

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS NATURAIS E EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM METEOROLOGIA

Diogo Alessandro Arsego

**MODELO ESTATÍSTICO DE PREVISÃO DE PRODUTIVIDADE DE SOJA
E ARROZ PARA O RIO GRANDE DO SUL**

Santa Maria, RS
2017

Diogo Alessandro Arsego

**MODELO ESTATÍSTICO DE PREVISÃO DE PRODUTIVIDADE DE SOJA E ARROZ
PARA O RIO GRANDE DO SUL**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Meteorologia, Área de Concentração em Estudos e aplicações em tempo e clima, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Doutor em Meteorologia**.

ORIENTADORA: Prof.^a Simone Erotildes Teleginski Ferraz

COORIENTADOR: Prof. Nereu Augusto Streck

Santa Maria, RS
2017

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

Arsego, Diogo Alessandro
Modelo estatístico de previsão de produtividade de soja e arroz para o Rio Grande do Sul / Diogo Alessandro Arsego.- 2017.
156 p.; 30 cm

Orientador: Simone Erotildes Teleginski Ferraz
Coorientador: Nereu Augusto Streck
Tese (doutorado) - Universidade Federal de Santa Maria, Centro de Ciências Naturais e Exatas, Programa de Pós-Graduação em Meteorologia, RS, 2017

1. Produtividade Agrícola 2. Índices Climáticos 3. Previsão de Safra 4. Modelo Estatístico I. Ferraz, Simone Erotildes Teleginski II. Streck, Nereu Augusto III. Título.

©2017

Todos os direitos autorais reservados a Diogo Alessandro Arsego. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

End. Eletr.: diogo.arsego@gmail.com

Diogo Alessandro Arsego

**MODELO ESTATÍSTICO DE PREVISÃO DE PRODUTIVIDADE DE SOJA E ARROZ
PARA O RIO GRANDE DO SUL**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Meteorologia, Área de Concentração em Estudos e aplicações em tempo e clima, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Doutor em Meteorologia**.

Aprovado em 14 de agosto de 2017:

Simone Erotildes Teleginski Ferraz, Dra. (UFSM)
(Presidenta/Orientadora)

Andréa de Oliveira Cardoso, Dra. (UFABC) (videoconferência)

Cleber Maus Alberto, Dr. (UNIPAMPA)

Jônatan Dupont Tatsch, Dr. (UFSM)

Nathalie Tissot Boiaski, Dra. (UFSM)

Santa Maria, RS
2017

DEDICATÓRIA

A meus pais

AGRADECIMENTOS

Agradeço ...

... a Deus

... a minha família, especialmente aos meus pais (Mirian e Nelson), por serem meus exemplos, minha inspiração, estarem sempre ao meu lado e sempre me incentivarem a buscar o meu melhor.

... a Vivian pelo companheirismo, paciência e por estar ao meu lado nos momentos de incerteza, incentivando e auxiliando no desenvolvimento do trabalho.

... a professora Simone pela orientação, atenção e conhecimento a mim dedicados ao longo do período do doutorado.

... aos professores Nereu e Andréa pela participação no comitê de orientação que foi fundamental para o desenvolvimento desta pesquisa.

... a PPGMet pela oportunidade e bolsa concedida.

... aos colegas de Santa Maria, do café e do futebol, principalmente, Adriano, Pablo, Daniel, Mariana, Puntel, Geovane, Gisele, Marcelo e Franciano.

... aos colegas da FURG, especialmente, Maurício Mata, Fujita, Iole, Camila e Mariah.

... aos colegas do CPTEC e amigos de Cachoeira Paulista, principalmente, Elton, Marquinhos, Liviany, Jhonatan, Moacir e Pará.

RESUMO

MODELO ESTATÍSTICO DE PREVISÃO DE PRODUTIVIDADE DE SOJA E ARROZ PARA O RIO GRANDE DO SUL

AUTOR: Diogo Alessandro Arsego

ORIENTADORA: Simone Erotildes Teleginski Ferraz

COORDENADOR: Nereu Augusto Streck

Nesta pesquisa de doutorado, destaca-se a utilidade da inserção de indicadores climáticos em um modelo estatístico de previsão de produtividade de arroz e soja no Rio Grande do Sul. Inicialmente, dados de produtividade das duas culturas fornecidos pelo IBGE foram separados em grupos de comportamento homogêneo em termo da produtividade média. Para a soja, o período de estudo foi de 1974 a 2013, excluindo-se a safra de 1983 por não constar na base de dados. Destaca-se a região nordeste do Estado com maior produtividade, enquanto os municípios situados no noroeste apresentam as séries com menor produtividade média. Na cultura do arroz, o estudo compreendeu os anos de 1990 a 2013 e o oeste e sul do Estado apresentam a maior produtividade média ao longo do período de estudo e nos municípios da depressão central e próximos a Lagoa dos Patos são observadas a menor produtividade média. Após esta etapa, foram realizadas correlações defasadas entre indicadores climáticos e a produtividade média de cada um dos grupos homogêneos de forma a identificar padrões de teleconexão que exerçam influência na variabilidade interanual de produtividade de arroz e soja no Estado. Para a soja, os indicadores climáticos que apresentaram maiores correlações foram a Oscilação Ártica, a Oscilação do Atlântico Norte além de uma região no Oceano Atlântico Sul entre 20°S/30°S e 20°W/40°W. De forma geral, o arroz apresentou correlações mais elevadas que a soja, destacando-se, principalmente, os índices referentes as componentes oceânica e atmosférica do fenômeno El Niño Oscilação Sul e o índice referente a Oscilação Decadal do Pacífico. Além dos índices de maior correlação com cada grupo homogêneo, referente as culturas do arroz e da soja, foram adicionadas áreas de Temperatura da Superfície do Mar do oceano global com elevada correlação com a produtividade para a elaboração de um modelo estatístico de regressão para a previsão de safra no Rio Grande do Sul. Por meio do método da Regressão de Componentes Principais, foram selecionadas as combinações de índices que fornecessem a melhor previsão para cada grupo e cultura com o intuito de fornecer no mês de outubro, período em que se inicia a maior parte do plantio de soja e arroz no Estado, uma estimativa de produtividade baseada em indicadores obtidos até o mês de setembro. O modelo apresentou bons resultados, incluindo-se, assim, como ferramenta de apoio no planejamento de safra de arroz e soja no Estado gaúcho. À medida que ocorre o avanço no plantio e desenvolvimento das culturas, o modelo pode ser atualizado com a inclusão de novos índices e ser, também, útil como ferramenta de acompanhamento de safra e de auxílio para eventuais correções de estimativas que necessitem ser realizadas.

Palavras-chave: Arroz. Soja. Produtividade. Indicadores Climáticos. Modelo Estatístico de Regressão.

ABSTRACT

STATISTICAL MODEL OF SOYBEAN AND RICE YIELD FORECAST FOR RIO GRANDE DO SUL

AUTHOR: Diogo Alessandro Arsego

ADVISOR: Simone Erotildes Teleginski Ferraz

CO-ADVISOR: Nereu Augusto Streck

In this PhD thesis, the usefulness of the insertion of climatic indicators in a statistical model for predicting rice and soybean yield in Rio Grande do Sul is presented. Initially, yield data of the two crops were separated into groups of homogeneous behavior in term of average yield. For soybean, the study period was from 1974 to 2013, excluding the 1983 crop because it was not included in the database. The northeast region of the State with the highest yield is highlighted, while the municipalities located in the northwest present series with lower average yield. In the rice crop, the study comprised the years 1990 to 2013 and the western and southern regions of the State show the highest average yield during the study period. In the municipalities of the central depression and near the Patos Lagoon the lowest average yield is observed. After this stage, lagged correlations were made between climatic indicators and a mean yield of each of the homogeneous groups in order to identify teleconnection patterns that influence the interannual variability of rice and soybean yield in the State. For soybean, the climatic indicators that presented the highest correlations were the Arctic Oscillation, North Atlantic Oscillation in addition to a region in the South Atlantic Ocean between 20°S/30°S and 20°W/40° W. Rice, in general, presented higher correlations than soybean. This fact highlighting mainly the indices referring to the oceanic and atmospheric components of the phenomenon El Niño Southern Oscillation and the index referring to Pacific Decadal Oscillation. To the highest correlation indexes with each homogeneous group, such as rice and soybean cultures, areas of Sea Surface Temperature with a high production correlation were added. Thereby a statistical regression model to crop forecast in Rio Grande do Sul may be elaborated. Through the Principal Component Regression method, the predictors for each group and culture were selected with the purpose of providing in October a yield estimate based on indicators obtained up to the month of September. October is when a major part of the soybean and rice are sown. The model shows good results, including as a support tool in the planning of rice and soybean harvest in the State of Rio Grande do Sul. As the advance in planting and crop development occurs the model can be updated with the inclusion of new index. It is also useful as a crop tracking tool and as an aid to eventual corrections of estimates that need to be made.

Keywords: Rice. Soybean. Yield. Climate Index. Statistical Regression Model.

