo. Com esse propósito, busca-se verificar a existência de diferenças estatisticamente significativas entre as médias do INPR e do VPA, estimados para o grupo experimental (GE) e o grupo de controle (GC), por meio do teste t de Student. Parte-se da hipótese de que a média estimada para o GE deve ser maior, numérica e estatisticamente, à média observada para o GC.

Portanto, a hipótese nula (H_0) consiste na igualdade entre as médias das variáveis antes e após o acesso ao Programa Agroamigo, considerando os mesmos beneficiários. O teste é realizado separadamente para o INPR e para o VPA, conforme apresentado na Equação (36):

$$H_0: \mu_1 - \mu_2 = 0 \quad (36)$$

Em que,

μ_1 é a média do INPR e VPA após o acesso ao Agroamigo; e

μ_2 é a média do INPR e VPA antes do acesso ao Agroamigo.

4 RESULTADOS E DISCUSSÃO

Os resultados são apresentados e discutidos nesta seção, organizados segundo a mesma sequência dos objetivos propostos na seção de introdução deste trabalho de doutorado, e em consonância com os procedimentos metodológicos definidos para cada problema específico de pesquisa, conforme exposto na seção 3.

4.1 Resultados obtidos para o primeiro objetivo específico

As evidências apresentadas na Tabela 1 demonstram a evolução no número de municípios, em cada um dos estados, que captaram recursos do Programa Agroamigo, no período de 2005 a 2024. Nessa tabela, também são mostradas as TGC estimadas para essa evolução das captações em cada estado.

Tabela 1 – Evolução na quantidade de municípios que captaram recursos do Agroamigo entre 2005 e 2024

Ano/Estados	AL	BA	CE	ES	MA	MG	PB	PE	PI	RN	SE	Total anual
2005	18	20	27	0	27	5	28	47	49	33	9	263
2006	56	151	114	12	91	37	78	93	100	91	59	882
2007	52	176	131	6	92	51	99	101	94	93	62	957
2008	62	189	150	5	124	72	133	112	131	99	67	1144
2009	67	294	164	0	169	102	181	128	206	140	74	1525
2010	95	386	181	0	194	159	223	178	222	158	75	1871
2011	95	399	182	0	200	167	221	181	224	161	75	1905
2012	97	400	182	0	212	165	223	184	224	159	75	1921
2013	101	406	182	10	214	167	223	185	223	161	74	1946
2014	99	406	183	15	213	168	223	185	223	163	75	1953
2015	100	408	181	13	217	168	223	185	222	165	74	1956
2016	98	404	181	12	217	167	223	184	223	166	75	1950
2017	95	405	183	14	217	168	222	183	224	166	73	1950
2018	97	405	182	9	217	168	222	184	224	165	74	1947
2019	92	400	182	20	216	167	223	182	224	162	74	1942
2020	92	400	182	21	217	168	222	182	224	165	73	1946
2021	96	398	183	23	217	167	222	182	224	164	73	1949
2022	96	399	182	23	217	189	222	182	224	164	71	1969
2023	94	399	182	21	217	202	223	183	224	166	68	1979
2024	96	400	184	27	217	207	222	183	224	166	71	1997
TGC (% a.a)	4,4	7,5	4,0	7,3	5,9	10,2	5,9	4,3	4,8	4,4	3,3	5,5

Fonte: Elaboração própria, de acordo com os dados do BNB (2025a).

Dos resultados mostrados na Tabela 1, depreende-se que o estado de Minas Gerais

experimentou a maior taxa de aceleração na capitação dos recursos do Agroamigo (10,2% a.a.) entre os anos de 2005 e 2024. Por outro lado, Sergipe (TGC= 3,3% a.a.) e Ceará (TGC = 4,0% a.a.) apresentaram as menores taxas de aceleração na inserção do Programa no período estudado.

A situação de Sergipe pode ser explicada pelo fato de que apenas recentemente seis dos seus municípios passaram a ser oficialmente inseridos no regime climático do Semiárido, região que constitui uma das principais prioridades para a aplicação dos recursos do Programa Agroamigo. Minas Gerais, por sua vez, experimentou uma significativa inserção por parte do CONDEL/SUDENE dos seus municípios no Semiárido (Tabela 1).

Observa-se, ainda, que a TGC média de inserção dos municípios em todos os estados avaliados no Programa foi de 5,5% a.a., uma taxa alta, que evidencia a expressiva demanda por microcrédito por parte dos agricultores familiares, os quais dependem desses recursos para alcançar avanços em termos de inclusão econômica e social.

A Tabela 2 mostra a evolução do Agroamigo ao longo das duas últimas décadas, em que são apresentadas as evoluções das quantidades de contratos, dos valores totais e médios dos contratos, bem como as TGC dessas variáveis entre 2005 e 2024. Mostram-se ainda os valores anuais dos salários mínimos e a participação relativa dos valores médios anuais do Agroamigo em salários mínimos anuais.

Tabela 2 – Quantidade de contratos, valores totais de contratos, valores médios anuais dos contratos, salário mínimo anual e valor médio dos contratos em salários mínimos no período de 2005 a 2024

(Continua)

Ano	Quantidade de Contratos	Valor contratado (mil R\$)	Valores médios dos contratos em Reais	Salário mínimo anual	Valor médio dos contratos em salários mínimos
(1)	(2)	(3)	(4) = (3)/(2) x 1000	(5)	(6) = (5)/(4)
2005	18.035	59.300,58	3.288,08	7.991,12	0,41
2006	138.721	504.647,82	3.637,86	9.164,30	0,4
2007	192.736	828.509,03	4.298,67	9.468,44	0,45
2008	182.947	727.138,30	3.974,58	9.296,25	0,43
2009	286.175	1.249.495,41	4.366,19	10.132,56	0,43
2010	329.105	1.591.207,04	4.834,95	10.719,92	0,45
2011	366.681	1.907.479,35	5.202,01	10.495,63	0,5
2012	375.088	2.127.948,58	5.673,20	11.242,66	0,5
2013	421.486	2.743.459,80	6.509,02	11.452,70	0,57
2014	406.408	3.185.247,84	7.837,56	11.431,58	0,69

Tabela 2 – Quantidade de contratos, valores totais de contratos, valores médios anuais dos contratos, salário mínimo anual e valor médio dos contratos em salários mínimos no período de 2005 a 2024

(Conclusão)					
2015	448.593	3.575.793,90	7.971,13	11.952,98	0,67
2016	481.639	3.484.315,80	7.234,29	12.114,26	0,6
2017	518.697	4.053.043,50	7.813,89	12.771,47	0,61
2018	507.097	4.180.283,36	8.243,56	12.292,49	0,67
2019	495.684	3.916.355,24	7.900,91	15.822,43	0,5
2020	564.896	4.008.435,66	7.095,88	15.851,35	0,45
2021	589.752	3.674.050,97	6.229,82	15.142,82	0,41
2022	593.629	3.747.085,64	6.312,17	16.519,76	0,38
2023	585.759	5.772.623,99	9.854,95	17.008,48	0,58
2024	687.884	8.603.252,37	12.506,84	16.944,00	0,74
Total	8.191.012	59.939.674,18	7.317,74	12.390,76	0,59
TGC (%a.a.)	10,6	15,8	5,2	3,7%	1,5

Fonte: Elaboração própria, de acordo com os dados do BNB (2025a).

(*) Valores corrigidos para o ano de 2024, com base no IGP-DI, da Fundação Getúlio Vargas.

(**) Valores médios no período avaliado.

1 - Significante a menos de 1% de erro;


2 - Significante a menos de 5,8% de erro.

Observa-se que a Tabela 2 destaca três aspectos principais da atuação do Programa: a ampliação do número de contratos, a valorização dos contratos e os períodos de adaptação às condições econômicas. As informações revelam um aumento significativo no total de contratos, que passou de 18.035 em 2005 para 687.884 em 2024. Essa rápida expansão, que se deu a uma TGC de 10,6% a.a., evidencia a relevância crescente do Agroamigo como ferramenta de crédito rural para a agricultura familiar.

A Tabela 2 mostra ainda que o total de operações contratadas foi de aproximadamente 8,2 milhões, que demandaram recursos de aproximadamente R\$ 60 bilhões em valores de 2024. O valor médio anual dos contratos foi de R\$ 7.317,74, com TGC de 15,8% a.a. no período analisado.

O Gráfico 1, na sequência, revela que os valores médios dos contratos apresentaram uma trajetória de crescimento até 2018, seguida por uma queda entre os anos de 2018 e 2021. A partir de 2022, no entanto, observa-se uma retomada com um aumento significativamente mais acelerado até 2024.

Gráfico 1 – Evolução dos valores médios dos contratos contraídos do Agroamigo em todos os estados inseridos no Programa entre os anos de 2005 e 2024



Fonte: Elaboração própria, com base na Tabela 2.

Evidencia-se, ainda, que enquanto o salário mínimo anual cresceu a uma taxa média anual de 3,7% a.a., o crescimento do valor médio dos contratos se expandiu a uma TGC de 5,2% ao ano. Contudo, quando se avalia a evolução dos valores médios contratados *vis a vis* os valores reais do salário mínimo, constata-se que a relação evoluiu a uma taxa significativamente inferior, de apenas 1,5% a.a.

Esse comportamento indica que, embora haja incremento nominal nos valores contratados, tal crescimento não acompanha, na mesma proporção, a evolução do poder de compra do valor médio dos contratos representado pelo salário mínimo. Assim, o resultado sugere que os recursos disponibilizados permanecem relativamente limitados frente às necessidades produtivas dos agricultores familiares, evidenciando a persistência de restrições financeiras nesse segmento, o que sinaliza os níveis de dificuldades enfrentadas pelas famílias envolvidas (Tabela 2).

A Tabela 3 apresenta a distribuição dos contratos e dos valores reais aplicados pelo Agroamigo por estado em 2024. Os Gráficos 2 e 3 mostram, respectivamente, as distribuições dos contratos e dos valores contratados em cada estado no mesmo ano. Observa-se que, individualmente, Bahia e Ceará concentraram o maior número de operações contratadas, bem como os maiores volumes de recursos do Programa nesse ano, destacando-se, ainda, os estados de Pernambuco, Piauí e Maranhão. Por outro lado, Sergipe e Espírito Santo registraram os

menores volumes de recursos aplicados e as menores quantidades de operações contratadas.


Tabela 3 – Distribuição dos contratos e valores reais aplicados pelo Programa Agroamigo por estado em 2024

Estados	Quantidade de contratos	(%)	Valor contratado (R\$) *	(%)
BA	164.290	23,88	2.036.527,09	23,67
CE	83.620	12,16	1.035.328,59	12,03
PE	82.591	12,01	1.010.742,05	11,75
PI	77.597	11,28	963.856,05	11,20
MA	65.392	9,51	899.269,27	10,45
MG	60.944	8,86	739.342,34	8,59
PB	61.513	8,94	735.007,65	8,54
RN	37.729	5,48	457.120,82	5,31
AL	31.208	4,54	415.114,79	4,83
SE	22.070	3,21	291.069,59	3,38
ES	930	0,14	19.874,12	0,23
Total	687.884	100,00	8.603.252,37	100,00

Fonte: Elaboração própria, de acordo com os dados do BNB (2025a).


(*) Valores corrigidos para o ano de 2024, com base no IGP-DI, da Fundação Getúlio Vargas.

Gráfico 2 – Quantidades de contratos do Agroamigo em cada estado em 2024



Fonte: Elaboração própria, de acordo com os dados do BNB (2025a).

Gráfico 3 – Valor total de contratos do Agroamigo em cada estado em 2024




Fonte: Elaboração própria, de acordo com os dados do BNB (2025a).

Registre-se que, as variações no número e nos valores dos contratos estão relacionadas às características locais da demanda e às questões operacionais. No que se refere ao aspecto operacional, Melo *et al.* (2023) argumentam que as diferenças de contratação entre os estados podem estar relacionadas aos diferentes procedimentos adotados pelas unidades de atendimento do Agroamigo na disseminação da estratégia de ampliação do Programa. Além desse aspecto, a dimensão territorial dos estados, aliada à elevada dispersão espacial dos agricultores nos territórios, também pode contribuir para as disparidades observadas nas contratações.

As Figuras 3 e 4 apresentam a distribuição espacial dos municípios que acessaram recursos do Agroamigo em 2024, considerando, respectivamente, a quantidade de contratos realizados e o valor total contratado, além do valor médio dos contratos. A classificação dos municípios em quintis permite identificar os diferentes níveis de intensidade das operações e da aplicação de recursos do Agroamigo.

Figura 4 – Distribuição espacial dos valores médios dos contratos do Agroamigo em 2024



Fonte: Elaboração própria, de acordo com os dados do BNB (2025a).

A Figura 3 mostra que, tanto a quantidade de contratos, quanto os valores totais contratados se distribuem de forma heterogênea entre os municípios atendidos pelo Programa. A Figura 4 evidencia maior dispersão territorial, indicando que municípios com menor número de operações podem ter registrado valores médios relativamente mais elevados.

De modo geral, a análise conjunta das Figuras 3 e 4 evidencia a forte presença do Agroamigo no Nordeste, Região em que a agricultura familiar assume maior relevância econômica e social. Verifica-se, ainda, que uma parcela significativa dos municípios classificados nos quintis superiores (Q5), tanto em número de contratos quanto em volume financeiro contratado (Figura 4), concentra-se nos estados da Bahia, Ceará, Maranhão, Pernambuco e Piauí.

Esse padrão na distribuição espacial fundamenta a delimitação empírica adotada neste estudo. Assim, a análise concentra-se nesses cinco estados, que reuniram,

simultaneamente, o maior número de operações contratadas e o maior volume de recursos aplicados pelo Agroamigo em 2024. Considerando os municípios atendidos nesses estados, a amostra é composta por 1.208 municípios, distribuídos da seguinte forma: Bahia (400), Ceará (184), Maranhão (217), Pernambuco (183) e Piauí (224).

Adicionalmente, os resultados encontrados quanto à inserção dos municípios que fazem parte do Semiárido na captação dos recursos do Agroamigo no período investigado estão mostrados na Tabela 4, a seguir. Observa-se que, em 2024, todos os municípios que fazem parte do Semiárido nos estados de Alagoas, Piauí e Sergipe foram beneficiados pelo crédito advindo do Programa Agroamigo. Minas Gerais (82,5%) e Espírito Santo (83,3%) destacam-se como os estados com menor participação de municípios do Semiárido que acessaram recursos do Agroamigo.

Tabela 4 – Total de municípios no Semiárido brasileiro e participação relativa dos municípios com Agroamigo no Semiárido em 2024

Estados	Total de Municípios	Municípios no Semiárido	Municípios Agroamigo no Semiárido em 2024	Participação relativa dos municípios abrangidos pelo Agroamigo em 2024 no Semiárido (%)
(1)	(2)	(3)	(4)	(5) = (4)/(3)x100
Alagoas	102	42	42	100
Bahia	417	287	279	97,2
Ceará	184	175	174	99,4
Maranhão	217	16	16	100
Paraíba	223	198	193	97,5
Pernambuco	185	142	140	98,6
Piauí	224	216	216	100
Rio Grande do Norte	167	148	141	95,3
Sergipe	75	30	30	100
Minas Gerais	853	217	179	82,5
Espírito Santo	78	6	5	83,3
BRASIL	5570	1477	1415	95,8

Fonte: Elaboração própria, de acordo com os dados do BNB (2025a) e de CONDEL/SUDENE (2024).

4.2 Resultados obtidos para o segundo objetivo específico

Os resultados obtidos permitem avaliar as sinergias existentes entre as culturas a partir da estrutura do modelo estimado por redes neurais artificiais (RNA), em que a capacidade explicativa é avaliada por vários testes, incluindo a aderência entre valores observados e

previstos e pelas métricas de erro. O Apêndice A mostra o desempenho das RNA na estimação das produtividades e rendas das lavouras analisadas nos estados do Ceará, Bahia, Pernambuco, Maranhão e Piauí, no período de 1985 a 2024.

De modo geral, observa-se que os coeficientes de correlação de Pearson (r) foram elevados, especialmente nas produtividades, indicando forte associação entre os dados observados e os valores estimados. Em Pernambuco, a produtividade do milho apresentou o melhor resultado (0,855). Maranhão e Piauí registraram melhores ajustes nas produtividades de milho (0,986 e 0,954) e feijão (0,957 e 0,911), respectivamente. Nesses estados, a cultura de arroz também apresentou ajustamento elevado, de 0,814 no Maranhão e 0,900 no Piauí. Esses resultados indicam que a dinâmica produtiva dessas culturas apresenta maior estabilidade ao longo do tempo. Quanto ao VPH, observa-se maior heterogeneidade no Ceará, em que a mandioca obteve correlação de 0,934 e o feijão, 0,568. Nos demais estados, as correlações foram elevadas, variando de 0,952, (arroz no Piauí) a 0,725 (mandioca em Pernambuco), indicando que a dimensão monetária é mais instável, influenciada por fatores como clima, preços e condições de mercado (ver Apêndice A).

No Apêndice B, mostram-se as arquiteturas das redes extraídas para as variáveis analisadas, em que se observa que o número de unidades na camada oculta variou conforme a complexidade da variável estimada. Em alguns casos, o número gerado pelo algoritmo superou o mínimo previamente definido, indicando maior necessidade de processamento para captar padrões não lineares; em outros, manteve-se próximo ao mínimo, sugerindo estrutura suficiente para representação dos dados. Em geral, os resultados confirmam a adequação das RNA na modelagem das variáveis agrícolas analisadas, evidenciando elevada capacidade de ajuste e potencial aplicação para análises preditivas no contexto da agricultura de sequeiro.

O Apêndice C apresenta os resultados dos testes de erro nos grupos de treinamento e teste. No treinamento, a soma dos erros quadráticos associados às produtividades foi relativamente baixa, variando entre 0,71 e 5,82, e um pouco maior para o VPH (entre 1,12 e 11,50), com destaque para a mandioca no Ceará (11,50). Os erros relativos variaram de 0,04 a 0,7 nas produtividades e de 0,09 a 0,77 no VPH, indicando desvios reduzidos entre valores observados e estimados durante o processo de aprendizagem.

No grupo de teste, que avalia o desempenho do modelo fora da amostra utilizada no treinamento, as produtividades mantiveram baixos níveis de erro. Destacam-se o milho no Maranhão, (0,04 de soma dos erros quadráticos e 0,01 de erro relativo), e o arroz no Piauí, além de feijão e milho no Ceará, com erros relativos reduzidos (de 0,02, 0,06 e 0,06, respectivamente). Para o VPH, os erros também foram relativamente baixos, em geral, como

na mandioca no Ceará (0,08) e no milho no Maranhão (0,09), embora o VPH de feijão tenha apresentado valores mais elevados no Piauí (4,29) e em Pernambuco (4,26). Ainda assim, os erros relativos permaneceram baixos, indicando bom desempenho preditivo do modelo, apesar de alguma instabilidade na renda agrícola, possivelmente associada a choques econômicos e institucionais (ver Apêndice C).

A comparação entre os grupos de treinamento e teste mostra que, nas produtividades, não há aumento significativo dos erros fora da amostra, o que indica ausência de sobreajuste e boa capacidade de generalização das redes neurais. No VPH, os erros são um pouco mais elevados em ambos os grupos, refletindo uma maior instabilidade da renda agrícola e a influência de fatores externos, como oscilações de preços e condições de mercado. Não obstante, os erros de previsão mantiveram-se, em geral, em níveis reduzidos nos dois grupos, confirmando a adequação da RNA.

O Apêndice D apresenta os resultados dos testes de acurácia das estimativas, de forma a aferir a qualidade e precisão dos ajustes. Os valores de RMSE e MAE para as variáveis devem ser interpretados considerando o fato de que refletem a magnitude absoluta das variáveis analisadas, razão pela qual culturas com níveis produtivos mais elevados, como a mandioca, apresentam erros absolutos maiores. Assim, a avaliação da precisão das estimativas é mais adequadamente realizada por meio do MAPE, que expressa o erro em termos percentuais.

Para as produtividades, o MAPE variou entre 6,0% e 11,7% no Ceará, 3,0% e 6,3% na Bahia, 6,9% e 13,9% em Pernambuco, 2,8% e 10,2% no Maranhão e entre 9,4% e 14,4% no Piauí, indicando boa precisão das estimativas. Para o VPH, os erros foram mais elevados, entre 8,4% e 23,5%, considerando os estados analisados, sugerindo que, embora o modelo consiga captar parte relevante da dinâmica da renda agrícola, ainda há limitações relacionadas à instabilidade de preços e às condições de mercado, que não são plenamente captadas pelo modelo (ver Apêndice D).

O Apêndice E apresenta a contribuição das variáveis explicativas na previsão das variáveis resposta, evidenciando forte interdependência entre as culturas e o papel das defasagens na capacidade preditiva dos modelos. No Ceará, observa-se a influência cruzada entre as lavouras do feijão e milho, tanto na produtividade quanto na renda. Na Bahia, feijão e mandioca apresentaram maior interdependência, enquanto em Pernambuco há maior articulação entre feijão, mandioca e milho, o que indica uma estrutura produtiva relativamente mais especializada. No Maranhão, a estrutura é mais diversificada, com destaque para o arroz, que teve maior influência nas variáveis relacionadas ao milho, e com pesos mais distribuídos entre as culturas, refletindo maior heterogeneidade produtiva. No Piauí, o milho exerce maior

influência sobre as produtividades de arroz, feijão e mandioca, enquanto o arroz impacta o VPH de mandioca e milho. Em todos os estados, o termo defasado se mostra relevante, indicando que técnicas e disponibilidade hídrica de um ano influenciam o ciclo seguinte, evidenciando a persistência do desempenho das lavouras.

Em geral, quanto maior a inserção do estado no Semiárido e na agricultura de sequeiro, maior tende a ser a concentração dos pesos e a relevância do efeito inercial das culturas, indicando uma dinâmica produtiva marcada por interdependência e pela propagação de choques climáticos e produtivos. Ademais, algumas culturas exercem influência dominante sobre outras, enquanto determinadas variáveis apresentam forte dependência de seus valores defasados. Em conjunto, esses resultados sugerem uma trajetória produtiva cumulativa, influenciada por capital produtivo, experiência técnica acumulada e condições estruturais da atividade agrícola.

O Apêndice F, por fim, apresenta a evolução dos valores observados e previstos das produtividades e dos VPH nos estados analisados. Em geral, a análise gráfica das trajetórias temporais mostra elevada proximidade entre as séries observadas e estimadas, indicando bom desempenho preditivo e robustez das estimativas. Assim, os resultados obtidos são consistentes e servem de base para a construção dos indicadores nas etapas seguintes da análise.

A Tabela 5 mostra os resultados da estimação dos escores fatoriais utilizados na construção do Índice de Produtividade (INPR) para cada estado analisado na pesquisa, bem como as magnitudes de cada variável com o fator isolado e os coeficientes gerados para a construção desses escores. Assim, as variáveis relacionadas às produtividades das lavouras são reunidas em um único fator, sintetizando o comportamento conjunto, o que permite avaliar de forma integrada a dinâmica agrícola.