LISTA DE FIGURAS

Figura 2.1 – Calendário médio da cultura da soja para o Estado do Rio Grande do Sul.	28
Figura 2.2 – Zoneamento agroclimático da soja para o Rio Grande do Sul.	28
Figura 2.3 – Calendário médio da cultura do arroz para o Estado do Rio Grande do Sul.	29
Figura 2.4 – Zoneamento agroclimático do arroz para o Rio Grande do Sul.	30
Figura 3.1 – Representação esquemática da área aproximada de referência dos índices climáticos utilizados.	38
Figura 3.2 – Representação esquemática das áreas do Oceano Atlântico destacadas como regiões de influência na precipitação do Rio Grande do Sul nos estudos de Santos e Diniz (2014) (ATSM1) e Cataldi et al. (2010) (ATSM2). O campo de TSM refere-se a climatologia do mês de janeiro para o período de estudo.	39
Figura 3.3 – Fluxograma utilizado para a elaboração do modelo estatístico de previsão de produtividade.	45
Figura 4.1 – Mapa das regiões homogêneas de produtividade de soja no Rio Grande do Sul com a distribuição espacial dos grupos G1, G2 e G3 resultante da análise de agrupamento.	48
Figura 4.2 – Perfis médios de produtividade de grãos de soja dos grupos: G1 (azul), G2 (preto) e G3 (verde). A área sombreada delimita o desvio padrão de cada uma das séries.	48
Figura 4.3 – Correlação entre os indicadores climáticos e a produtividade de soja entre maio e agosto para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.	51
Figura 4.4 – Correlação entre os indicadores climáticos e a produtividade de soja entre setembro e dezembro para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.	52
Figura 4.5 – Correlação entre os indicadores climáticos e a produtividade de soja entre janeiro e abril para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.	53
Figura 4.6 – Relação entre anomalias de TSM na região do Niño 3.4 em novembro e anomalias de produtividade para o grupo: a) G1, b) G2 e c) G3. No gráfico, quadrados representam eventos de El Niño, círculos de neutralidade e asteriscos de La Niña.	58
Figura 4.7 – Correlação entre anomalia da temperatura da superfície do mar no mês de abril e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	61
Figura 4.8 – Correlação entre anomalia da temperatura da superfície do mar no mês de maio e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	62
Figura 4.9 – Correlação entre anomalia da temperatura da superfície do mar no mês de	

	junho e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	63
Figura 4.10	– Correlação entre anomalia da temperatura da superfície do mar no mês de julho e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	64
Figura 4.11	– Correlação entre anomalia da temperatura da superfície do mar no mês de agosto e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	65
Figura 4.12	– Correlação entre anomalia da temperatura da superfície do mar no mês de setembro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	66
Figura 4.13	– Correlação entre anomalia da temperatura da superfície do mar no mês de outubro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	67
Figura 4.14	– Correlação entre anomalia da temperatura da superfície do mar no mês de novembro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	68
Figura 4.15	– Correlação entre anomalia da temperatura da superfície do mar no mês de dezembro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	69
Figura 4.16	– Correlação entre anomalia da temperatura da superfície do mar no mês de janeiro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	70
Figura 4.17	– Correlação entre anomalia da temperatura da superfície do mar no mês de fevereiro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	71
Figura 4.18	– Correlação entre anomalia da temperatura da superfície do mar no mês de março e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	72
Figura 4.19	– Relação entre anomalias de TSM no mês de setembro na região próxima a 50°S/72°E e anomalias de produtividade no Grupo 1. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) de TSM nessa região.	73
Figura 4.20	– Comparação entre a produtividade média da soja do Grupo 1 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da	

	série histórica do grupo.	75
Figura 4.21	– Relação entre anomalias de TSM no mês de setembro na região próxima a 48°S/146°E e anomalias de produtividade no Grupo 2. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias positivas (negativas) de TSM nessa região.	77
Figura 4.22	– Comparação entre a produtividade média da soja do Grupo 2 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.	78
Figura 4.23	– Relação entre anomalias de TSM no mês de setembro na região próxima a 48°S/146°E e anomalias de produtividade no Grupo 3. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias positivas (negativas) de TSM nessa região.	79
Figura 4.24	– Comparação entre a produtividade média da soja do Grupo 3 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; e) janeiro e f) fevereiro. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.	81
Figura 4.25	– Mapa das regiões homogêneas de produtividade de arroz no Rio Grande do Sul com a distribuição espacial dos grupos G1, G2 e G3 resultante da análise de agrupamento. Os limites e a numeração referem-se às regiões orizícolas do Estado segundo o IRGA.	85
Figura 4.26	– Perfis médios de produtividade de grãos de arroz dos grupos: G1 (azul), G2 (preto) e G3 (verde). A área sombreada delimita o desvio padrão de cada uma das séries.	85
Figura 4.27	– Correlação entre os indicadores climáticos e a produtividade de arroz entre abril e julho para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.	88
Figura 4.28	– Correlação entre os indicadores climáticos e a produtividade de arroz entre agosto e novembro para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.	89
Figura 4.29	– Correlação entre os indicadores climáticos e a produtividade de arroz entre dezembro e março para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.	90
Figura 4.30	– Correlação entre anomalia da temperatura da superfície do mar no mês de abril e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	94
Figura 4.31	– Correlação entre anomalia da temperatura da superfície do mar no mês de maio e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	95

Figura 4.32 – Correlação entre anomalia da temperatura da superfície do mar no mês de junho e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	96
Figura 4.33 – Correlação entre anomalia da temperatura da superfície do mar no mês de julho e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	97
Figura 4.34 – Correlação entre anomalia da temperatura da superfície do mar no mês de agosto e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	98
Figura 4.35 – Correlação entre anomalia da temperatura da superfície do mar no mês de setembro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	99
Figura 4.36 – Correlação entre anomalia da temperatura da superfície do mar no mês de outubro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	100
Figura 4.37 – Correlação entre anomalia da temperatura da superfície do mar no mês de novembro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	101
Figura 4.38 – Correlação entre anomalia da temperatura da superfície do mar no mês de dezembro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	102
Figura 4.39 – Correlação entre anomalia da temperatura da superfície do mar no mês de janeiro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	103
Figura 4.40 – Correlação entre anomalia da temperatura da superfície do mar no mês de fevereiro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	104
Figura 4.41 – Correlação entre anomalia da temperatura da superfície do mar no mês de março e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.	105
Figura 4.42 – Relação entre anomalias de TSM no mês de setembro na região delimitada por Santos e Diniz (2014) (ATSM1) e anomalias de produtividade de arroz no Grupo 1. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) de TSM nessa região.	106
Figura 4.43 – Relação entre o índice do mês de abril referente a Oscilação Quase-Bienal e anomalias de produtividade de arroz no Grupo 1. O percentual indica o número de vezes em que ocorreram anomalias positivas (nega-	

	tivas) de produtividade associadas a anomalias negativas (positivas) do índice.	107
Figura 4.44	– Comparação entre a produtividade média do arroz do Grupo 1 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.	108
Figura 4.45	– Relação entre anomalias de TSM no mês de setembro na região oceânica próxima a 19°S/121°W e anomalias de produtividade de arroz no Grupo 2. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) de TSM nessa região.	110
Figura 4.46	– Comparação entre a produtividade média do arroz do Grupo 2 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.	111
Figura 4.47	– Relação entre anomalias de TSM no mês de agosto na região oceânica próxima a 27°S/159°W e anomalias de produtividade de arroz no Grupo 3. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) de TSM nessa região.	113
Figura 4.48	– Comparação entre a produtividade média do arroz do Grupo 3 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.	114
Figura A.1	– Variação das anomalias de TSM na região do Niño 3.4 (superior) e o Índice de Oscilação Sul (inferior) durante o período de estudo. A linha preta sólida indica a tendência linear da série.	129
Figura B.1	– Variação do índice mensal referente a NAO durante o período de estudo. A linha preta sólida indica a tendência linear da série.	131
Figura C.1	– Variação do índice mensal referente a PNA durante o período de estudo. A linha preta sólida indica a tendência linear da série.	133
Figura D.1	– Variação do índice mensal referente a AMO durante o período de estudo. A linha preta sólida indica a tendência linear da série.	135
Figura E.1	– Variação do índice mensal referente a TSA durante o período de estudo. A linha preta sólida indica a tendência linear da série.	137
Figura F.1	– Variação do índice mensal referente a TNA durante o período de estudo. A linha preta sólida indica a tendência linear da série.	139
Figura G.1	– Variação do índice mensal referente a ODP durante o período de estudo. A linha preta sólida indica a tendência linear da série.	141
Figura H.1	– Variação do índice mensal referente a QBO durante o período de estudo. A linha preta sólida indica a tendência linear da série.	143
Figura I.1	– Variação do índice mensal referente ao AMM durante o período de estudo. A linha preta sólida indica a tendência linear da série.	145
Figura J.1	– Variação do índice mensal referente ao AO durante o período de estudo. A linha preta sólida indica a tendência linear da série.	147

Figura K.1 – Variação do índice mensal referente a OAA durante o período de estudo.
A linha preta sólida indica a tendência linear da série.149

LISTA DE TABELAS

Tabela 3.1 – Indicação do número de municípios excluídos por não apresentarem série completa, por apresentarem baixa correlação com a produtividade do Estado e número de municípios restantes utilizados no Estudo para cada cultura.....	35
Tabela 4.1 – Principais resultados obtidos que evidenciam as correlações ao nível de confiança de 95% e o sinal destas correlações entre os índices climáticos mensais e a produtividade média de soja dos três grupos homogêneos. .	54
Tabela 4.2 – Quantidade de ocorrência das fases positiva, negativa e de neutralidade com relação ao fenômeno El Niño durante os meses de estudo.	56
Tabela 4.3 – Correlação e nível de confiança da correlação entre a produtividade média dos três grupos homogêneos e anomalias de TSM na região do Niño 3.4 para eventos de El Niño. *NS: correlação não significativa.....	56
Tabela 4.4 – Correlação e nível de confiança da correlação entre a produtividade média dos três grupos homogêneos e anomalias de TSM na região do Niño 3.4 para situações de neutralidade. *NS: correlação não significativa.	57
Tabela 4.5 – Correlação e nível de confiança da correlação entre a produtividade média dos três grupos homogêneos e anomalias de TSM na região do Niño 3.4 para eventos de La Niña. *NS: correlação não significativa.	57
Tabela 4.6 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo da soja referente ao Grupo 1 para as previsões dos meses de outubro a março.	76
Tabela 4.7 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo da soja referente ao Grupo 2 para as previsões dos meses de outubro a março.	77
Tabela 4.8 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo da soja referente ao Grupo 3 para as previsões dos meses de outubro a março.	80
Tabela 4.9 – Previsão estatística de produtividade de soja para as safras 2013/2014 e 2014/2015 para os Grupos 1, 2 e 3. Os valores indicam a probabilidade da produtividade ser acima, abaixo ou dentro da normal climatológica do período de estudo.	83
Tabela 4.10 – Produtividade registrada nos Grupos 1, 2 e 3 nas safras de 2013/2014 e 2014/2015 e média climatológica de produtividade dos três grupos ao longo do período de estudo.	83
Tabela 4.11 – Principais resultados obtidos que evidenciam as correlações ao nível de confiança de 95% e o sinal destas correlações entre os índices climáticos mensais e a produtividade média de arroz dos três grupos homogêneos.	92
Tabela 4.12 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo do arroz referente ao Grupo 1 para as previsões dos meses de outubro a março.	109
Tabela 4.13 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo do arroz referente ao Grupo 2 para as previsões dos meses de outubro a março.	112
Tabela 4.14 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo do arroz referente ao Grupo 3 para as previsões dos meses de outu-	

bro a março.	115
Tabela 4.15 – Previsão estatística de produtividade de arroz para as safras 2015/2016 e 2016/2017 para os Grupos 1, 2 e 3. Os valores indicam a probabilidade da produtividade ser acima, abaixo ou dentro da normal climatológica do período de estudo.	116
Tabela 4.16 – Produtividade registrada nos Grupos 1, 2 e 3 nas safras de 2015/2016 e 2016/2017 e média climatológica de produtividade dos três grupos ao longo do período de estudo.	117
Tabela L.1 – Municípios com produtividade homogênea de soja.	151
Tabela M.1 – Lista de preditores utilizados para o Grupo 1 de soja para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.	153
Tabela N.1 – Lista de preditores utilizados para o Grupo 2 de soja para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.	155
Tabela O.1 – Lista de preditores utilizados para o Grupo 3 de soja para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.	157
Tabela P.1 – Municípios com produtividade homogênea de arroz.	159
Tabela Q.1 – Lista de preditores utilizados para o Grupo 1 de arroz para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.	161
Tabela R.1 – Lista de preditores utilizados para o Grupo 2 de arroz para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.	163
Tabela S.1 – Lista de preditores utilizados para o Grupo 3 de arroz para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.	165