Tabela 5 - Resultados da AF para a construção do Índice de Produtividade (INPR) nos estados analisados entre 1985 e 2024

(Continua)			
Variáveis	Componentes	Escores	Pesos
Ceará			
Produtividade Feijão	0,93	0,87	0,33
Produtividade Mandioca	0,92	0,85	0,33
Produtividade Milho	0,98	0,95	0,35
KMO	0,67		
Graus de Liberdade (GL)	3		
Qui-Quadrado (QQ)	108,61		
Significância	0,00		

Tabela 5 - Resultados da AF para a construção do Índice de Produtividade (INPR) nos estados analisados entre 1985 e 2024

(Conclusão)			
Variância explicada (%)	88,91		
Bahia			
Produtividade Feijão	0,72	0,51	0,78
Produtividade Mandioca	0,99	0,97	1,07
Produtividade Milho	-0,78	0,61	-0,84
KMO	0,32		
Graus de Liberdade (GL)	3		
Qui-Quadrado (QQ)	75,44		
Significância	0,00		
Variância explicada (%)	69,65		
Pernambuco			
Produtividade Feijão	0,85	0,72	0,32
Produtividade Mandioca	0,87	0,75	0,33
Produtividade Milho	0,94	0,89	0,36
KMO	0,65		
Graus de Liberdade (GL)	3,0		
Qui-Quadrado (QQ)	58,06		
Significância	0,00		
Variância explicada (%)	78,35		
Maranhão			
Produtividade Arroz	0,89	0,79	0,24
Produtividade Feijão	0,97	0,95	0,27
Produtividade Mandioca	0,85	0,73	0,23
Produtividade Milho	0,95	0,90	0,26
KMO	0,74		
Graus de Liberdade (GL)	6,0		
Qui-Quadrado (QQ)	163,21		
Significância	0,00		
Variância explicada (%)	83,96		
Piauí			
Produtividade Arroz	0,98	0,96	0,30
Produtividade Feijão	0,30	0,97	0,30
Produtividade Mandioca	0,11	0,13	0,11
Produtividade Milho	0,28	0,85	0,28
KMO	0,68		
Graus de Liberdade (GL)	6		
Qui-Quadrado (QQ)	170,68		
Significância	0,00		
Variância explicada (%)	72,57		

Fonte: Elaboração própria (2026).

A análise fatorial apresentou boa adequação estatística para a construção do índice na maioria dos estados, com variância explicada superior a 80% no Ceará e no Maranhão, de

72,6% no Piauí, 78,3% em Pernambuco. Na Bahia, embora a variância explicada tenha sido de 69,7%, o KMO abaixo de 0,5 indica que a matriz de correlações é uma identidade, ou seja, que as variáveis ortogonais estão correlacionadas, inviabilizando a aplicação da técnica nesse estado (Tabela 5).

Ceará e Pernambuco apresentaram estrutura fatorial equilibrada, com pesos relativamente homogêneos entre as culturas. No Maranhão, o KMO de 0,74 indica bom desempenho estatístico e adequação amostral consistente. No Piauí, apesar da significância estatística, a menor contribuição da cultura de mandioca sugere menor integração produtiva (Tabela 5).

Os ajustamentos alcançados foram robustos de um ponto de vista estatístico, pois o Teste de Bartlett indica que a hipótese de matriz identidade de correlação entre as variáveis que fazem parte do índice seja rejeitada, com exceção da Bahia. Para este estado, o INPR é estimado através da média geométrica dos índices parciais.

4.3 Resultados obtidos para o terceiro objetivo específico

Os testes de contrastes de médias utilizam os valores previstos antes e depois do Agroamigo, tanto para as produtividades quanto para os valores da produção por hectare, sendo as diferenças associadas aos erros de estimação.

A Tabela 6, abaixo, apresenta os resultados do teste t de Student para amostras emparelhadas, utilizado para verificar a existência de diferenças estatisticamente significativas entre as médias do INPR e do VPA, antes e depois do surgimento do Agroamigo, tendo como hipótese nula a igualdade entre as médias. Os resultados indicam que os efeitos do Programa não foram homogêneos, refletindo dinâmicas produtivas distintas entre os estados.

Tabela 6 - Teste t de amostras emparelhadas nos estados analisados antes e depois do acesso ao Agroamigo

(Continua)

Teste T de amostras emparelhadas					
Pares	Média	Diferença	Estatística T	gl	Sign. (2 extremidades)
Ceará					
INPR antes	64,46	4,88	- 0,77	18	0,449
INPR depois	69,34				
VPA antes	7.294,47	2.379,25	- 2,27	18	0,036
VPA depois	9.673,43				

Tabela 6 - Teste t de amostras emparelhadas nos estados analisados antes e depois do acesso ao Agroamigo

(Conclusão)

Bahia					
INPR antes	51,37	1,08	- 0,11	18	0,907
INPR depois	52,45				
VPA antes	18.472,33	-8.058,88	5,01	18	0,000
VPA depois	10.413,44				
Pernambuco					
INPR antes	74,71	3,22	- 0,91	18	0,375
INPR depois	77,92				
VPA antes	12.308,71	-748,97	0,56	18	0,584
VPA depois	11.559,74				
Maranhão					
INPR antes	66,72	21,46	- 11,02	18	0,000
INPR depois	88,19				
VPA antes	11.544,82	-1.227,39	1,91	18	0,072
VPA depois	10.317,42				
Piauí					
INPR antes	60,68	11,20	- 1,72	18	0,103
INPR depois	71,88				
VPA antes	10.608,70	-2.872,16	2,46	18	0,024
VPA depois	7.736,54				

Fonte: Elaboração própria (2026).

No Ceará, o INPR apresentou aumento médio de 64,46 para 69,34 após o acesso ao Programa, embora sem significância estatística. Entretanto, o VPA apresentou crescimento significativo ao nível de 5%, com aumento médio de R\$ 2.379,25 no estado, indicando valorização econômica da produção, possivelmente associada à ampliação da escala produtiva ou à inserção das lavouras em mercados mais favoráveis (Tabela 6).

Na Bahia, o INPR apresentou leve aumento após o acesso ao Agroamigo, de 51,37 para 52,45, porém sem diferença estatisticamente significativa. Em contraste, o VPA apresentou redução significativa, de 18.472,33 para 10.413,44, o que sugere a influência de fatores estruturais e climáticos sobre o valor da produção. Em Pernambuco, não houve diferenças estatisticamente significativas, apesar de pequena elevação do INPR e leve redução do VPA, indicando que o Programa pode ter atuado mais na manutenção da atividade produtiva do que como um fator de mudança estrutural (Tabela 6).

No Maranhão, o INPR apresentou aumento estatisticamente significativo após o

Agroamigo, com variação média de 21,46, indicando forte resposta produtiva ao crédito. Entretanto, o VPA não foi significativo, o que sugere ganhos de eficiência sem uma valorização monetária correspondente, possivelmente influenciados por políticas de preços. No Piauí, o INPR aumentou após o acesso ao Programa, mas sem significância estatística, enquanto o VPA registrou redução significativa, provavelmente associada a oscilações de mercado (Tabela 6).

De modo geral, os resultados do teste de paridade de amostras indicam que os efeitos do Agroamigo não foram uniformes entre os estados, embora haja evidências pontuais de avanços. O Ceará se destaca pelo aumento do VPA, indicando fortalecimento da renda, enquanto o Maranhão apresentou aumento no INPR, sinalizando maior eficiência produtiva após o crédito. Pernambuco e Piauí registraram variações positivas no INPR, mas sem significância estatística, e a Bahia apresentou redução da renda no período. Assim, os efeitos mais consistentes concentram-se no Ceará e no Maranhão, evidenciando que o impacto do Agroamigo varia entre os estados analisados.

Vale ressaltar que os valores das produções por hectare são influenciados pelos preços dos produtos agrícolas estudados. Esses preços são determinados exogenamente pelas conjunturas de mercado, portanto, independem das vontades dos agricultores. Os resultados do acesso ao crédito rural, de qualquer fonte, inclusive Agroamigo, interferem na forma de produzir e nas tecnologias adotadas, que incrementam as produtividades. Os resultados encontrados mostram que, mesmo nos estados onde as produtividades não foram estatisticamente diferentes antes e depois da inserção do Agroamigo, os valores absolutos observados depois da inserção do Programa nos estados (2005/2024) foram maiores do que os observados antes dessas inserções (1985/2004).

De modo geral, os resultados mostram que o impacto do Agroamigo não é homogêneo entre os estados, uma vez que atua no contexto do Semiárido, marcado por limitações climáticas e estruturais. Assim, em alguns casos, o Programa impulsiona ganhos produtivos; em outros, contribui para a manutenção da atividade diante de condições adversas. Portanto, seus efeitos dependem das condições locais, condicionados por fatores climáticos, institucionais e de mercado. Isso mostra que o crédito, isoladamente, não transforma a realidade produtiva, mas pode potencializar as capacidades já existentes quando associado a um ambiente favorável.

O Apêndice G apresenta o INPR E VPA observado e previsto nos estados analisados antes e depois do Agroamigo, de forma a comparar o comportamento desses indicadores e evidenciar mudanças estruturais relevantes no período posterior à implementação do Programa. No Ceará, o INPR apresentou trajetória crescente ao longo do tempo, em especial após 2005,

com resultados acima do esperado, indicando ganhos consistentes de produtividade. Quanto ao VPA, embora com algumas oscilações ao longo da série, observa-se um crescimento após 2013, sinalizando uma dinamização econômica após a implantação do Agroamigo.

Na Bahia, o INPR apresentou elevada volatilidade ao longo do período. Até os anos 2000, os valores observados ficaram, em geral, acima do previsto, sugerindo um desempenho produtivo superior ao esperado. Contudo, nos anos mais recentes, verifica-se uma queda acentuada, em que o indicador passa a situar-se abaixo do previsto, o que indica perda de dinamismo produtivo e maior instabilidade. Em Pernambuco, o INPR obteve um comportamento cíclico até o início dos anos 2000, com melhoria significativa a partir de 2005, quando os valores observados passam a superar a tendência prevista, indicando ganhos de eficiência produtiva. O VPA apresentou crescimento após 2012, com resultados acima do esperado, indicando fortalecimento da renda agrícola (ver Apêndice G).

No Maranhão, a trajetória estimada do INPR apresenta tendência de queda ao longo do tempo, sugerindo perda de desempenho produtivo. O VPA apresentou redução ao longo dos anos, com recuperação pontual, mas sem um crescimento consistente. No Piauí, o INPR manteve-se relativamente estável, com oscilações e recuperação após 2016. Em alguns anos após a implantação do Agroamigo, os valores observados superaram os previstos, indicando melhora na produtividade. O VPA acompanha esse movimento, especialmente nos anos mais recentes, sinalizando maior dinamismo econômico (ver Apêndice G).

Em geral, os resultados indicam avanços mais consistentes após o Agroamigo no Ceará, Pernambuco e Piauí, onde o INPR e/ou o VPA passam a superar com maior regularidade as trajetórias previstas. Na Bahia, observam-se sinais de recuperação e fortalecimento, embora com maior volatilidade. No Maranhão, não se verifica melhora estrutural após o Programa, mantendo-se um quadro de maior fragilidade nos indicadores analisados.

De forma geral, a comparação entre valores observados e previstos mostra que, nos estados onde os indicadores passam a superar de forma persistente a tendência histórica, há sinais de mudança estrutural positiva, indicando que o Agroamigo contribuiu para fortalecer a capacidade produtiva da agricultura familiar.

Diante dos elementos apresentados ao longo desta tese, apresentam-se, a seguir, as considerações finais, com destaque para os principais achados, suas implicações e algumas sugestões para aprimoramento do Agroamigo.

5 CONSIDERAÇÕES FINAIS

Os resultados evidenciam que o Programa Agroamigo apresentou uma expansão significativa ao longo de seus 20 anos de atuação (2005-2024), ampliando sua abrangência na área de atuação do BNB. Observam-se avanços expressivos tanto no número de contratos firmados quanto no volume de recursos contratados, com crescimento consistente entre 2005 e 2020.

Assim, embora haja incremento nominal nos valores contratados, esse crescimento não acompanha, na mesma proporção, a evolução do poder de compra do valor médio dos contratos, representado pelo salário mínimo. Nesse sentido, os resultados indicam que os recursos disponibilizados permanecem relativamente limitados frente às necessidades produtivas dos agricultores familiares, sugerindo que as famílias beneficiárias do Agroamigo operam em níveis bastante reduzidos de renda.

Por outro lado, a presente pesquisa revela uma expressiva inserção dos municípios atualmente situados no Semiárido na captação de recursos do Programa, o que reforça o papel do Agroamigo como instrumento relevante de apoio às regiões mais vulneráveis.

Ademais, os resultados indicam que a utilização do método de Redes Neurais Artificiais apresentou elevada capacidade de captar a dinâmica da agricultura de sequeiro. Nesse contexto, as produtividades demonstraram comportamento mais estável e previsível quando comparadas à renda agrícola, que se mostrou maior volátil. Essa volatilidade reflete, sobretudo, a influência de fatores externos, como as oscilações dos preços, que experimentam influências de instabilidades pluviométricas e de conjunturas de mercado, que estão fora da capacidade de decisão dos agricultores, em geral, e dos familiares, em particular, como é o foco estudado neste estudo.

Observou-se, ainda, que as lavouras operam de forma interdependente, em que os resultados de uma cultura influenciam diretamente as demais, comprovando a primeira hipótese do estudo, ao evidenciar a existência de relações temporais e espaciais entre as variáveis analisadas, as quais impactam o desempenho das lavouras de sequeiro.

As construções do INPR e do VPA permitiram sintetizar essa dinâmica de forma agregada, evidenciando diferenças estruturais relevantes entre os estados analisados. Em geral, quanto maior a inserção do estado no Semiárido e na agricultura de sequeiro, maior tende a ser a concentração dos pesos e o efeito inercial das culturas, indicando que a dinâmica produtiva é interdependente, o que reforça a existência de sinergias entre as lavouras, bem como a propagação de choques climáticos e produtivos ao longo do tempo.

Enquanto algumas regiões apresentaram maior equilíbrio e integração entre as culturas, outras revelaram estruturas mais frágeis ou menos articuladas, reforçando que a agricultura familiar, em geral, e no Semiárido, em particular, não pode ser compreendida de maneira homogênea. Dessa forma, os achados destacam a importância de políticas públicas que considerem não apenas os níveis de produção, mas também as relações internas do sistema produtivo e sua dependência temporal.

No que se refere ao impacto do Programa Agroamigo, conforme esperado, ao se delinear esta pesquisa, os resultados indicam que seus efeitos não se manifestam de forma uniforme, sendo fortemente condicionados pelas características locais. Embora tenham sido identificados avanços relevantes, como o aumento da renda no Ceará e o ganho de produtividade no Maranhão, esses efeitos não se reproduzem de forma consistente nos demais estados analisados. Essa constatação confirma, ainda que parcialmente, a segunda hipótese deste estudo, segundo a qual o Agroamigo exerce influência sobre variáveis agrícolas, contribuindo para o aumento da produtividade e da renda nos estados beneficiados.

Em alguns casos, como na Bahia, observou-se inclusive redução da renda agrícola, indicando que o acesso ao crédito, por si só, não é suficiente para garantir melhorias sustentadas no desempenho produtivo. Esse resultado é particularmente relevante, pois evidencia que o crédito atua como um elemento potencializador, mas não determinante, dependendo de condições conjunturais, como o clima, para que seus efeitos se concretizem.

Vale ressaltar que, se durante o processo vegetativo das lavouras as pluviometrias forem favoráveis, isso tende a elevar a produção agrícola no entorno dos agricultores, considerando que a produção é sazonal. Isso aumenta a oferta e eleva o risco de os agricultores não conseguirem vender a parte que reservaram pelos preços com base nas suas expectativas, tornando-os mais vulneráveis aos atravessadores e, assim, os preços tendem a cair. Por outro lado, quando há dificuldades pluviométricas, a produção tende a diminuir, gerando um cenário de escassez que pressiona os preços para cima. Contudo, os agricultores não se apropriam dessas elevações de preços na sua integridade, uma vez que acabam sendo capturadas pelos intermediários.

A conclusão geral do presente estudo de doutorado é de que o Programa Agroamigo contribuiu para a dinamização produtiva da agricultura familiar no Semiárido, embora seus efeitos dependam das condições estruturais e climáticas locais para transformar esses ganhos em acréscimo de renda, como é esperado nas atividades agrícolas em geral.

Assim, seu potencial transformador depende da articulação com outros fatores, como assistência técnica, infraestrutura, acesso a mercados e, sobretudo, da mitigação dos

riscos climáticos que caracterizam a agricultura de sequeiro. Dessa forma, conclui-se que políticas de crédito rural, quando isoladas, possuem alcance limitado, sendo necessário integrá-las a estratégias mais amplas de desenvolvimento rural.

O Agroamigo tem contribuído para a inserção dos municípios da área de abrangência do BNB na captação de recursos destinados à agricultura familiar. No entanto, observa-se que as limitações econômicas das famílias atendidas, em sua maioria classificadas como potenciais beneficiárias do Pronaf B, dificultam a contratação de valores mais elevados.

Esse fator está associado tanto às características produtivas, como às atividades agrícolas predominantes de sequeiro, que apresentam acesso limitado às tecnologias que poderiam prover melhores resultados físicos e econômicos para as famílias beneficiadas.

Em contrapartida, durante anos os valores máximos permitidos para contratação pelas famílias do Grupo B permaneceram defasados, o que reduziu significativamente a capacidade de ampliação dos investimentos por parte dos agricultores, sendo reajustados apenas em 2023.

Diante dessa constatação, emerge como sugestão a necessidade de reavaliar os limites de financiamento atualmente disponíveis para os agricultores familiares. Todavia, é fundamental reconhecer que a definição orçamentária não é atribuição do BNB, estando condicionada à autoridade monetária, representada pelo Banco Central e, sobretudo, às diretrizes estratégicas e políticas do Poder Executivo Federal.

Nessa perspectiva, cabe aos tomadores de decisão no BNB, assim como em outras instâncias de formulação de políticas públicas, buscar estratégias que viabilizem a ampliação desses limites, em diálogo com o Banco Central e com os Poderes Executivo e Legislativo, observando as diretrizes macroeconômicas e o controle inflacionário.

Ainda que a elevação dos limites de financiamento do Agroamigo possa representar um avanço relevante, tal medida deve ser avaliada com cautela, considerando aspectos técnicos, socioeconômicos e políticos. Isso implica assegurar que eventuais mudanças promovam efetivamente ganhos de bem-estar para os agricultores familiares, respeitando suas reais condições de produção e reprodução social, especialmente em uma região cuja regra é a instabilidade climática, o que os torna vulneráveis a esse fenômeno natural, além das vulnerabilidades induzidas que caracterizam os habitantes dessas áreas como alguns dos mais carentes do país.

Diante desse contexto, este trabalho sugere ainda que os empréstimos concedidos por meio do Agroamigo sejam vinculados a uma modalidade de seguro agrícola. Embora o Programa já disponha de mecanismos de proteção, como o seguro de vida e o Proagro Mais,

essas iniciativas ainda são limitadas para o enfrentamento dos riscos climáticos, sobretudo no Semiárido.

Assim, propõe-se, como reflexão, a ampliação dessa cobertura para incluir um seguro agrícola específico, com financiamento tripartite que poderia ser definido da seguinte forma, apenas como sugestão: um terço custeado pelos próprios agricultores (descontado do valor contratado), um terço pelas prefeituras e um terço pelos governos estaduais. Os aportes públicos poderiam ser viabilizados por meio de realocação de recursos de programas já existentes de apoio à agricultura familiar, em âmbito local e estadual, de forma complementar aos recursos do FNE que financiam atualmente o Agroamigo.

Por fim, esta pesquisa reforça que compreender a agricultura familiar implica reconhecer sua complexidade, bem como suas interdependências e limitações estruturais. Nesse sentido, os resultados evidenciam a necessidade de uma visão integrada, capaz de incorporar a variabilidade climática e a diversidade regional à construção de políticas públicas mais eficazes e sustentáveis, alinhadas às realidades vivenciadas por esses agricultores no Semiárido.

REFERÊNCIAS

ABRAMOVAY, Ricardo *et al.* **Cinco anos de Agroamigo: retrato do público e efeitos do Programa.** Fortaleza: Banco do Nordeste, 2012.

ALMEIDA, Aléssio Tony Cavalcanti de.; OLIVEIRA, Jailson da Conceição Teixeira de. O Agroamigo e a equidade no repasse de recursos: evidências usando a fronteira de melhor disponibilidade de serviços para idênticas necessidades. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 46, suplemento especial, p. 89–104, 2015. Disponível em: <https://www.bnb.gov.br/revista/ren/article/view/43> Acesso em: 16 abr. 2025.

ALVES, Maria Odete *et al.* **PRONAF na área de atuação do BNB: avaliação de resultados e impactos.** Fortaleza: Banco do Nordeste do Brasil, 2017. Disponível em: <https://www.bnb.gov.br/s482-dspace/handle/123456789/674>. Acesso em: 27 mar. 2025.

ALVES, Maria Odete; SANTOS, Camila Ribeiro Cardoso. O banco de desenvolvimento do Nordeste: trajetória da consolidação institucional do BNB. *In*: VALENTE JR., Airton Saboya; ALVES, Maria Odete; SANTOS, Camila Ribeiro Cardoso (org.). **Banco do Nordeste do Brasil: 70 anos de contribuição para o desenvolvimento regional.** Fortaleza, CE: Banco do Nordeste do Brasil, 2022. p.103-185.

ALVES, Maria Odete. Transformações silenciosas: impactos do Agroamigo Crescer na inclusão financeira e autonomia econômica de mulheres do Nordeste rural. *In*: ALVES, Maria Odete; VALENTE JUNIOR, Airton Saboya (coord.). **Agroamigo 20 anos: duas décadas apoiando a realização de sonhos e transformando a agricultura familiar.** Fortaleza: Banco do Nordeste do Brasil, 2025. p. 205–206.

AMARAL, Paulo. A expansão do microcrédito no Brasil: a estabilização monetária e o Plano Real. **Revista Brasileira de Economia**, Rio de Janeiro, RJ, v. 59, n. 1, p. 79–97, 2005. Disponível em: https://www.bcb.gov.br/content/publicacoes/outras_pub_alfa/microcredito.pdf Acesso em: 18 mai. 2024.

AQUINO, Joacir Rufino de.; ALVES, Maria Odete.; VIDAL, Maria de Fátima. Agricultura familiar no Nordeste do Brasil: um retrato atualizado a partir dos dados do Censo Agropecuário 2017. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 51, p. 31-54, 2020. Disponível em: <https://www.bnb.gov.br/revista/ren/article/view/1271> Acesso em: 26 fev. 2025.

AQUINO, Joacir Rufino de.; SILVA, Roberto Marinho Alves. O semiárido rural e a atuação do BNB: trajetória, panorama recente e desafios. *In*: VALENTE JR., Airton Saboya; ALVES, Maria Odete; SANTOS, Camila Ribeiro Cardoso (org.). **Banco do Nordeste do Brasil: 70 anos de contribuição para o desenvolvimento regional.** Fortaleza, CE: Banco do Nordeste do Brasil, 2022. p. 64-102.

AQUINO, Joacir Rufino de.; BASTOS, Fernando. Dez anos do Programa Agroamigo na Região Nordeste: evolução, resultados e limites para o fortalecimento da agricultura familiar. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 46, supl. esp., p. 139–160, 2015. Disponível em: <https://www.bnb.gov.br/revista/ren/article/view/46> Acesso em: 17 abr. 2025.

AQUINO, Joacir Rufino de.; SCHNEIDER, Sérgio. O PRONAF e o desenvolvimento rural

brasileiro: avanços, contradições e desafios para o futuro. *In*: GRISA, Catia; SCHNEIDER, Sérgio (org.). **Políticas públicas de desenvolvimento rural no Brasil**. Porto Alegre: Editora da UFRGS, 2015. p. 53–81.

AWE, Oluwaseun; DIAS, Rui. Comparative Analysis of ARIMA and Artificial Neural Network Techniques for Forecasting Non-Stationary Agricultural Output Time Series. **AGRIS on-line Papers in Economics and Informatics**, [s. l.], v. 14, n. 4, p. 3–9, 2022. Disponível em: <https://online.agris.cz/archive/2022/04/01>. Acesso em: 27 mar. 2025.