LISTA DE ABREVIATURAS E SIGLAS

<i>AMM</i>	Modo Meridional do Atlântico
<i>AMO</i>	Oscilação Multidecadal do Atlântico
<i>AO</i>	Oscilação Ártica
<i>ATSM1</i>	Anomalia de TSM no Oceano Atlântico entre 20°S/30°S e 20°W/40°W
<i>ATSM2</i>	Anomalia de TSM no Oceano Atlântico entre 33°S/43°S e 48°W/63°W
<i>CC</i>	Coeficiente de Correlação
<i>Corr</i>	Correlação
<i>CPT</i>	Climate Predictability Tool
<i>CP</i>	Componente Principal
<i>EN</i>	El Niño
<i>ENOS</i>	El Niño Oscilação Sul
<i>IBGE</i>	Instituto Brasileiro de Geografia e Estatística
<i>IRGA</i>	Instituto Riograndense do Arroz
<i>IOS</i>	Índice de Oscilação Sul
<i>LN</i>	La Niña
<i>OMJ</i>	Oscilação Madden Julian
<i>NAO</i>	Oscilação do Atlântico Norte
<i>NINO</i>	Anomalia de TSM na região do Niño 3.4
<i>NOAA</i>	National Oceanic and Atmospheric Administration
<i>OAA</i>	Oscilação Antártica
<i>PCR</i>	Regressão de Componentes Principais
<i>ODP</i>	Oscilação Decadal do Pacífico
<i>PIB</i>	Produto Interno Bruto
<i>PNA</i>	Padrão Pacífico/América do Norte
<i>QBO</i>	Oscilação Quase Bianual
<i>RS</i>	Rio Grande do Sul
<i>RMSE</i>	Raiz do Erro Médio Quadrático

<i>TNA</i>	Anomalia de TSM no Atlântico Tropical Norte
<i>TSA</i>	Anomalia de TSM no Atlântico Tropical Sul
<i>TSM</i>	Temperatura da Superfície do Mar

SUMÁRIO

1	INTRODUÇÃO	23
2	REVISÃO BIBLIOGRÁFICA	27
2.1	CULTURAS AGRÍCOLAS E METEOROLOGIA NO RIO GRANDE DO SUL ..	27
2.1.1	Soja	27
2.1.2	Arroz	29
2.1.3	Influência da Variabilidade Climática no Regime de Precipitação no Rio Grande do Sul	30
2.1.4	Influência da Variabilidade Climática na Agricultura do Rio Grande do Sul	32
2.2	MODELOS DE PREVISÃO DE SAFRA	33
3	MATERIAIS E MÉTODOS	35
3.1	SÉRIES DE PRODUTIVIDADE	35
3.1.1	Filtragem dos Dados	35
3.1.2	Tendência Tecnológica	35
3.1.3	Regiões Homogêneas	36
3.2	INDICADORES CLIMÁTICOS	37
3.2.1	Indicadores Climáticos e a Produtividade de Soja	39
3.2.2	Indicadores Climáticos e a Produtividade de Arroz	40
3.2.3	Correlação Global de TSM e Produtividade	40
3.3	MODELO ESTATÍSTICO DE PREVISÃO DE SAFRA	40
3.3.0.1	<i>Seleção dos Preditores</i>	41
3.3.0.2	<i>Regressão de Componentes Principais</i>	42
3.3.0.3	<i>Validação do Modelo</i>	44
3.3.0.4	<i>Previsões de Safra</i>	45
4	RESULTADOS E DISCUSSÃO	47
4.1	SOJA	47
4.1.1	Regiões Homogêneas	47
4.1.2	Comparação Intraíndices	49
4.1.3	Influência do Fenômeno El Niño Oscilação Sul na Variabilidade Interanual da Produtividade de Soja no Rio Grande do Sul	55
4.1.4	Influência das Anomalias de TSM na Variabilidade Interanual da Produtividade de Soja no Rio Grande do Sul	59
4.1.5	Previsão Estatística - G1 Soja	73
4.1.5.1	<i>Preditores Selecionados</i>	73
4.1.5.2	<i>Validação Cruzada</i>	74
4.1.6	Previsão Estatística - G2 Soja	76
4.1.6.1	<i>Preditores Selecionados</i>	76
4.1.6.2	<i>Validação Cruzada</i>	76
4.1.7	Previsão Estatística - G3 Soja	79
4.1.7.1	<i>Preditores Selecionados</i>	79
4.1.7.2	<i>Validação Cruzada</i>	80
4.1.8	Previsão das safras de soja de 2013/2014 e 2014/2015	82
4.2	ARROZ	84
4.2.1	Regiões Homogêneas	84
4.2.2	Comparação Intraíndices	86

4.2.3	Influência das Anomalias de TSM na Variabilidade Interanual da Produtividade de Arroz no Rio Grande do Sul	92
4.2.4	Previsão Estatística - G1 Arroz	106
4.2.4.1	<i>Preditores Seleccionados.....</i>	106
4.2.4.2	<i>Validação Cruzada</i>	107
4.2.5	Previsão Estatística - G2 Arroz	109
4.2.5.1	<i>Preditores Seleccionados.....</i>	109
4.2.5.2	<i>Validação Cruzada</i>	110
4.2.6	Previsão Estatística - G3 Arroz	112
4.2.6.1	<i>Preditores Seleccionados.....</i>	112
4.2.6.2	<i>Validação Cruzada</i>	113
4.2.7	Previsão das safras de arroz de 2015/2016 e 2016/2017	115
5	CONCLUSÃO	119
	REFERÊNCIAS BIBLIOGRÁFICAS	123
	ANEXO A – EL NIÑO OSCILAÇÃO SUL - ENOS.....	129
	ANEXO B – OSCILAÇÃO DO ATLÂNTICO NORTE - NAO	131
	ANEXO C – PADRÃO DO PACÍFICO / AMÉRICA DO NORTE - PNA	133
	ANEXO D – OSCILAÇÃO MULTIDECADAL DO ATLÂNTICO - AMO.....	135
	ANEXO E – ANOMALIA DE TSM NO ATLÂNTICO TROPICAL SUL - TSA..	137
	ANEXO F – ANOMALIA DE TSM NO ATLÂNTICO TROPICAL NORTE -	
	TNA.....	139
	ANEXO G – OSCILAÇÃO DECADAL DO PACÍFICO - ODP	141
	ANEXO H – OSCILAÇÃO QUASE BIENAL - QBO	143
	ANEXO I – MODO MERIDIONAL DO ATLÂNTICO - AMM	145
	ANEXO J – OSCILAÇÃO ÁRTICA - AO	147
	ANEXO K – OSCILAÇÃO ANTÁRTICA - OAA	149
	ANEXO L – MUNICÍPIOS HOMOGÊNEOS DE PRODUTIVIDADE DE SOJA	151
	ANEXO M – PREDITORES - SOJA G1	153
	ANEXO N – PREDITORES - SOJA G2	155
	ANEXO O – PREDITORES - SOJA G3	157
	ANEXO P – MUNICÍPIOS HOMOGÊNEOS DE PRODUTIVIDADE DE AR-	
	ROZ.....	159
	ANEXO Q – PREDITORES - ARROZ - G1.....	161
	ANEXO R – PREDITORES - ARROZ - G2.....	163
	ANEXO S – PREDITORES - ARROZ - G3.....	165

1 INTRODUÇÃO

O setor do agronegócio é um dos principais componentes da economia brasileira e do Rio Grande do Sul (RS). No ano de 2015, a participação do setor agropecuário no Produto Interno Bruto (PIB) do Brasil representou aproximadamente 21% da produção nacional, sendo cerca de 14% relacionada a atividade agrícola (CEPEA, 2017). As principais culturas agrícolas do Estado são cultivadas durante o verão. Neste período, destacam-se, principalmente, as culturas da soja (terceiro Estado em produção) e do arroz (responsável por 70% da produção nacional). No ano de 2015 foram colhidas 15.700.264 toneladas de soja e 8.679.489 toneladas de arroz no RS (IBGE, 2017).

Dentre as atividades econômicas, a agricultura é a mais dependente das condições meteorológicas, tendo como principais variáveis responsáveis pela variabilidade da produtividade a precipitação, a temperatura do ar e a radiação solar (HOOGENBOOM, 2000). Em escala global, cerca de um terço da variabilidade na produtividade está associada a variabilidade climática (RAY et al., 2015). Embora o Rio Grande do Sul se caracterize por um regime climático de precipitações bem distribuídas ao longo do ano e com totais pluviométricos elevados (RAO; HADA, 1990; REBOITA et al., 2010), episódios de estiagem são recorrentes e estão associados a quedas de produtividade agrícola e prejuízos para a economia do Estado (LAZZARI, 2006).

Para a soja, a precipitação compreendida entre janeiro e março é fundamental para o sucesso da safra no RS (BERLATO; FONTANA, 1999; FERREIRA, 2006). Sendo a maior parte da cultura no Estado cultivada em condições de sequeiro (ANA, 2016), a distribuição irregular da precipitação nas fases de maior demanda de água (floração) e mais críticas ao déficit hídrico (enchimento de grãos) (FARIAS; NEUMAIER; NEPOMUCENO, 2009), torna-se o principal fator limitante à produtividade (ZANON; STRECK; GRASSINI, 2016). Recentemente, Sentelhas et al. (2015), demonstraram que, apesar de apresentar o maior potencial de produtividade de soja no Brasil, o RS é um dos Estados com menor produtividade média por conta dos frequentes períodos de estiagem.