BANCO CENTRAL DO BRASIL. **Manual de Crédito Rural**. Brasília, DF: BCB, 2025. Disponível em: <https://www3.bcb.gov.br/mcr>. Acesso em: 18 mai. 2025.

BANCO DO NORDESTE DO BRASIL. **Agroamigo**: Programa de Microcrédito Produtivo Rural. Fortaleza: BNB, 2025a.

BANCO DO NORDESTE DO BRASIL. **Relatório de gestão do Fundo Constitucional de Financiamento do Nordeste (FNE)**: exercício 2024. Fortaleza: BNB, 2025b.

BANCO DO NORDESTE DO BRASIL. **Relatório dos programas de microfinanças do Banco do Nordeste**. Fortaleza: BNB, 2025c.

BANCO DO NORDESTE DO BRASIL. **Relatórios e resultados anuais**. Fortaleza: BNB, 2024.

BANCO INTERAMERICANO DE DESENVOLVIMENTO (BID). **Regulamentação das microfinanças**. Rio de Janeiro: BID, 2002. Disponível em: <http://www.iadb.org>. Acesso em: 18 mai. 2025.

BARONE, Marcelo *et al.* **Introdução ao microcrédito**. Brasília: Conselho da Comunidade Solidária, 2002.

BIANCHINI, Luciano Araujo. **A readequação do Pronaf B e a criação do Agroamigo**: evolução e desafios. Fortaleza: Banco do Nordeste do Brasil, 2016.

BIJOS, Leila Maria Da’Juda. Microcrédito no Brasil: histórico e desafios. **Revista Brasileira de Microfinanças**, [s. l.], v. 9, n. 2, p. 99-113, 2004. Disponível em: <https://bd.tjdft.jus.br/items/fec56ed1-1e90-4bc8-abb7-e0b91a13afe1> Acesso em: 23 ago. 2025.

BRAGA, Márcio; TONETO JÚNIOR, Rudinei. Microcrédito e desenvolvimento local. **Economia e Sociedade**, Campinas, SP, v. 18, n. 33, p. 129-154, 2000. Disponível em: <https://seer.ufrgs.br/index.php/AnaliseEconomica/article/view/10643> Acesso em: 16 abr. 2025.

BRASIL. **Decreto nº 9.064, de 31 de maio de 2017**. Dispõe sobre a Unidade Familiar de Produção Agrária, institui o Cadastro Nacional da Agricultura Familiar e regulamenta a Lei nº 11.326, de 24 de julho de 2006, que estabelece as diretrizes para a formulação da Política Nacional da Agricultura Familiar e empreendimentos familiares rurais. Brasília, DF: Secretaria Geral, 2017.

BRASIL. **Lei nº 11.110, de 25 de maio de 2005**. Institui o Programa Nacional do Microcrédito Produtivo Orientado (PNMPO). Brasília, DF: Casa Civil, 2005.

BRASIL. **Lei nº 11.326, de 24 de julho de 2006**. Estabelece as diretrizes para a formulação da Política Nacional da Agricultura Familiar e Empreendimentos Familiares Rurais. Brasília, DF: Casa Civil, 2006.

BRASIL. **Lei nº 13.636, de 20 de março de 2018**. Altera dispositivos da Lei nº 11.110, de 25 de maio de 2005, que institui o Programa Nacional do Microcrédito Produtivo Orientado (PNMPO). Brasília, DF: Casa Civil, 2018.

BRASIL. **Nova delimitação do semiárido brasileiro**. Brasília: MIN, 2017.

BRASIL. **Plano Safra da Agricultura Familiar 2023–2024**. Brasília: MDA, 2023. Disponível em: <https://www.gov.br/mda/pt-br/plano-safra>. Acesso em: 31 mai. 2025.

BRASIL. **O que é o Pronaf**. Brasília, DF: MDA, 2025. Disponível em: <https://www.gov.br/mda/pt-br/acao-a-informacao/acoes-e-programas/programas-projetos-acoes-obras-e-atividades/programa-nacional-de-fortalecimento-da-agricultura-familiar-pronaf/o-que-e>. Acesso em: 23 mai. 2025.

BÚRIGO, Fábio Luiz *et al.* O Sistema Nacional de Crédito Rural no Brasil: principais continuidades e descontinuidades no período 2003-2014. **Estudos Sociedade e Agricultura**, [s. l.], v. 29, n. 3, p. 636-668, 2021. Disponível em: <https://lemate.paginas.ufsc.br/files/2021/10/Artigo-ESA-Continuidade-e-descontinuidades.pdf>. Acesso em: 07 dez. 2025.

COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira de grãos 2025/2026**. Brasília: CONAB, 2025. Disponível em: <https://www.conab.gov.br>. Acesso em: 15 mai. 2025.

CONDEL/SUDENE. **Resolução Nº 176/2024, de 03 de janeiro de 2024**. Brasília, DF: CONDEL/SUDENE, 2024.

COSTA, Edward Martins *et al.* Efeitos heterogêneos do Programa Agroamigo sobre os pequenos produtores rurais. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 49, n. 2, p. 43-61, 2018. Disponível em: <https://www.bnb.gov.br/revista/ren/article/view/633>. Acesso em: 16 abr. 2025.

COSTANZI, Rogério Nagamine. Microcrédito no âmbito das políticas públicas de trabalho e renda. **Revista Mercado de Trabalho - Conjuntura e Análise**, Brasília, DF, ano 7, p. 21-25, 2002. Disponível em: <https://share.google/biGMSpijpo9PzNsmD>. Acesso em: 29 ago. 2025.

CRUZ, Nayara Barbosa *et al.* Acesso da agricultura familiar ao crédito e à assistência técnica no Brasil. **Revista de Economia e Sociologia Rural**, Brasília, DF, v. 59, p. 1–20, 2021. Disponível em: <https://www.scielo.br/j/resr/a/Vh4gyBhmFdqqMbMstWmBdGL/?format=html&lang=pt>. Acesso em: 23 ago. 2025.

DUARTE, Silvia Patrícia da Silva *et al.* A metodologia de microcrédito rural e seus impactos:

análise do Agroamigo. **Revista de Extensão Rural**, Santa Maria, RS, v. 12, n. 3, p. 15–30, 2017. Disponível em: <https://periodicos.ufsm.br/extensaorural/issue/view/1180> Acesso em: 13 mai. 2025.

ELSARAITI, Meftah. Short-term power consumption forecasting using neural networks with first- and second-order differencing. **Academia Green Energy**, v. 1, n. 3, p. 1-12, 2024. Disponível em: <https://www.academia.edu/journals/academia-green-energy/about> Acesso em: 22 set. 2025.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Cultivo e manejo de culturas no Semiárido brasileiro**. Brasília: EMBRAPA Semiárido, 2025.

ENDERS, Walter. **Applied econometric time series**. Hoboken, NJ: John Wiley & Sons, 2014.

FARRANHA, Luís. O microcrédito como instrumento de desenvolvimento local: uma análise do programa Crediamigo. **Revista de Economia e Desenvolvimento**, v. 6, p. 15-29, 2005.

FÁVERO, Luiz Paulo Lopes *et al.* **Análise de dados: modelagem multivariada para tomada de decisões**. Rio de Janeiro: Elsevier, 2009.

FÁVERO, Luiz Paulo Lopes; BELFIORE, Patrícia. **Manual de análise de dados**. Rio de Janeiro: Elsevier, 2017.

FEITOSA, Milena Monteiro; LEMOS, José de Jesus Sousa. Hybrid model of artificial neural networks and principal component decomposition for predicting greenhouse gas emissions in the Brazilian MATOPIBA region. **Global Journal of Human-Social Science: E Economics**, Massachusetts, v. 25, edição 1, p. 69–80, 2025. Disponível em: https://globaljournals.org/GJHSS_Volume25/7-Hybrid-Model-of-Artificial.pdf. Acesso em: 11 jan. 2026.

FERREIRA, Francisco Diego Guedes *et al.* Indicadores de desenvolvimento rural e sua relação com as políticas públicas da agricultura familiar: uma análise para as mesorregiões brasileiras. **Acta Geográfica**, Fortaleza, CE, v. 16, n. 40, p. 179–205, 2022. Disponível em: <https://repositorio.ufc.br/handle/riufc/68806> Acesso em: 26 fev. 2025.

FREIRE, Paulo. **Pedagogia da indignação: cartas pedagógicas e outros escritos**. São Paulo: Editora UNESP, 2000.

GOLDMARK, Linda; POCKROSS, David; VECHINA, Manuel. O papel do Banco Nacional de Desenvolvimento Econômico e Social (BNDES) no microcrédito brasileiro. **Revista de Economia Social**, [s. l.], v. 14, n. 1, p. 55-67, 2002. Disponível em: https://www.revista-es.info/uploads/1/1/8/1/118198432/revista-es_n1_1.pdf Acesso em: 13 mai. 2025.

GREENE, William. **Econometric Analysis**. New York: Pearson, 2018.

GUANZIROLI, Carlos Enrique *et al.* Agricultura familiar e políticas públicas: desafios para o desenvolvimento sustentável. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 45, n. esp., p. 25–40, 2014.

GUEDES, Isabela Assis; ALMEIDA, Aléssio Tony Cavalcanti; SIQUEIRA, Liedje Bettizaide Oliveira de. Efeitos do microcrédito rural sobre a produção agropecuária na região Nordeste: evidências do Programa Agroamigo. **Revista de Economia e Sociologia Rural**, Brasília, DF, v. 59, n. 1, e210774, 2021. Disponível em:

<https://www.scielo.br/j/resr/a/WRSFqttHMVD3mWDG3YD5VZH/?lang=pt> Acesso em: 28 dez. 2025.

GUILLAUMONT, Patrick; SIMONET, Catherine. Designing an index of structural vulnerability to climate change. FERDI-Fondation for studies and research on international. **Policy Brief**, [s. l.], v. 18, n. 42, p. 1-8, 2011. Disponível em: <https://ferdi.fr/dl/df-wGxz7S3WC8RfZ82UJVCCwjzw/ferdi-b18-designing-an-index-of-physical-vulnerability-to-climate-change.pdf> Acesso em: 13 mai. 2025.

GUJARATI, Damodar N.; PORTER, Dawn C. **Econometria Básica**. Porto Alegre: AMGH, 2011.

HAHN, Micah; RIEDERER, Anne; FOSTER, Stanley. The Livelihood Vulnerability Index: A pragmatic approach to assessing risks from climate variability and change - A case study in Mozambique. **Global Environmental Change**, [s. l.], v. 19, n. 1, p. 74-88. 2009. Disponível em: Acesso em: Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S095937800800112X> Acesso em: 18 mai. 2025.

HERNANI, Luis Carlos; SOUZA, Luiz Carlos Ferreira; CECCO, Gerson. **Consortiação de culturas**. Brasília: EMBRAPA, 2022.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo Agropecuário 2017**. Rio de Janeiro: IBGE, 2019. Disponível em: <https://sidra.ibge.gov.br/pesquisa/censo-agropecuario/censo-agropecuario-2017/resultados-definitivos>. Acesso em: 31 mai. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo Demográfico 2022**. Rio de Janeiro: IBGE, 2022. Disponível em: <https://sidra.ibge.gov.br/pesquisa/censodemografico/demografico-2022/inicial>. Acesso em: 10 jun. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Mapa de Clima do Brasil**. Rio de Janeiro: IBGE/CREN/DGC, 2006.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção Agrícola Municipal (PAM)**. Rio de Janeiro: IBGE, 2024. Disponível em: <https://sidra.ibge.gov.br/pesquisa/pam/tabelas>. Acesso em: 5 jan. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção Agrícola Municipal (PAM): culturas temporárias e permanentes**. Rio de Janeiro: IBGE, 2025. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html>. Acesso em: 3 mar. 2026.

INSTITUTO NACIONAL DE COLONIZAÇÃO E REFORMA AGRÁRIA (INCRA); FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (FAO). **Novo**

retrato da agricultura familiar: o Brasil redescoberto. Brasília: INCRA/FAO, 2000.

JESUS, Carlos Magno *et al.* Programa Agroamigo na Bahia (2005-2022): resultados gerais e desempenho no semiárido e demais regiões do estado. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 54, n. 2, p. 233-250, 2023. Disponível em:

<https://www.bnb.gov.br/revista/ren/issue/view/127> Acesso em: 29 ago. 2025.

JOHNSON, Richard; WICHERN, Dean. **Applied multivariate statistical analysis.** Upper Saddle River: Pearson Education, 2007.

KANG, Manjit; PHAM, Ha. Simultaneous Selection for High Yielding and Stable Crop Genotypes. **Agronomy Journal**, [s. l.], v. 83, p. 161-165, 1991. Disponível em:

<https://doi.org/10.2134/agronj1991.00021962008300010037x> Acesso em: 23 ago. 2025.

LEE, June-Goo *et al.* Deep learning in medical imaging: General overview. **Korean Journal of Radiology**, [s. l.], v. 18, n. 4, p. 570–584, 2017. Disponível em:

<https://pubmed.ncbi.nlm.nih.gov/28670152/> Acesso em: 31 mar. 2025.

LEMOS, José de Jesus Sousa. **Vulnerabilidades induzidas no semiárido brasileiro.** Fortaleza: Imprensa Universitária, 2020.

LEMOS, José de Jesus Sousa *et al.* Agricultura familiar no Ceará: evidências a partir do censo agropecuário de 2017. **Revista Econômica do Nordeste**, Fortaleza, v. 51, suplemento especial, p. 93-112, 2020. Disponível em:

<https://www.bnb.gov.br/revista/ren/article/view/1264> Acesso em: 23 jun. 2025.

LESSA, Laura Cunha Rebouças *et al.* Estabilidade da agricultura alimentar de sequeiro da Paraíba frente às instabilidades pluviométricas. **Revista de Economia e Sociologia Rural**, v. Brasília, DF, v. 62, e274633, 2024. Disponível em:

<https://www.scielo.br/j/resr/a/V3r8ySzyjxf87rfVKCqPrQM/abstract/?lang=pt> Acesso em: 23 jul. 2025.

LIU, Han; COCEA, Mihaela. Semi-random partitioning of data into training and test sets in granular computing context. **Granular Computing**, [s. l.], v. 2, p. 357–386, 2017. Disponível em: <https://link.springer.com/article/10.1007/s41066-017-0049-2> Acesso em: 23 ago. 2025.

MACHADO, Rodrigo *et al.* Distribuição do crédito do Pronaf: uma análise recente. **Revista de Estudos Sociais e Rurais**, Brasília, DF, v. 19, n. 1, p. 99–123, 2024. Disponível em:

<https://revistaesa.com/ojs/index.php/esa/issue/view/82> Acesso em: 31 mar. 2025.

MAGALHÃES, Reginaldo Sales *et al.* **Avaliação dos impactos do Pronaf na agricultura familiar brasileira.** Brasília: Instituto de Pesquisa Econômica Aplicada (IPEA), 2006.

MAIA, Guilherme Baptista da Silva; PINTO, Arthur de Rezende. Agroamigo: uma análise de sua importância no desempenho do Pronaf B. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 46, suplemento especial, p. 9–20, 2015. Disponível em:

<https://www.bnb.gov.br/revista/ren/article/view/38/20> Acesso em: 13 mai. 2025.

MARIONI, L. S. *et al.* Uma aplicação de regressão quantílica para dados em painel do PIB e do Pronaf. **Revista de Economia e Sociologia Rural**, Brasília, DF, v. 54, n. 2, p.

221-242, 2016. Disponível em:
<https://www.scielo.br/j/resr/a/HDhfTtTQ8LRyM6LG4qsN6wN/?lang=pt> Acesso em: 23 set. 2025.

MAROCO, João. **Análise estatística com utilização do SPSS**. Lisboa: Edições Sílabo, 2007.

MATOS, Daniel Abud Seabra; RODRIGUES, Erica Castilho. **Análise fatorial**. Brasília: Enap, 2019.

MENDES, Aldemi Ferreira. **Contextualização e interdisciplinaridade na utilização da matemática no estudo de fenômenos climáticos e meteorológicos**. 2010. Dissertação (Mestrado em Ciências), Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ. 53 f.

MIRANDA, Ingry Natalia Gómez; JARAMILLO, José Manuel Fernández; PEÑUELA, Gustavo. Hybrid multivariate statistical and neural network model to predict greenhouse gas emissions. **Arabian Journal for Science and Engineering**, [s. l.], v. 46, n. 10, p. 1-11, 2021. Disponível em:
https://www.researchgate.net/publication/348988950_Hybrid_Multivariate_Statistical_and_Neural_Network_Model_to_Predict_Greenhouse_Gas_Emissions Acesso em: 17 abr. 2025.

MONTEIRO, Alexandra Pedrosa; LEMOS, José de Jesus Sousa. Desigualdades na distribuição dos recursos do PRONAF entre as regiões brasileiras. **Revista de Política Agrícola**, Brasília, DF, v. 2019, p. 6-17, 2019. Disponível em:
<https://rpa.sede.embrapa.br/RPA/article/view/1279> Acesso em: 23 out. 2025.

MORETTIN, Pedro Alberto; TOLOI, Clélia Maria de Castro. **Análise de séries temporais**. São Paulo: Edgard Blucher, 2006.

MORETTIN, Pedro Alberto; BUSSAB, Wilton O. **Estatística básica**. São Paulo: Saraiva, 2014.

MOTA, Wilton Luiz; SANTANA, José Ricardo. O microcrédito como estratégia de redução da pobreza do Nordeste: uma avaliação a partir do programa crediamigo. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 42, n. 1, p. 25-48, 2011. Disponível em:
<https://www.bnb.gov.br/revista/ren/article/view/142> Acesso em 31 ago. 2025.

MOURA, Magna Soelma Beserra *et al.* **Clima e água de chuva no semiárido**. Brasília. EMBRAPA, 2007.

NUNES, Emanuel Márcio *et al.* Políticas agrárias e agrícolas no contexto do desenvolvimento do Nordeste: evolução, desafios e perspectivas. **Planejamento e Políticas Públicas (PPP)**, Brasília, DF, n. 43, p. 91-126, 2014. Disponível em:
<https://www.ipea.gov.br/ppp/index.php/PPP/article/view/330/339> Acesso em: 23 ago. 2025.

NUNES, Emanuel Márcio *et al.* Microcrédito, infraestrutura e desenvolvimento rural: o Agroamigo investimento e custeio na agricultura familiar de territórios do Rio Grande do Norte. **Revista Econômica do Nordeste**, Fortaleza, CE, v. 46, suplemento especial, p. 55–71, 2015. Disponível em: <https://www.bnb.gov.br/revista/ren/article/view/41/23> Acesso em: 23 ago. 2025.

ORGANIZATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT (OECD). Handbook on constructing composite indicators: methodology and user guide. Paris: **OECD Publishing**, 2008. Disponível em: <https://www.oecd.org/sdd/42495745.pdf>. Acesso em: 11 mar. 2025.

PHAM, Binh Thai *et al.* Prediction of shear strength of soft soil using machine learning methods. **Catena**, [s. l.], v. 166, p. 181–191, 2018. Disponível em: https://www.researchgate.net/publication/324173845_Prediction_of_Shear_Strength_of_Soft_Soil_Using_Machine_Learning_Methods Acesso em: 23 nov. 2025.

PHESA, Mbulelo; WOYESSA, Yali; MBATHA, Nkanyiso. Evapotranspiration Prediction Using ARIMA, ANN and Hybrid Models for Optimum Water Use in Agriculture: A Case Study of Keiskammahoek Irrigation Scheme, Eastern Cape, South Africa. **Proceedings of the 3rd International Symposium on Water, Ecology and Environment (ISWEE)**, p. 276-286, 2022. Disponível em: <https://www.scitepress.org/Papers/2022/120090/120090.pdf> Acesso em: 23 ago. 2025.

QUARANTA, Giovanni. Agricultura de sequeiro. Land care in desertification affected areas: From science towards application. **Folheto Série C**, [s. l.], n. 4, p. 3, 2013. Disponível em: http://geografia.fcsh.unl.pt/lucinda/Leaflets/C4_Leaflet_PT.pdf. Acesso em: 10 set. 2024.

RENNER, Alpha *et al.* The backpropagation algorithm implemented on spiking neuromorphic hardware. **Nature Communications**, [s. l.], v. 15, art. 9691, 2024. Disponível em: <https://www.nature.com/articles/s41467-024-53827-9> Acesso em: 23 jun. 2025.

RIBEIRO, Cristina Tauaf, CARVALHO, Carlos Eduardo. **Do microcrédito às microfinanças**: desempenho financeiro, dependência de subsídios e fontes de financiamento – uma contribuição à análise da experiência brasileira. São Paulo: FAPESP/EDUC, 2006.

SABOYA JÚNIOR, Antônio; SOUSA, José Márcio Pereira de. **Análise das liberações dos recursos do Pronaf**: descentralização das aplicações do crédito rural? Fortaleza: Banco do Nordeste do Brasil, 2005.

SANJEEV; BHARDWAJ, Nitin. Time series prediction using hybrid ARIMA–ANN models for sugarcane. International. **Journal of Plant & Soil Science**, [s. l.], v. 34, n. 23, p. 772–782, 2022. Disponível em: <https://journalijpss.com/index.php/IJPSS/article/view/2488>. Acesso em: 13 jan. 2026.

SANTIAGO, Eduardo Girão. **Empreender para sobreviver**: ação econômica dos empreendedores de pequeno porte. Fortaleza: Banco do Nordeste do Brasil, 2008.

SCHRÖDER, Mônica. Políticas públicas e agricultura familiar no Brasil: inovações institucionais a partir do Pronaf. In: BARBOSA, Cristiane Garcia; TEIXEIRA, Marcelo Azevedo; DAMASCENO, Wellington Santos (org.). **A experiência dos programas de microcrédito do Banco do Nordeste**. Fortaleza: Banco do Nordeste do Brasil, 2012. p. 245-280.

SHARDA, Ramesh; PATIL, Rajesh. Connectionist approach to time series prediction: An

empirical test. **Journal of Intelligent Manufacturing**, [s. l.], v. 3, n. 5, p. 317–323, 1992. Disponível em: https://www.researchgate.net/publication/227078976_Connectionist_approach_to_time_series_prediction_An_empirical_test Acesso em: 16 abr. 2025.

SILVA, Carolina Braz de Castilho e.; COLEN, Célia Mara Ladeia; MELO, Maria Renata Bezerra. **Programa Agroamigo: uma avaliação dos impactos do crédito nas condições socioeconômicas dos clientes**. Fortaleza, CE: Banco do Nordeste do Brasil, 2024.

SILVA, Maria Aparecida. **Estudo sobre a criação e implementação do programa Crediamigo: uma análise do impacto da microfinanças no Brasil**. São Paulo: Editora Universidade, 2007.

SILVA, Sandro Pereira; CIRÍACO, Juliane da Silva; AQUINO, Joacir Rufino de. **Análise do Programa Agroamigo de crédito para a agricultura familiar: evolução, aderência e incidência sobre agregados econômicos municipais na região Nordeste**. Brasília: Instituto de Pesquisa Econômica Aplicada, 2025.

SILVEIRA, Marina Porto Coelho; MONTENEGRO, Rosa Livia Gonçalves; PEREIRA, Patrícia Rosado Alves. Pronaf e desenvolvimento rural: uma análise para Minas Gerais nos anos de 2006 e 2017. **Revista de Economia e Sociologia Rural**, Brasília, DF, v. 62, e264581, 2024. Disponível em: <https://www.scielo.br/j/resr/a/fH5ZR7R9Rj5MvSqNs7LvsqG/?lang=pt> Acesso em: 23 dez. 2025.

SIMS, Christopher A. Macroeconomics and Reality. **Econometrica**, [s. l.], v. 48, n. 1, p. 1–48, 1980. Disponível em: <https://www.jstor.org/stable/1912017> Acesso em: 23 jan. 2025.