Para o arroz, a temperatura do ar é um dos elementos climáticos de maior importância para o crescimento, o desenvolvimento e a produtividade da cultura. Em geral, a seca ou estiagem não são um fator limitante à produção no Rio Grande do Sul, uma vez que a chuva ocorrida durante o ano é suficiente para repor o volume de água dos mananciais para irrigação, das lagoas, barragens e rios. Apesar disso, excessos de chuva podem prejudicar o crescimento da planta, por reduzir a disponibilidade da radiação global durante o ciclo da cultura e por prejudicarem as práticas de manejo da cultura do arroz (HEINEMANN; STONE; SILVA, 2009).

Dada a alta dependência dos cultivos agrícolas às condições climáticas ao longo do período de desenvolvimento da cultura, a compreensão dos mecanismos responsá-

veis pela variabilidade climática e uma previsão confiável das condições meteorológicas ao longo do período de desenvolvimento torna-se fator determinante para o sucesso ou fracasso da safra agrícola. O principal mecanismo global de variabilidade interanual é o fenômeno acoplado El Niño Oscilação Sul (ENOS) (KAYANO; ANDREOLI, 1998) que possui influência marcante sobre o regime de precipitação no RS (RAO; HADA, 1990; GRIMM; FERRAZ; GOMES, 1998).

Assim como influencia no regime de chuva no Rio Grande do Sul, a variabilidade climática também está relacionada a alterações nas safras agrícolas. Evidências mostram que o ENOS exerce papel importante na produtividade de culturas por meio de alterações nos padrões de clima em algumas regiões (FERREIRA, 2006). De uma forma geral, no RS, o ENOS possui correlação positiva com a produtividade de soja (BERLATO; FONTANA, 1999) e milho (BERLATO; FARENZENA; FONTANA, 2005) e, negativa com arroz (MOTA, 2000) e trigo (CUNHA; DALMAGO; ESTEFANEL, 1999; ALBERTO et al., 2006).

Além do ENOS, outros padrões de teleconexão como a Oscilação Decadal do Pacífico (Mantua et al., 1997), Oscilação Antártica (Cavalcanti e Ambrizzi, 2009) e anomalias de Temperatura da Superfície do Mar no Oceano Atlântico (Cataldi et al., 2010; Santos e Diniz, 2014) também exercem influência direta no regime de precipitação sobre o Estado gaúcho. No entanto, a influência de tais padrões na variabilidade da produtividade agrícola do RS precisa ser mais investigada e explorada.

Estudos prévios demonstraram a utilidade do uso de indicadores climáticos como preditores em modelos estatísticos de previsão de precipitação (SANTOS; DINIZ, 2014; GRIMM; LEITE; SAHAI, 2004) e vazão (HASTENRATH, 1990; CARDOSO; CATALDI, 2012). Para a agricultura, anomalias de Temperatura da Superfície do Mar (TSM) no Oceano Pacífico Equatorial se mostraram como bons preditores de produtividade de milho no Nordeste (RAO et al., 1997). Apesar disso, não encontra-se na literatura o uso de indicadores climáticos como preditores de modelos estatísticos para estimativas de produtividade agrícola sobre o RS.

Modelos estatísticos apresentam-se como ferramenta poderosa para estimativas de produtividade tendo em vista seu baixo custo computacional e o fato de que, quando encontradas as variáveis preditoras adequadas, tornam-se de fácil aplicação para a atividade operacional. Apesar disso, tais modelos ficam restritos ao local para o qual foram elaborados, são suscetíveis a erros para eventos extremos não representados pelos dados utilizados na calibração e, nem sempre, a equação descritiva do modelo representa um processo físico válido (GOMMES, 1998). Outras desvantagens associadas a este tipo de modelo são a co-linearidade entre as variáveis preditoras e a suposição de estacionariedade, onde assume-se que as relações passadas serão mantidas no futuro (LOBELL; BURKE, 2010).

Atualmente, as estimativas de safra são realizadas com base em entrevistas com agricultores, agrônomos e cooperativas agrícolas (MONTEIRO et al., 2013). Mais recen-

temente, dados meteorológicos previstos provenientes de modelos regionais de previsão climática foram inseridos no modelo mecanístico SimulArroz apresentando bons resultados para a previsão de produtividade de arroz no RS (SILVA et al., 2016).

Assim sendo, dada a praticidade que um modelo estatístico oferece, a lacuna de estudos aprofundados da influência de indicadores climáticos na variabilidade agrícola do Estado e a importância da atividade para a economia do Rio Grande do Sul, surgiu o questionamento se seria possível, baseando-se em diferentes indicadores climáticos, fornecer antes mesmo do início do plantio, estimativas a respeito da produtividade esperada para a próxima safra. Aspirando um estudo que fornecesse impacto significativo para a sociedade o objetivo principal desta proposta de doutorado é:

Estabelecer uma relação entre indicadores climáticos e a produtividade agrícola de soja e arroz no Rio Grande do Sul que propicie a elaboração de um modelo estatístico para previsão de safra de cada cultura analisada.

Visando o êxito na meta estabelecida, os seguintes objetivos específicos foram instituídos:

- Delimitação dos municípios de produtividade significativa para cada cultura estudada;
- Organização dos municípios restantes em regiões de comportamento homogêneo de acordo com sua produtividade média;
- Análise da relação entre índices climáticos e a produtividade de soja e arroz no Rio Grande do Sul em diferentes defasagens;
- Identificação dos índices com maior influência e período em que a atuação destes índices é mais significativa;
- Elaboração de modelos estatísticos de produtividade para a previsão de safra com diferentes defasagens.

2 REVISÃO BIBLIOGRÁFICA

2.1 CULTURAS AGRÍCOLAS E METEOROLOGIA NO RIO GRANDE DO SUL

O Rio Grande do Sul destaca-se no cenário agrícola nacional de produção de grãos. Segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE), o valor de produção associado a atividade agrícola no RS no ano de 2015 foi de R\$ 30.633.382.000. As principais culturas agrícolas do Estado são a soja (15.700.264 toneladas colhidas em 2015), arroz (8.679.489 toneladas) e milho (5.563.555 toneladas) que são cultivados durante o verão. No inverno, embora em menor quantidade, destaca-se também a cultura do trigo com 1.391.829 toneladas colhidas na safra de 2015. Nos dados acima listados, evidenciam-se o arroz e a soja com área plantada de 1.127.916 hectares e 5.263.899 hectares, respectivamente, no ano de 2015. (IBGE, 2017).

2.1.1 Soja


O principal fator associado a queda de rendimento da cultura de soja no Sul do Brasil é o déficit hídrico durante a fase de enchimento de grãos (SENTELHAS et al., 2015). Além do período de floração e enchimento de grãos, a disponibilidade de água é importante na época de germinação e emergência (FARIAS; NEUMAIER; NEPOMUCENO, 2009).

Significativos déficits de água durante as fases de florescimento e enchimento de grãos provocam modificações fisiológicas na planta, como fechamento dos estômatos e dobramento das folhas, fator que provoca a queda prematura das folhas e flores e diminuição do rendimento (CARDOSO et al., 2011). Em situações de déficit hídrico, o índice de área foliar é menor e há, também, um encurtamento no período de enchimento de grãos, fatores que resultam em menor produtividade (THOMAS; COSTA, 1994). Por outro lado, excesso de chuva e dias nublados podem prejudicar a fotossíntese, arejamento do solo, o desenvolvimento das raízes e a fixação de nitrogênio no solo (FARIAS; NEUMAIER; NEPOMUCENO, 2009).

A Figura 2.1, extraída de Fontana et al. (2001), apresenta o calendário médio da cultura da soja para o Rio Grande do Sul. Nota-se que os períodos de floração e enchimento de grãos se concentram, principalmente, entre o começo de janeiro e meados de março. Estudos prévios demonstraram que a precipitação concentrada neste período (janeiro a março) é fundamental para o sucesso da safra (BERLATO; FONTANA, 1999; FERREIRA, 2006).

Pesquisas de zoneamento agrícola são importantes na minimização dos riscos re-

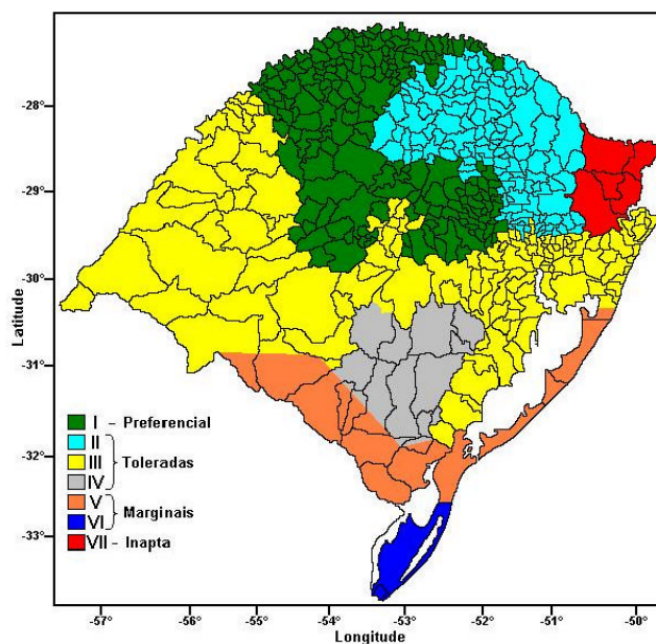
Figura 2.1 – Calendário médio da cultura da soja para o Estado do Rio Grande do Sul.



Fonte: Adaptado de Fontana et al. (2001).

lacionados a variabilidade climática e ajudam a identificar as melhores épocas e regiões para o plantio de cada cultura. Para o cultivo da soja há um gradiente que indica o aumento da magnitude das perdas, no sentido de nordeste para sudoeste, além de, na metade sul essas perdas serem sempre maiores (CUNHA et al., 2001). A Figura 2.2 apresenta o zoneamento agroclimático da cultura da soja no Rio Grande do Sul e sinaliza a metade norte do Estado como mais apta ao desenvolvimento desta cultura agrícola.

Figura 2.2 – Zoneamento agroclimático da soja para o Rio Grande do Sul.



Fonte: Adaptada de Melo (2003).

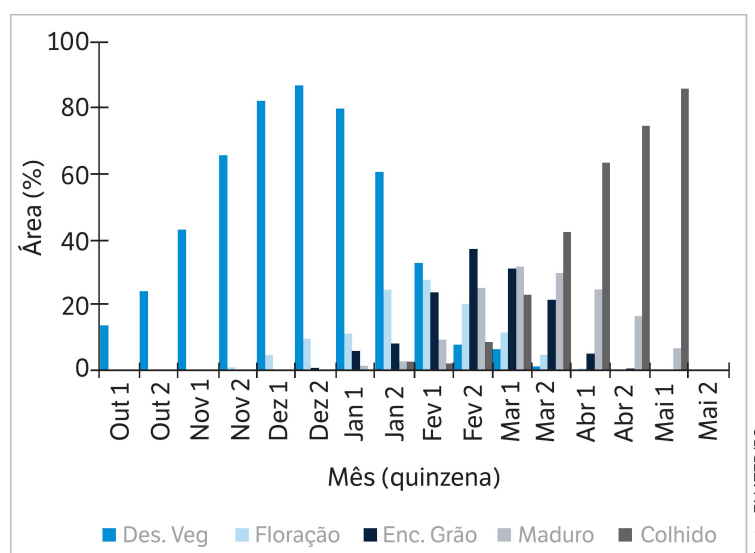
2.1.2 Arroz

O arroz é um dos alimentos mais importantes para a nutrição humana, sendo a base alimentar de mais de três bilhões de pessoas (SOSBAI, 2014). Estima-se que a produção de arroz necessita crescer, ao menos, 40% nas próximas 3 décadas para atender as demandas globais (WMO, 2012). Sendo o RS o responsável pela maior parte da produção nacional, a compreensão dos mecanismos responsáveis pela variabilidade da produção no Estado torna-se ainda mais importante.

Um dos elementos climáticos com maior influência na produtividade do arroz é a temperatura do ar (HEINEMANN; STONE; SILVA, 2009). A ocorrência de baixas temperaturas e de baixa disponibilidade de radiação solar durante as fases reprodutiva e de maturação da planta são fatores que estão relacionados com queda de produtividade no arroz (SOSBAI, 2014; MOTA, 2000). Devido ao fato das lavouras de arroz serem irrigadas, em geral, períodos de baixa precipitação não são limitantes à produção de arroz no Rio Grande do Sul, mas excessos de chuva podem prejudicar o crescimento da planta, por conta da redução da radiação global durante o desenvolvimento da cultura (HEINEMANN; STONE; SILVA, 2009).

A Figura 2.3, extraída de Klering et al. (2016), apresenta o calendário médio da cultura do arroz para o Rio Grande do Sul. Nesta mesma figura, nota-se que os períodos de floração e enchimento de grãos concentram-se, principalmente, entre janeiro e meados de março.

Figura 2.3 – Calendário médio da cultura do arroz para o Estado do Rio Grande do Sul.

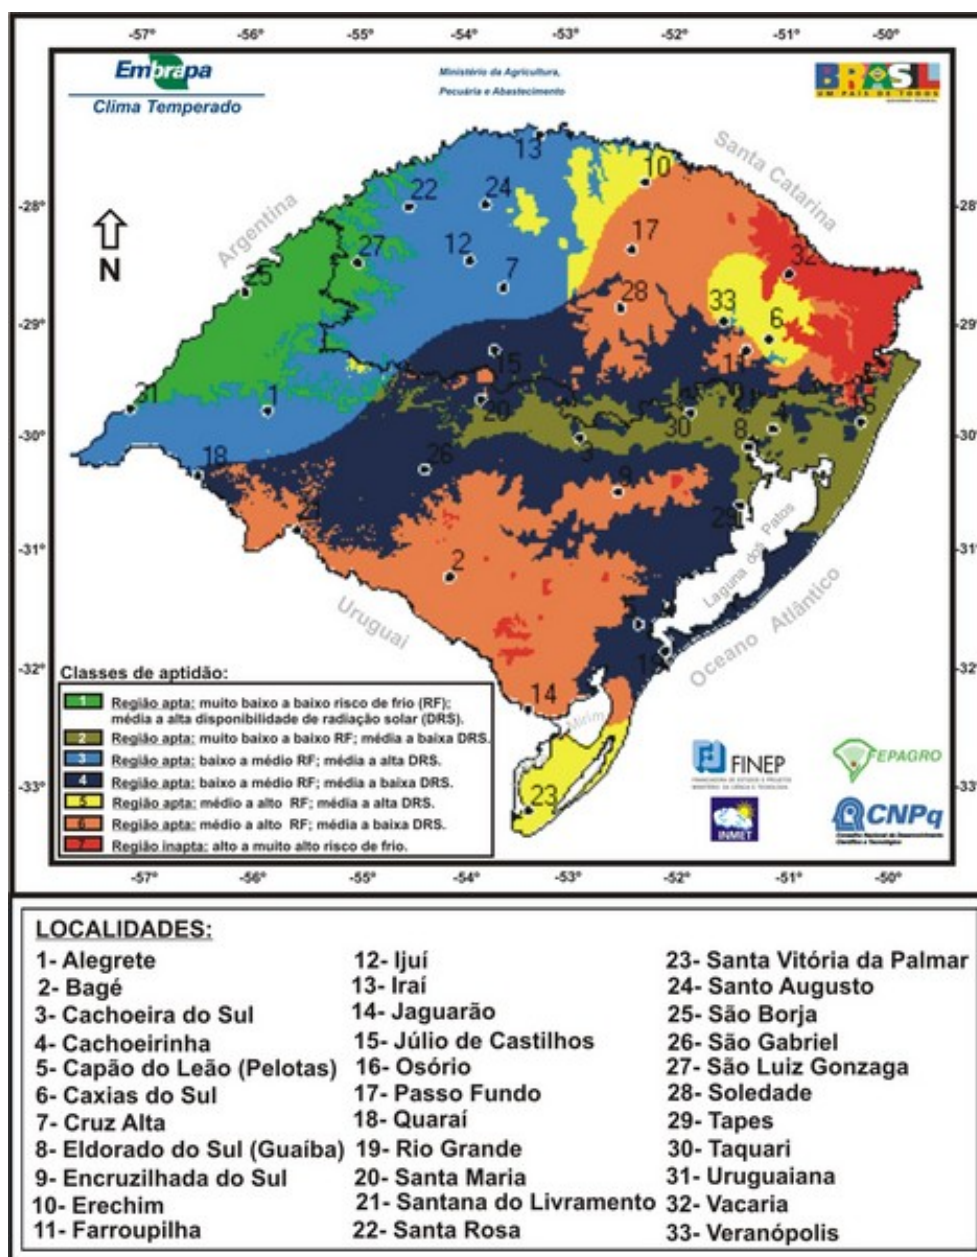


Fonte: Adaptado de Klering et al. (2016).

A combinação dos fatores acima citados, sinaliza a fronteira oeste como a região mais favorável a cultura do arroz no Estado por apresentar maior disponibilidade de radiação e, ao mesmo tempo, menores riscos de frio, como pode ser observado na Figura 2.4

que apresenta o zoneamento agroclimático do arroz para o Rio Grande do Sul.

Figura 2.4 – Zoneamento agroclimático do arroz para o Rio Grande do Sul.



Fonte: Extraída de <http://agromet.cpact.embrapa.br/zoneamento/macro_arroz/consulta.php>.

2.1.3 Influência da Variabilidade Climática no Regime de Precipitação no Rio Grande do Sul

Rao e Hada (1990) apresentaram o estudo da variação anual da precipitação no Brasil e caracterizaram os trimestres mais chuvosos para cada região, sendo a Região Sul

do Brasil caracterizada por precipitações bem distribuídas ao longo do ano. Além disso, a correlação entre a precipitação sobre o Rio Grande do Sul e o Índice de Oscilação Sul (IOS) mostra que a chuva sobre o Estado está significativa e negativamente relacionada ao índice, com correlação mais elevada durante a primavera.

As mudanças na circulação das células de Walker e Hadley e seus impactos na América do Sul durante os eventos de ENOS registrados na década de 80 foram descritas por Souza e Ambrizzi (2002). Durante os eventos de El Niño (EN) há uma inversão nos padrões climatológicos de circulação e são observados ramos descendentes das células de Hadley e Walker sobre parte do norte e nordeste da América do Sul. Por outro lado, na região subtropical, onde normalmente é observado o ramo descendente da célula de Hadley, anomalias positivas de circulação vertical são observadas. Nos episódios de La Niña (LN), há um fortalecimento da circulação de Hadley o que acarreta em anomalias negativas de precipitação sobre o sul da América do Sul.

Em estudo focado na região Sul do Brasil, Grimm, Ferraz e Gomes (1998) verificaram a influência dos fenômenos EN e LN no regime de chuva da região. Os autores demonstraram que toda região de estudo apresenta anomalias positivas (negativas) de precipitação durante a primavera do ano de ocorrência do evento quente (frio), com pico no mês de novembro. Além disso, o sudeste da região também apresenta tendência de precipitação acima da média durante o inverno no ano subsequente de ocorrência de EN.

Embora o fenômeno acoplado ENOS seja o mais conhecido e documentado na literatura, outros padrões de teleconexões também exercem papel importante no regime de precipitação do Sul do Brasil. Dentre estes, podem ser citados a Oscilação Decadal do Pacífico (ODP) (escala interdecadal), e Oscilação de Madden Julian (OMJ) (escala intrassazonal) e Oscilação Antártica (OAA).

A ODP é um fenômeno de mais baixa frequência, com variabilidade temporal de 20 a 30 anos, caracterizada por um dipolo de TSM entre o Pacífico Norte Central e Oeste e, o Pacífico Tropical Centro e Leste (MANTUA et al., 1997). Na América do Sul, a ODP atua construtivamente (destrutivamente) ao fenômeno ENOS quando estão na mesma fase (fase oposta) (KAYANO; ANDREOLI, 1998)

A OMJ é o modo equatorial mais importante na escala intrassazonal e possui impactos nas distribuições anômalas de precipitação nos trópicos e subtropicais. Na parte leste da América do Sul, situações ativas da OMJ estão relacionadas a aumentos na frequência de extremos de precipitação (KAYANO; JONES; DIAS, 2009).