STOCK, James Harold; WATSON, Mark William. **Introduction to Econometrics**. Boston: Pearson, 2019.

THORNTON, Philip *et al.* Climate change and poverty in Africa: mapping hotspots of vulnerability. **African Journal of Agricultural and Resource Economics**, [s. l.], v. 2, n. 1, p. 24–44, 2008. Disponível em: <https://hdl.handle.net/10568/663> Acesso em 18 mai. 2025.

TOLSTIKHIN, Ilya *et al.* MLP-Mixer: An all-MLP architecture for vision. **Advances in Neural Information Processing Systems (NeurIPS)**, [s. l.], v. 34, 2021. Disponível em: <https://arxiv.org/abs/2105.01601> Acesso em: 17 abr. 2025.

TRIPATHY, Debesh Shankar; PRUSTY, B. Rajanarayan. Forecasting of renewable generation for applications in smart grid power systems. In: TOMAR, Atul; KANDARI, Ramesh (ed.). **Advances in Smart Grid Power System**. London: Academic Press, 2021. p. 265–298.

UNITED NATIONS. **United Nations Environment Management Group**. New York: UN, 2011. Disponível em: <https://unemg.org/>. Acesso em: 12 fev. 2026.

UNITED NATIONS DEVELOPMENT PROGRAMME (UNDP). **Human development report 2023–2024: technical notes calculating the human development indices**. New York: UNDP, 2024. Disponível em: https://hdr.undp.org/sites/default/files/2023-24_HDR/hdr2023-24_technical_notes.pdf. Acesso em: 11 mar. 2026.

VARIAN, Hal. **Intermediate microeconomics: a modern approach**. New York: W. W. Norton & Company, 2019.

VIALI, Lourí. **Introdução à Estatística Multivariada**. Porto Alegre: PUCRS, 2002.

VIEIRA, Fábio Alves. Avaliação dos impactos sociais do Programa Agroamigo. **Revista de Políticas Públicas**, São Luiz, MA, v. 21, n. 4, p. 210–225, 2017. Disponível em: <https://www.redalyc.org/pdf/3211/321143201001.pdf> Acesso em: 26 fev. 2025.

WANG, Yuhan *et al.* Progress in research on deep learning-based crop yield prediction. **Agronomy**, [s. l.], v. 14, n. 10, p. 2264, 2024. Disponível em: <https://www.mdpi.com/2073-4395/14/10/2264> Acesso em: 23 fev. 2025.

WOOLDRIDGE, Jeffrey M. **Introdução à econometria: uma abordagem moderna**. São Paulo: Cengage Learning, 2016.

YUNUS, Muhammad. **O banqueiro dos pobres**. São Paulo: Ática, 2001.

ZHANG, Guoqiang. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, [s. l.], v. 50, p. 159–175, 2003. Disponível em: <http://dl1.icdst.org/pdfs/files/2c442c738bd6bc178e715f400bec5d5f.pdf> Acesso em: 23 mar. 2025.

ZHANG, Guoqiang; PATUWO, Bernard; HU, Michael. Forecasting with artificial neural networks: the state of the art. **International Journal of Forecasting**, [s. l.], v. 14, p. 35–62, 1998. Disponível em: <https://ideas.repec.org/a/eee/intfor/v14y1998i1p35-62.html> Acesso em: 23 abr. 2025.

APÊNDICE A – DESEMPENHOS DA RNA NA ESTIMAÇÃO DAS VARIÁVEIS


Tabela A1 – Desempenhos da RNA na estimação das variáveis

Variável	Pearson (r)	Treinamento (%)	Teste (%)	Unidades mínimas na camada oculta	Unidades geradas na camada oculta
Ceará					
Prod Feijão	0,960	61,5	38,5	5	6
Prod Mand	0,833	74,4	25,6	3	4
Prod Milho	0,931	69,2	30,8	5	5
VPH Feijão	0,568	79,5	20,5	9	10
VPH Mand	0,934	79,5	20,5	1	1
VPH Milho	0,824	74,4	25,6	12	12
Bahia					
Prod Feijão	0,949	69,2	30,8	5	5
Prod Mand	0,952	79,5	20,5	1	2
Prod Milho	0,969	79,5	20,5	3	4
VPH Feijão	0,893	69,2	30,8	5	5
VPH Mand	0,873	74,4	25,6	5	5
VPH Milho	0,899	79,5	20,5	5	6
Pernambuco					
Prod Feijão	0,830	61,5	38,5	5	6
Prod Mand	0,632	79,5	20,5	9	10
Prod Milho	0,855	74,4	25,6	3	4
VPH Feijão	0,812	66,7	33,3	7	8
VPH Mand	0,725	61,5	38,5	5	5
VPH Milho	0,897	74,4	25,6	3	3
Maranhão					
Prod Arroz	0,814	66,7	33,3	7	7
Prod Feijão	0,957	74,4	25,6	3	3
Prod Mand	0,903	69,2	30,8	5	6
Prod Milho	0,986	79,5	20,5	1	5
VPH Arroz	0,907	66,7	33,3	7	8
VPH Feijão	0,922	61,5	38,5	7	7
VPH Mand	0,829	79,5	20,5	1	2
VPH Milho	0,857	79,5	20,5	1	2
Piauí					
Prod Arroz	0,900	74,4	25,6	3	4
Prod Feijão	0,911	74,4	25,6	3	3
Prod Mand	0,777	66,7	33,3	5	6
Prod Milho	0,954	71,8	28,2	3	5
VPH Arroz	0,952	66,7	33,3	3	5
VPH Feijão	0,875	66,7	33,3	1	2
VPH Mand	0,849	76,9	23,1	7	7
VPH Milho	0,821	79,5	20,5	7	8

Fonte: Elaboração própria (2026).


APÊNDICE B – ARQUITETURA DA RNA PARA OS ESTADOS ANALISADOS

Figura B1 – Arquitetura da RNA para a produtividade do feijão no Ceará




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B2 – Arquitetura da RNA para a produtividade da mandioca no Ceará




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B3 – Arquitetura da RNA para a produtividade do milho no Ceará




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B4 – Arquitetura da RNA para o VPH do feijão no Ceará




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B5 – Arquitetura da RNA para o VPH da mandioca no Ceará




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B6 – Arquitetura da RNA para o VPH do milho no Ceará




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B7 – Arquitetura da RNA para a produtividade do feijão na Bahia




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B8 – Arquitetura da RNA para a produtividade da mandioca na Bahia




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B9 – Arquitetura da RNA para a produtividade na Bahia




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B10 – Arquitetura da RNA para o VPH do feijão na Bahia




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B11 – Arquitetura da RNA para o VPH da mandioca na Bahia




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B12 – Arquitetura da RNA para o VPH do milho na Bahia




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B13 – Arquitetura da RNA para a produtividade do feijão em Pernambuco




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B14 – Arquitetura da RNA para a produtividade da mandioca em Pernambuco




Fonte: Elaboração própria a partir das estimativas da RNA.

Figura B15 – Arquitetura da RNA para a produtividade do Milho em Pernambuco




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B16 – Arquitetura da RNA para o VPH do feijão em Pernambuco




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B17 – Arquitetura da RNA para o VPH da mandioca em Pernambuco




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B18 – Arquitetura da RNA para o VPH do milho em Pernambuco




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B19 – Arquitetura da RNA para a produtividade do arroz no Maranhão




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B20 – Arquitetura da RNA para a produtividade do feijão no Maranhão




Fonte: Elaboração própria a partir das estimativas da RNA.

Figura B21 – Arquitetura da RNA para a produtividade da mandioca no Maranhão




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B22 – Arquitetura da RNA para a produtividade do milho no Maranhão




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B23 – Arquitetura da RNA para o VPH de arroz no Maranhão




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B24 – Arquitetura da RNA para o VPH do feijão no Maranhão




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B25 – Arquitetura da RNA para o VPH da mandioca no Maranhão




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B26 – Arquitetura da RNA para o VPH do milho no Maranhão




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B27 – Arquitetura da RNA para a produtividade do arroz no Piauí




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B28 – Arquitetura da RNA para produtividade do feijão no Piauí




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B29 – Arquitetura da RNA para a produtividade da mandioca no Piauí




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B30 – Arquitetura da RNA para a produtividade do milho no Piauí




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B31 – Arquitetura da RNA para o VPH de arroz no Piauí




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B32 – Arquitetura da RNA para o VPH do feijão no Piauí




Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B33 – Arquitetura da RNA para o VPH da mandioca no Piauí



Fonte: Elaboração própria, a partir das estimativas da RNA.

Figura B34 – Arquitetura da RNA para o VPH do milho no Piauí



Fonte: Elaboração própria, a partir das estimativas da RNA.

APÊNDICE C – RESULTADOS DOS ERROS DE PREVISÃO NOS GRUPOS DE TREINAMENTO E TESTE PARA OS ESTADOS ANALISADOS

Tabela C1 – Resultados dos erros de previsão nos grupos de treinamento e teste para os estados analisados *Continua*

Variável	Treinamento		Teste	
	Soma dos erros quadráticos	Erro relativo	Soma dos erros quadráticos	Erro relativo
Ceará				
Prod Feijão	1,12	0,10	0,64	0,06
Prod Mandioca	4,80	0,34	0,60	0,18
Prod Milho	2,43	0,19	0,47	0,06
VPH Feijão	11,50	0,77	0,99	0,65
VPH Mandioca	2,50	0,17	0,08	0,03
VPH Milho	4,14	0,30	2,63	0,39
Bahia				
Prod Feijão	1,01	0,08	0,74	0,19
Prod Mandioca	1,50	0,10	0,22	0,07
Prod Milho	0,71	0,05	0,51	0,14
VPH Feijão	2,96	0,23	1,28	0,17
VPH Mandioca	3,77	0,27	0,89	0,17
VPH Milho	3,84	0,26	0,39	0,06
Pernambuco				
Prod Feijão	3,65	0,32	1,31	0,36
Prod Mandioca	5,52	0,70	0,64	0,22
Prod Milho	4,74	0,34	0,72	0,15
VPH Feijão	3,63	0,29	4,26	0,46
VPH Mandioca	5,15	0,45	3,85	0,54
VPH Milho	2,39	0,17	1,67	0,32
Maranhão				
Prod Arroz	3,94	0,32	3,45	0,43
Prod Feijão	1,16	0,08	0,21	0,12
Prod Mandioca	2,06	0,16	2,22	0,25
Prod Milho	0,55	0,04	0,04	0,01
VPH Arroz	1,76	0,14	3,69	0,24
VPH Feijão	1,64	0,14	1,39	0,17
VPH Mandioca	5,90	0,39	0,24	0,15
VPH Milho	4,74	0,32	0,09	0,58
Piauí				
Prod Arroz	3,50	0,25	0,09	0,02
Prod Feijão	3,16	0,23	0,32	0,06
Prod Mandioca	5,82	0,47	0,79	0,27
Prod Milho	1,35	0,10	0,55	0,08
VPH Arroz	1,12	0,09	0,62	0,11
VPH Feijão	3,93	0,32	4,29	0,21
VPH Mandioca	4,37	0,30	0,39	0,36
VPH Milho	5,00	0,33	0,77	0,32

Fonte: Elaboração própria (2026).