Outro importante modo da variabilidade do clima na América do Sul é a OAA que, durante sua fase positiva (negativa) apresenta mais ciclones nas regiões circumpolares (latitudes médias) e menos nas latitudes médias (regiões circumpolares) (CAVALCANTI; AMBRIZZI, 2009).

Carvalho, Jones e Ambrizzi (2005) citaram a ligação entre a OAA e fenômenos de mais baixa frequência. Segundo o estudo, anomalias positivas (negativas) de TSM

no Pacífico Tropical favorecem fases negativas (positivas) da OAA. Os autores também demonstraram a relação entre a convecção tropical associada a OMJ e a OAA, em que situações de convecção no Pacífico Central estão relacionadas a fases negativas da OAA.

Mais recentemente, Cataldi et al. (2010) demonstraram que anomalias positivas de TSM na região de encontro entre as Correntes do Brasil e das Malvinas alteram o regime de chuvas e favorecem precipitações abaixo (acima) da média no Sul (Sudeste). Os autores ainda destacaram que situação semelhante a simulada no estudo foi observada durante o verão de 2005, ano em que o Rio Grande do Sul passou por uma forte estiagem.

2.1.4 Influência da Variabilidade Climática na Agricultura do Rio Grande do Sul

Da mesma forma que influencia no regime de chuva no Rio Grande do Sul, a variabilidade climática também está relacionada a alterações nas safras agrícolas. Evidências mostram que o ENOS exerce papel importante na produtividade de culturas mediante alterações nos padrões de clima em algumas regiões (FERREIRA, 2006). Por esse motivo, vários estudos têm sido desenvolvidos com o intuito de verificar as consequências das fases positivas e negativas do fenômeno no desenvolvimento das culturas.

Há fortes evidências de que o EN favorece a cultura da soja e determina produtividades recordes da oleaginosa em vários casos, uma vez que tais episódios estão relacionados a uma elevação da precipitação durante a fase crítica da cultura. No entanto, o fenômeno pode representar algum prejuízo no caso de repique muito intenso no outono, o que afetaria a colheita (BERLATO; FONTANA, 1999).

Para o arroz no RS, a relação entre o El Niño e a produtividade é oposta a observada para a soja (BERLATO; FONTANA, 2003). Em geral, episódios de EN são desfavoráveis a cultura enquanto eventos de La Niña estão associados a elevação da produtividade (CARMONA, 2001). Em Pelotas, episódios de LN forte estiveram associados a incidência de radiação solar acima da média no mês de fevereiro, fato que, associado com o pequeno número de horas com temperatura igual ou inferior a 15 °C no mesmo mês, resultaram em produtividade superior a média observada entre 1982 e 1998 (MOTA, 2000).

A influência do ENOS na variabilidade agrícola de outras culturas do Estado também foi objeto de estudos prévios. O milho, assim como a soja, possui correlação positiva com o El Niño (BERLATO; FARENZENA; FONTANA, 2005; BERLATO; FONTANA, 2003). O trigo, por sua vez, é influenciado negativamente pelo fenômeno (CUNHA; DALMAGO; ESTEFANEL, 1999; ALBERTO et al., 2006). No que diz respeito as culturas de inverno, além do trigo, o EN é desfavorável à cevada e, possivelmente, a outros cereais, sobretudo porque as precipitações pluviais intensas e frequentes, provocadas por este fenômeno no final da primavera, coincidem com o período de maturação e colheita desses cereais (BERLATO; FONTANA, 2003).

No entanto, o estudo recente de Tedeschi, Cavalcanti e Grimm (2013) demonstrou que os diferentes tipos do fenômeno ENOS (Canônico e Modoki) exercem influência distinta nos padrões de precipitação sobre a América do Sul. Enquanto, como listado anteriormente, eventos de El Niño (La Niña) Canônico estão associados a elevação (redução) da precipitação sobre o RS, em situações de El Niño Modoki há uma diminuição da precipitação sobre o Sul do Brasil durante o verão. Para eventos de La Niña Modoki, os autores não encontraram variações no regime de precipitação de verão no RS. Este fato reforça a necessidade de estudos mais amplos a cerca da influência deste fenômeno nas culturas agrícolas do RS.

Além disto, como visto na Seção 2.1.3, outros índices climáticos exerçam influência no regime de precipitação e, conseqüentemente, no rendimento agrícola, poucos estudos no Brasil têm abordado essa relação. Pesquisas realizadas em outras partes do globo sinalizam que a associação entre indicadores climáticos e produtividade agrícola é útil para o melhor planejamento das safras. Para o nordeste do Irã, indicadores climáticos relacionados à Oscilação do Atlântico Norte (NAO) e EN (na região do Niño 3.4) exercem influência na aridez do solo e, conseqüentemente, nos cultivos de trigo e cevada na região (BANNAYAN et al., 2010). Indicadores climáticos associados ao ENOS, a anomalias de TSM no Atlântico Tropical Norte (TNA) e ao Padrão Pacífico/América do Norte (PNA) também apresentam sinal marcante na variabilidade da produtividade de milho nos Estados Unidos (MARTINEZ; BAIGORRIA; JONES, 2009). Mais recentemente, Cherenkova, Bardin e Zolotokrylin (2015) encontraram sinais da influência da Oscilação Quase Bianaual (QBO) no cultivo do trigo na parte europeia da Rússia.

Ainda que a importância do ENOS na variabilidade interanual da produtividade agrícola do Rio Grande do Sul seja notável, fica evidente uma imensa lacuna a ser preenchida a respeito da influência que outros índices climáticos possam exercer na produtividade de arroz e soja no Estado gaúcho.

2.2 MODELOS DE PREVISÃO DE SAFRA

Segundo Gomme (1998), os modelos de avaliação do impacto dos fatores de tempo e clima nas produção agrícola podem ser classificados em:

- Modelos globais de biomassa: baseados em métodos descritivos que relacionam a biomassa com as condições do ambiente. Adequados para estudos climatológicos e agroclimatológicos globais.
- Modelos de vegetação: descrevem o comportamento da vegetação.
- Modelos estatísticos: importante ferramenta para estudos do impacto das condições

de tempo nas culturas. Relacionam parâmetros agronômicos como a produtividade outros fatores relacionados ao meio ambiente e clima. Se os preditores forem escolhidos corretamente, se caracterizam como uma ferramenta eficiente e de baixo custo. Aplicação mais comum é o uso de técnicas de regressão múltipla.

- Modelos de simulação: simulam a interação entre a planta e o ambiente baseados na química, física, fisiologia e anatomia.
- Demais modelos: outros métodos de estudo dos impactos do tempo na agricultura que não se encaixam nas categorias descritas acima.

As duas principais metodologias que têm sido empregadas para estudar a relação entre tempo e produtividade agrícola são os modelos de desenvolvimento de cultura e modelos de regressão (CAI et al., 2013). Por não necessitarem detalhes específicos a respeito de fisiologia e manejo da cultura, os modelos estatísticos são menos dependentes de dados de campo sendo assim, muito indicados para estudos em maior escala espacial onde os mesmos capturam o efeito global de todos os processos afetados por mudanças do clima (LOBELL; FIELD, 2007; LOBELL; BURKE, 2010).

Estudos prévios demonstraram que modelos estatísticos baseados em indicadores climáticos se caracterizam como ferramenta útil para a previsão de produtividade. Indicadores associados ao ENOS são úteis para previsão de produtividade de arroz na Indonésia (NAYLOR et al., 2001) e milho no Nordeste do Brasil (RAO et al., 1997; SUN et al., 2007). Também para o Milho, mas nos Estados Unidos, Martinez, Baigorria e Jones (2009) demonstraram ser possível uma previsão estatística baseada no ENOS, TNA, PNA e um índice relacionado a baixa pressão das Bermudas.

Para o Rio Grande do Sul, Ferreira (2006) apresentou um modelo estatístico de previsão de produtividade baseado em séries de precipitação do trimestre janeiro/fevereiro/março. Além disso, também foi demonstrada a influência do ENOS na variabilidade da precipitação e da produtividade de soja sem, no entanto, estabelecer uma previsão direta da produtividade baseada no índice referente ao ENOS.

Dada a marcante influência de padrões de teleconexão na variabilidade climática do Rio Grande do Sul e o êxito de estudos que estabeleceram uma ligação direta entre índices climáticos e produtividade agrícola permitindo uma previsão baseada nestes índices, estabelece-se a possibilidade da aplicação de metodologia semelhante para os estudos de variabilidade interanual da produtividade no Estado.

3 MATERIAIS E MÉTODOS

3.1 SÉRIES DE PRODUTIVIDADE

Nesta análise, foram utilizados dados de produtividade de soja e arroz dos 497 municípios do RS, fornecidos pelo IBGE. Para o arroz, o período de estudo compreende-se entre os anos de 1990 a 2013. Já para a soja, o período de estudo foi compreendido entre 1974 a 2013, com a ausência do ano referente a safra de 1983 que não consta na base de dados. O período de estudo maior para o caso da soja foi necessário para aumentar os graus de liberdade e, com isso, procurar um maior ajuste para o modelo empírico.

3.1.1 Filtragem dos Dados

Para eliminar dados espúrios ou séries de municípios de pouca representatividade para a cultura, foram adotados dois filtros: eliminação dos municípios com dados faltantes e/ou repetidos por três anos consecutivos e remoção de séries que apresentassem correlação inferior a 0,7 com a produtividade média do Estado de forma a manter apenas municípios representativos para cada cultura no RS. Na Tabela 3.1, estão listados o número de municípios excluídos por não possuírem uma série completa, por apresentarem baixa correlação com a produtividade do Estado (não produtores) e os municípios restantes utilizados neste estudo.

Tabela 3.1 – Indicação do número de municípios excluídos por não apresentarem série completa, por apresentarem baixa correlação com a produtividade do Estado e número de municípios restantes utilizados no Estudo para cada cultura.

	Série Incompleta	Não Produtores	Municípios Utilizados
Soja	399 (80 %)	11 (2 %)	87 (18 %)
Arroz	448 (90 %)	2 (1 %)	47 (9 %)

3.1.2 Tendência Tecnológica

No estudo de séries temporais de produtividade, a variabilidade interanual entre os dados deve-se a dois fatores: variabilidade climática e incremento tecnológico. O incremento ou tendência tecnológica representa uma taxa de aumento de produtividade ao

longo dos anos devido a melhoramentos genéticos e/ou avanços nas técnicas de manejo. Portanto, em estudos focados na variabilidade devido às condições climáticas, esta tendência tecnológica precisa ser removida (BANNAYAN et al., 2010).