APÊNDICE D – RESULTADOS DOS TESTES DE ACURÁCIA DO MODELO DE RNA NA ESTIMAÇÃO DAS VARIÁVEIS NOS ESTADOS ANALISADOS


Tabela D1 – Resultados dos testes de acurácia do modelo de RNA na estimação das variáveis nos estados analisados

Variável	Testes de acurácia (%)		
	RMSE	MAE	MAPE
Ceará			
Prod Feijão	21,45	16,81	6,04
Prod Mandioca	1078,96	820,14	11,21
Prod Milho	96,90	67,95	11,77
VPH Feijão	334,53	240,72	15,72
VPH Mandioca	1439,64	1047,02	17,17
VPH Milho	198,63	160,84	20,62
Bahia			
Prod Feijão	20,57	15,69	3,01
Prod Mandioca	737,39	514,79	5,75
Prod Milho	66,12	54,22	6,39
VPH Feijão	518,04	396,18	15,64
VPH Mandioca	2795,90	1880,70	20,47
VPH Milho	195,53	139,03	10,84
Pernambuco			
Prod Feijão	36,88	27,05	7,77
Prod Mandioca	766,98	585,96	6,90
Prod Milho	78,66	61,30	13,98
VPH Feijão	388,69	293,42	14,98
VPH Mandioca	2688,87	2055,33	23,52
VPH Milho	152,74	115,31	18,04
Maranhão			
Prod Arroz	137,17	99,90	10,25
Prod Feijão	15,82	12,56	3,03
Prod Mandioca	298,64	214,41	2,89
Prod Milho	93,32	73,72	8,10
VPH Arroz	311,31	236,26	11,76
VPH Feijão	250,66	203,94	8,46
VPH Mandioca	899,91	689,26	14,24
VPH Milho	231,32	177,69	13,70
Piauí			
Prod Arroz	154,79	103,83	11,12
Prod Feijão	29,73	23,35	9,46
Prod Mandioca	1743,38	1182,53	14,41
Prod Milho	109,04	85,60	11,78
VPH Arroz	365,84	302,01	17,04
VPH Feijão	232,70	165,59	11,73
VPH Mandioca	1176,74	805,15	18,30
VPH Milho	259,90	194,03	20,86

Fonte: Elaboração própria (2026).


APÊNDICE E – IMPORTÂNCIA DAS VARIÁVEIS EXPLICATIVAS NAS PREVISÕES POR RNA PARA OS ESTADOS ANALISADOS

Figura E1 – Importância das variáveis explicativas na previsão da produtividade do feijão no Ceará




Fonte: Elaboração própria (2026).

Figura E2 – Importância das variáveis explicativas na previsão da produtividade de mandioca no Ceará




Fonte: Elaboração própria (2026).

Figura E3 – Importância das variáveis explicativas na previsão da produtividade do milho no Ceará




Fonte: Elaboração própria (2026).

Figura E4 – Importância das variáveis explicativas na previsão do VPH de feijão no Ceará




Fonte: Elaborada pela autora com base nos dados da pesquisa (2026).

Figura E5 – Importância das variáveis explicativas na previsão do VPH de mandioca no Ceará




Fonte: Elaboração própria (2026).

Figura E6 – Importância das variáveis explicativas na previsão do VPH de milho no Ceará




Fonte: Elaboração própria (2026).

Figura E7 – Importância das variáveis explicativas na previsão da produtividade do feijão na Bahia




Fonte: Elaboração própria (2026).

Figura E8 – Importância das variáveis explicativas na previsão da produtividade de mandioca na Bahia




Fonte: Elaboração própria (2026).

Figura E9 – Importância das variáveis explicativas na previsão da produtividade do milho na Bahia




Fonte: Elaboração própria (2026).

Figura E10 – Importância das variáveis explicativas na previsão do VPH de feijão na Bahia




Fonte: Elaboração própria (2026).

Figura E11 – Importância das variáveis explicativas na previsão do VPH de mandioca na Bahia




Fonte: Elaboração própria (2026).

Figura E12 – Importância das variáveis explicativas na previsão do VPH de milho na Bahia




Fonte: Elaboração própria (2026).

Figura E13 – Importância das variáveis explicativas na previsão da produtividade do feijão em Pernambuco




Fonte: Elaboração própria (2026).

Figura E14 – Importância das variáveis explicativas na previsão da produtividade de mandioca em Pernambuco




Fonte: Elaboração própria (2026).

Figura E15 – Importância das variáveis explicativas na previsão da produtividade do milho em Pernambuco




Fonte: Elaboração própria (2026).

Figura E16 – Importância das variáveis explicativas na previsão do VPH de feijão em Pernambuco




Fonte: Elaboração própria (2026).

Figura E17 – Importância das variáveis explicativas na previsão do VPH de mandioca em Pernambuco




Fonte: Elaboração própria (2026).

Figura E18 – Importância das variáveis explicativas na previsão do VPH de milho em Pernambuco




Fonte: Elaboração própria (2026).

Figura E19 – Importância das variáveis explicativas na previsão da produtividade do arroz no Maranhão




Fonte: Elaboração própria (2026).

Figura E20 – Importância das variáveis explicativas na previsão da produtividade do feijão no Maranhão




Fonte: Elaboração própria (2026).

Figura E21 – Importância das variáveis explicativas na previsão da produtividade de mandioca no Maranhão




Fonte: Elaboração própria (2026).

Figura E22 – Importância das variáveis explicativas na previsão da produtividade do milho no Maranhão




Fonte: Elaboração própria (2026).

Figura E23 – Importância das variáveis explicativas na previsão do VPH de arroz no Maranhão




Fonte: Elaboração própria (2026).

Figura E24 – Importância das variáveis explicativas na previsão do VPH de feijão no Maranhão




Fonte: Elaboração própria (2026).

Figura E25 – Importância das variáveis explicativas na previsão do VPH de mandioca no Maranhão




Fonte: Elaboração própria (2026).

Figura E26 – Importância das variáveis explicativas na previsão do VPH de milho no Maranhão




Fonte: Elaboração própria (2026).

Figura E27 – Importância das variáveis explicativas na previsão da produtividade do arroz no Piauí




Fonte: Elaboração própria (2026).

Figura E28 – Importância das variáveis explicativas na previsão da produtividade do feijão no Piauí




Fonte: Elaboração própria (2026).

Figura E29 – Importância das variáveis explicativas na previsão da produtividade de mandioca no Piauí




Fonte: Elaboração própria (2026).

Figura E30 – Importância das variáveis explicativas na previsão da produtividade do milho no Piauí




Fonte: Elaboração própria (2026).

Figura E31 – Importância das variáveis explicativas na previsão do VPH de arroz no Piauí




Fonte: Elaboração própria (2026).

Figura E32 – Importância das variáveis explicativas na previsão do VPH de feijão no Piauí




Fonte: Elaboração própria (2026).

Figura E33 – Importância das variáveis explicativas na previsão do VPH de mandioca no Piauí



Fonte: Elaboração própria (2026).


Figura E34 – Importância das variáveis explicativas na previsão do VPH de milho no Piauí



Fonte: Elaboração própria (2026).


APÊNDICE F – EVOLUÇÃO DOS VALORES OBSERVADOS E PREVISTOS NOS ESTADOS ANALISADOS UTILIZANDO O MODELO RNA

Figura F1 – Evolução dos valores observados e previstos da produtividade de feijão no Ceará




Fonte: Elaboração própria (2026).

Figura F2 – Evolução dos valores observados e previstos da produtividade de mandioca no Ceará




Fonte: Elaboração própria (2026).

Figura F3 – Evolução dos valores observados e previstos da produtividade de milho no Ceará




Fonte: Elaboração própria (2026).

Figura F4 – Evolução dos valores observados e previstos do VPH de feijão no Ceará




Fonte: Elaboração própria (2026).

Figura F5 – Evolução dos valores observados e previstos do VPH de mandioca no Ceará




Fonte: Elaboração própria (2026).

Figura F6 – Evolução dos valores observados e previstos do VPH de milho no Ceará




Fonte: Elaboração própria (2026).

Figura F7 – Evolução dos valores observados e previstos da produtividade de feijão na Bahia




Fonte: Elaboração própria (2026).

Figura F8 – Evolução dos valores observados e previstos da produtividade de mandioca na Bahia




Fonte: Elaboração própria (2026)..

Figura F9 – Evolução dos valores observados e previstos da produtividade de milho na Bahia




Fonte: Elaboração própria (2026).

Figura F10 – Evolução dos valores observados e previstos do VPH de feijão na Bahia




Fonte: Elaboração própria (2026).

Figura F11 – Evolução dos valores observados e previstos do VPH de mandioca na Bahia




Fonte: Elaboração própria (2026).

Figura F12 – Evolução dos valores observados e previstos do VPH de milho na Bahia




Fonte: Elaboração própria (2026).

Figura F13 – Evolução dos valores observados e previstos da produtividade de feijão em Pernambuco




Fonte: Elaboração própria (2026).

Figura F14 – Evolução dos valores observados e previstos da produtividade de mandioca em Pernambuco




Fonte: Elaboração própria (2026).

Figura F15 – Evolução dos valores observados e previstos da produtividade de milho em Pernambuco




Fonte: Elaboração própria (2026).

Figura F16 – Evolução dos valores observados e previstos do VPH de feijão em Pernambuco




Fonte: Elaboração própria (2026).

Figura F17 – Evolução dos valores observados e previstos do VPH de mandioca em Pernambuco




Fonte: Elaboração própria (2026).

Figura F18 – Evolução dos valores observados e previstos do VPH de milho em Pernambuco




Fonte: Elaboração própria (2026).

Figura F19 – Evolução dos valores observados e previstos da produtividade de arroz no Maranhão




Fonte: Elaboração própria (2026).

Figura F20 – Evolução dos valores observados e previstos da produtividade de feijão no Maranhão




Fonte: Elaboração própria (2026).

Figura F21 – Evolução dos valores observados e previstos da produtividade de mandioca no Maranhão




Fonte: Elaboração própria (2026).

Figura F22 – Evolução dos valores observados e previstos da produtividade de milho no Maranhão




Fonte: Elaboração própria (2026).

Figura F23 – Evolução dos valores observados e previstos do VPH de arroz no Maranhão




Fonte: Elaboração própria (2026).

Figura F24 – Evolução dos valores observados e previstos do VPH de feijão no Maranhão




Fonte: Elaboração própria (2026).

Figura F25 – Evolução dos valores observados e previstos do VPH de mandioca no Maranhão




Fonte: Elaboração própria (2026).

Figura F26 – Evolução dos valores observados e previstos do VPH de milho no Maranhão




Fonte: Elaboração própria (2026).

Figura F27 – Evolução dos valores observados e previstos da produtividade de arroz no Piauí




Fonte: Elaboração própria (2026).

Figura F28 – Evolução dos valores observados e previstos da produtividade de feijão no Piauí




Fonte: Elaboração própria (2026).

Figura F29 – Evolução dos valores observados e previstos da produtividade de mandioca no Piauí




Fonte: Elaboração própria (2026).

Figura F30 – Evolução dos valores observados e previstos da produtividade de milho no Piauí




Fonte: Elaboração própria (2026).

Figura F31 – Evolução dos valores observados e previstos do VPH de arroz no Piauí




Fonte: Elaboração própria (2026).

Figura F32 – Evolução dos valores observados e previstos do VPH de feijão no Piauí




Fonte: Elaboração própria (2026).

Figura F33 – Evolução dos valores observados e previstos do VPH de mandioca no Piauí



Fonte: Elaboração própria (2026).


Figura F34 – Evolução dos valores observados e previstos do VPH de milho no Piauí



Fonte: Elaboração própria (2026).


APÊNDICE G – INPR E VPA OBSERVADOS E PREVISTOS NOS ESTADOS ANALISADOS ANTES E DEPOIS DO AGROAMIGO

Figura G1 – INPR observado e previsto no Ceará




Fonte: Elaboração própria (2026).

Figura G2 – VPA observado e previsto no Ceará




Fonte: Elaborada pela autora com base nos dados da pesquisa (2026).

Figura G3 – INPR observado e previsto na Bahia




Fonte: Elaboração própria (2026).

Figura G4 – VPA observado e previsto na Bahia




Fonte: Elaboração própria (2026).

Figura G5 – INPR observado e previsto em Pernambuco




Fonte: Elaboração própria (2026).

Figura G6 – VPA observado e previsto em Pernambuco




Fonte: Elaboração própria (2026).

Figura G7 – INPR observado e previsto no Maranhão




Fonte: Elaboração própria (2026).

Figura G8 – VPA observado e previsto no Maranhão




Fonte: Elaboração própria (2026).

Figura G9 – INPR observado e previsto no Piauí



Fonte: Elaboração própria (2026).

Figura G10 – VPA observado e previsto no Piauí



Fonte: Elaboração própria (2026).