A remoção da tendência tecnológica foi realizada através de uma abordagem que considera o rendimento ao longo do período dividido em duas séries: tendência e variação (WENJIAO; FULU; ZHAO, 2013). Nesta abordagem, assume-se que a tendência seja linear e esteja unicamente relacionada com o aumento da tecnologia e a sua remoção usando a Equação 3.1 fornece uma série temporal que, em tese, contém apenas variações climáticas.

$$Y_{ci} = Y_i - Y(X_i) + Y(X_f) \quad (3.1)$$

sendo que Y_{ci} é a produtividade corrigida para o ano i ; Y_i é a produtividade original do ano i ; $Y(X_i)$ é a produtividade estimada para o ano i através do modelo de regressão e $Y(X_f)$ é a produtividade do último ano estimada pela regressão linear.

Ressalta-se que outros métodos de remoção da tendência tecnológica foram testados: transformação logarítmica, regressão polinomial de segunda e terceira ordem, diferenças parciais e divisão da série por períodos. No entanto, por conta das séries resultantes serem semelhantes (elevada correlação) optou-se pela utilização do método mais simples descrito pela Equação 3.1.

3.1.3 Regiões Homogêneas

As séries foram separadas em grupos cujos membros apresentassem comportamento semelhante em termos de produtividade média. Por meio da análise de agrupamento os dados de produtividade dos municípios foram distribuídos em grupos que minimizem a diferença intragrupo e maximizem a diferença entre os membros de outro grupo.

A ideia central utilizada para o agrupamento é a medida de distâncias em que os grupos são compostos por membros separados por pequenas distâncias. A medida de distância mais comumente utilizada para verificar o nível de similaridade entre dois grupos de dados é a distância euclidiana (WILKS, 2006), dada por:

$$\|x - y\| = \sqrt{\sum_{k=1}^k (x_k - y_k)^2} \quad (3.2)$$

sendo que x_k e y_k são as observações dos membros e k é o número de observações.

O critério utilizado para o agrupamento foi o método hierárquico proposto por Ward (1963). Neste método, são formados grupos mutuamente exclusivos de forma que os

membros escolhidos são os que minimizem a soma das distâncias ao quadrado entre os pontos e o centróide do seu respectivo grupo.

$$W = \sum_{g=1}^G \sum_{i=1}^{n_g} \|x_i - \bar{x}_g\| = \sum_{g=1}^G \sum_{i=1}^{n_g} \sum_{k=1}^K (x_{i,k} - \bar{x}_{g,k})^2 \quad (3.3)$$

Foi realizado um corte no dendrograma de forma a reter três grandes grupos homogêneos para cada cultura (alta, média e baixa produtividade). A formação destes grupos permite a obtenção de uma série média de produtividade que represente a variabilidade interanual de cada grupo.

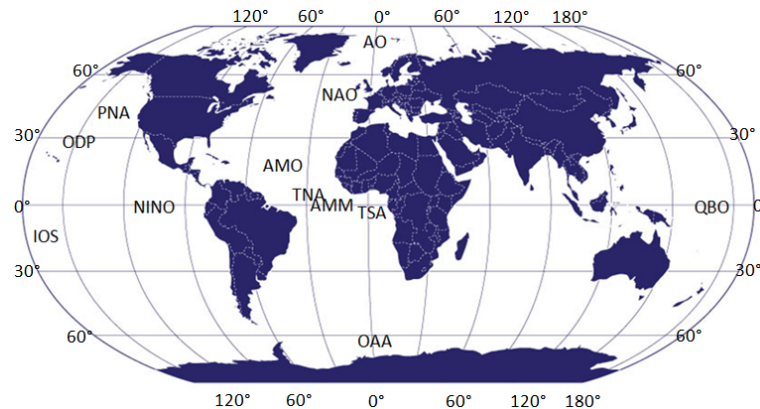
Os perfis médios obtidos puderam, então, ser relacionados a índices oceânicos e atmosféricos de forma a obter os indicadores climáticos com maior influência em cada grupo e cultura.

3.2 INDICADORES CLIMÁTICOS

A análise da influência dos padrões de teleconexão na variabilidade interanual da produtividade de soja e arroz no Rio Grande do Sul foi estudada com base na correlação entre a produtividade anual média para cada grupo homogêneo e os seguintes indicadores climáticos disponibilizados pela página do "National Oceanic and Atmospheric Administration - NOAA": Anomalia de TSM na região do Niño 3.4 (NINO – (TRENBERTH, 1997)); Índice de Oscilação Sul (IOS – (TRENBERTH, 1984)); Oscilação do Atlântico Norte (NAO – (ROGERS, 1985)); Padrão do Pacífico / América Norte (PNA – (WALLACE; FULU; ZHAO, 1981)); Oscilação Multidecadal do Atlântico (AMO – (SCHLESINGER; RAMANKUTTY, 1994)); Anomalia de TSM no Atlântico Tropical Sul (TSA – (ENFIELD et al., 1999)); Anomalia de TSM no Atlântico Tropical Norte (TNA – (ENFIELD et al., 1999)); Oscilação Decadal do Pacífico (ODP – (MANTUA et al., 1997)); Oscilação Quase Biental (QBO – (ANGELL; KORSHOVER, 1962)); Modo Meridional do Atlântico (AMM – (SERVAIN, 1991)); Oscilação Ártica (AO – (THOMPSON; WALLACE, 1998)) e Oscilação Antártica (OAA – (GONG; WANG, 1998)).

Na Figura 3.1 encontra-se a região de referência aproximada de cada um dos índices utilizados, sendo que a QBO cobre toda a região tropical do globo. Uma descrição mais detalhada de como são calculados os índices referentes a estes padrões de teleconexão e sua variação durante o período de estudo pode ser visualizada nos Anexos A a K, considerando as informações contidas na página da NOAA e nos artigos citados como referência de cada um deles.

Figura 3.1 – Representação esquemática da área aproximada de referência dos índices climáticos utilizados.



Fonte: Próprio autor.

Além dos indicadores acima listados, foram adicionados dois índices adicionais: ATSM1 e ATSM2 (Figura 3.2). O índice ATSM1 é referente a região do Atlântico Sul delimitada entre as latitudes de 20°S e 30°S e as longitudes 20°W e 40°W. Anomalias de TSM, nessa região, possuem correlação positiva com a precipitação no Rio Grande do Sul, principalmente, entre os meses de outubro e janeiro (SANTOS; DINIZ, 2014). O índice ATSM2 está relacionado a região oceânica compreendida entre 33°S e 43°S e 48°W e 63°W. Anomalias positivas (negativas) de TSM na região de encontro entre as Correntes do Brasil e das Malvinas alteram o regime de chuvas e favorecem precipitações abaixo (acima) da média no Sul (Sudeste) (CATALDI et al., 2010).


Estes índices foram criados por meio da normalização dos dados observados da seguinte forma (Equação 3.4):

$$ATSM = \frac{(x_{ij} - \bar{x}_i)}{\sigma_i} \quad (3.4)$$

sendo que x_{ij} é o valor observado no mês i e ano j , no caso da TSM o valor correspondente a média da TSM na região de estudo; \bar{x}_i é a média de todas observações do mês i e σ_i é o desvio padrão das observações no mês i . A climatologia de TSM utilizada na elaboração destes índices foi construída baseada numa série compreendida entre maio de 1973 e abril de 2013, totalizando assim, 40 anos de dados. Os dados de TSM possuem resolução de 1° e podem ser encontrados em: <<http://www.esrl.noaa.gov/psd/data/gridded/data.cobe.html>>.

Para analisar a influência de cada índice em cada grupo homogêneo das culturas de soja e arroz, foram realizadas correlações defasadas entre os índices climáticos associados a cada padrão de teleconexão e a produtividade média da soja e do arroz de cada um dos três grupos.

Figura 3.2 – Representação esquemática das áreas do Oceano Atlântico destacadas como regiões de influência na precipitação do Rio Grande do Sul nos estudos de Santos e Diniz (2014) (ATSM1) e Cataldi et al. (2010) (ATSM2). O campo de TSM refere-se a climatologia do mês de janeiro para o período de estudo.



Fonte: Próprio autor.

3.2.1 Indicadores Climáticos e a Produtividade de Soja

Para a soja, assumiu-se o mês de abril como referente a colheita, por ser o período em que é realizada a maior parte da colheita como pode ser visualizado na Figura 2.1, extraída de Fontana et al. (2001). Desta forma, as correlações foram analisadas com base nos indicadores de maio a dezembro do ano anterior e de janeiro a abril do ano de colheita. A primeira correlação é tomada entre o índice climático referente ao mês de maio do ano anterior e a produtividade do ano subsequente (lag 11), a segunda entre o índice do mês de junho do ano anterior e a produtividade do ano seguinte (lag 10) e assim, sucessivamente, até a última correlação entre o índice do mês de abril do ano referente à colheita e o valor de produtividade deste ano (lag 0).

O período de estudo utilizado para a correlação entre a produtividade de soja e os índices climáticos foi de 39 anos (1974 a 2013, excluído o ano de 1983). Definiu-se a significância estatística por meio do teste t de Student (FISHER; YATES, 1974) ao nível de confiança de 95% ($|r| > 0,267$) e 99% ($|r| > 0,37$). Para o índice referente à OAA, por se tratar de uma série menor (1980 a 2013), os valores de correlação são: $|r| > 0,293$ para

95% e $|r| > 0,405$ para 99%.

3.2.2 Indicadores Climáticos e a Produtividade de Arroz

Para o arroz, assumiu-se o mês de março como mês referente ao início da colheita, com base na Figura 2.3, extraída de Klering et al. (2016). Desta forma, as correlações foram analisadas com base nos indicadores de abril a dezembro do ano anterior e de janeiro a março do ano de colheita. A primeira correlação é tomada entre o índice climático referente ao mês de abril do ano anterior e a produtividade do ano subsequente (lag 11), a segunda entre o índice do mês de maio do ano anterior e a produtividade do ano seguinte (lag 10) e assim, sucessivamente, até a última correlação entre o índice do mês de março do ano referente à colheita e o valor de produtividade deste ano (lag 0).

O período de estudo utilizado para a correlação entre a produtividade de arroz e os índices climáticos foi de 24 anos (1990 a 2013). Definiu-se a significância estatística através do teste t de Student (FISHER; YATES, 1974) ao nível de confiança de 95% ($|r| > 0,345$) e 99% ($|r| > 0,472$).

3.2.3 Correlação Global de TSM e Produtividade

Baseado na série histórica de TSM elaborada e descrita na Seção 3.2, correlações globais entre os campos mensais de TSM e os perfis médios de produtividade de cada grupo homogêneo, tanto para o arroz como para a soja, foram correlacionados. Esta etapa, visou a obtenção de índices preditores associados a anomalias de TSM que pudessem resultar num incremento da destreza do modelo estatístico.

3.3 MODELO ESTATÍSTICO DE PREVISÃO DE SAFRA

Para cada grupo homogêneo e cada cultura foram desenvolvidos 6 modelos estatísticos diferentes que contemplaram diferentes fases de desenvolvimento da cultura (Figura 3.3 - Meses de Referência). O primeiro modelo fornece no mês de outubro uma estimativa de produtividade para o arroz e para a soja e, é constituído de indicadores climáticos até o mês de setembro. O segundo modelo, com a previsão fornecida em novembro, inclui índices até o mês de outubro e assim, sucessivamente, até o modelo do mês de março que apresenta uma estimativa já na fase final de desenvolvimento das culturas e engloba indicadores até o mês de fevereiro.

3.3.0.1 Seleção dos Preditores

Para a elaboração do modelo estatístico de previsão de produtividade agrícola, foram aplicados alguns filtros, de forma a reter apenas indicadores climáticos com influência sobre cada grupo e cultura em virtude dos inúmeros índices e defasagens de correlações analisadas. Como filtro inicial, usou-se o nível de confiança de 95%. No caso de um mesmo indicador climático apresentar correlação significativa para diferentes meses, apenas o mês com maior correlação foi selecionado.

Além dos indicadores climáticos conhecidos na literatura e listados na Seção 3.2, índices baseados em anomalias de Temperatura da Superfície do Mar foram utilizados na elaboração do modelo para elevar a confiabilidade do mesmo (Seção 3.2.3).

Potenciais regiões oceânicas preditoras foram selecionadas com base em regiões oceânicas que apresentassem um ponto central de máxima correlação e um nível de confiança estatística de 99%. Em torno deste ponto central, o segundo critério utilizado foi de uma área com correlação a um nível de confiança de 95%. Esta área, para a soja, corresponde a -2° a 2° de latitude e -5° a 5° de longitude em torno do ponto central. Enquanto para o arroz, esse limite vai de -4° a 4° de latitude e -7° a 7° de longitude em virtude deste apresentar correlações mais elevadas com os padrões de TSM. Os limites acima mencionados foram definidos por meio de testes buscando um número de índices que fornecesse uma previsão com destreza satisfatória para o mês de outubro.

Com as áreas de TSM selecionadas por meio do critério estabelecido, foram criados novos índices baseados na climatologia mencionada na Seção 3.2 e na Equação 3.4. Por definição, a partir deste momento, os índices criados com base na climatologia de TSM passarão a ser nomeados da seguinte forma: ATSM/MES/LAT/LON sendo MES o mês de referência da anomalia e LAT/LON a latitude e a longitude do ponto central deste índice.

Com o intuito de evitar a sobreposição de áreas referentes ao ENOS ($10^{\circ}\text{S}/10^{\circ}\text{N}-160^{\circ}\text{E}/90^{\circ}\text{W}$) e às regiões do Atlântico citadas pelos estudos de Santos e Diniz (2014) (ATSM1 - $20^{\circ}\text{S}/30^{\circ}\text{S}-20^{\circ}\text{W}/40^{\circ}\text{W}$) e Cataldi et al. (2010) (ATSM2 - $33^{\circ}\text{S}/43^{\circ}\text{S}-48^{\circ}\text{W}/63^{\circ}\text{W}$) as suas respectivas regiões oceânicas não foram incluídas na criação destes novos índices.

Na elaboração do modelo específico de cada mês de referência, foram selecionados os nove índices com maior correlação com a produtividade média de cada grupo homogêneo e de cada cultura analisada (Figura 3.3 - 1). Estes nove índices foram inseridos um a um no modelo de regressão linear resultando assim em nove combinações diferentes para cada mês e cada cultura.

3.3.0.2 Regressão de Componentes Principais

Uma das maiores dificuldades no emprego da regressão linear múltipla é o problema da multicolinearidade. A multicolinearidade é frequentemente, mas não sempre, indicada por elevada correlação entre as variáveis preditoras (JOLLIFFE, 2004). Sabe-se que muitos padrões de larga escala são correlacionados e que determinado padrão pode carregar o sinal de outros. Por esta razão, a regressão linear múltipla pode não fornecer uma relação estável quando mais de um preditor é incluído no modelo (MARTINEZ; BAIGORRIA; JONES, 2009; CAI et al., 2013). Para atenuar tal situação, foi utilizada a Regressão de Componentes Principais (PCR) (Figura 3.3 - 2) por meio do software Climate Predictability Tool (CPT) do IRI de forma semelhante ao proposto por Martinez, Baigorria e Jones (2009) para a cultura do milho nos Estados Unidos. A técnica baseia-se no uso de Componentes Principais (CPs) no lugar das variáveis preditoras e, dado que os modos retidos das componentes principais são não correlacionados, elimina-se a multicolinearidade e os cálculos de regressão são simplificados (JOLLIFFE, 2004).

Dado o modelo de regressão padrão, definido por:

$$y = X\beta + \epsilon \quad (3.5)$$

sendo y um vetor de n observações sobre a variável dependente, X a Matriz ($n \times p$) cujo elemento $(i, j)_{simo}$ é o valor da j^{th} variável preditora para a i_{simo} observação, β é um vetor de coeficientes de regressão e ϵ é um vetor dos erros. Assume-se que as variáveis preditoras foram padronizadas, de modo que $X'X$ é proporcional à matriz de correlação para as variáveis preditoras.

Os valores das CPs para cada observação são dados por:

$$Z = XA \quad (3.6)$$

sendo que o $(i, k)_{simo}$ elemento de Z é o valor (score) da k_{simo} CP da observação i_{simo} , e A é uma matriz ($P \times P$) cuja k_{simo} coluna é o k_{simo} autovetor de $X'X$.

Dada a ortogonalidade de A , $X\beta$ pode ser reescrito como $XAA'\beta = Z\gamma$, sendo $\gamma = A'\beta$. A Equação 3.5 pode então ser escrita como:

$$y = Z\gamma + \epsilon \quad (3.7)$$

que simplesmente substituiu as variáveis preditoras por suas CPs no modelo de regressão. A Regressão de Componente Principal pode ser definida por meio da Equação 3.7 ou de:

$$y = Z_m\gamma_m + \epsilon_m \quad (3.8)$$

sendo γ_m um vetor de m elementos que são um subconjunto de elementos de γ ,

Z_m uma matriz (nm) cujas colunas são o subconjunto correspondente de colunas de Z e m é o termo de erro apropriado.

Em cada mês de referência os índices selecionados foram ordenados da maior para a menor correlação. Sucessivas Regressões de Componentes Principais foram realizadas com as combinações dos índices previamente selecionados (9 combinações para cada mês de referência e cultura). Para a definição dos índices e das suas respectivas Componentes Principais a serem incluídas no modelo, foi utilizado o método de validação cruzada.

A validação cruzada permite testar a confiabilidade do modelo no mesmo conjunto de dados utilizado para construí-lo, sendo frequentemente utilizada para validar um modelo quando existem poucos dados observados (CARDOSO, 2005). O método baseia-se na remoção de uma janela de dados preditores e de observações associados. A série restante é então utilizada para a previsão do dado removido (BARNETT; PREISENDOFER, 1987).

Neste estudo, foi utilizada uma janela de três anos de forma semelhante a utilizada em Martinez, Baigorria e Jones (2009). Assim sendo, uma janela de três anos consecutivos é deixada fora da regressão e o ano médio desta janela é previsto. Esta iteração é repetida até que toda série tenha sido utilizada na validação e seja obtido um perfil histórico de dados previstos. O número ideal de modos é identificado baseado nas correlações entre a série observada e prevista. Para contemplar uma série completa, a validação cruzada da soja foi realizada (período de treinamento) entre 1984 a 2013, enquanto a do arroz foi estimada entre 1990 e 2013.

A inclusão de muitos preditores pode acarretar em um super ajuste da regressão das componentes principais. Para verificar tal possibilidade, foi utilizado o coeficiente de determinação ajustado (R_a^2) que é definido como:

$$R_a^2 = 1 - (1 - R^2) \frac{(n - 1)}{n - k} \quad (3.9)$$

sendo n o tamanho da amostra, k o número de variáveis independentes da regressão e R^2 o coeficiente de determinação definido como (WILKS, 2006):

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad (3.10)$$

sendo que SSR é a variação representada pela regressão; SST é a variação do preditando e SSE é a variação dos resíduos.

Para uma regressão perfeita, $SST = SST$ e $SSE = 0$, o que leva a $R = 1$. Para uma regressão sem valor, $SST = 0$ e $SSE = SST$, então $R = 0$.

Por ser utilizado apenas como uma variável de controle do super ajuste da regressão, valores relacionados ao (R_a^2) não serão apresentados nas discussões dos resultados.

3.3.0.3 Validação do Modelo

A destreza da regressão gerada pela validação cruzada foi avaliada com base nos seguintes métodos: Coeficiente de Correlação (Corr), Erro Médio (VIES ou BIAS), Raiz do Erro Médio Quadrático (RMSE) e Taxa de Acerto (Hit Score) (Figura 3.3 - 3).

O Coeficiente de Correlação linear (CC) fornece uma medida abreviada e de valor único da associação entre duas variáveis. O CC varia entre -1 e 1 onde $CC_{XY} = -1$ representa uma associação linear perfeita e negativa entre X e Y e, da mesma forma, $CC_{XY} = 1$ representa uma relação linear perfeita e positiva. O CC pode ser definido como (WILKS, 2006):

$$CC_{XY} = \frac{cov_{X,Y}}{\sigma_X \sigma_Y} \quad (3.11)$$

sendo que $cov_{X,Y}$ é a covariância entre X e Y ; σ_X o desvio padrão de X e σ_Y o desvio padrão de Y .

O Erro Médio quantifica o erro sistemático do modelo e é definido pela Equação 3.12. Valores positivos (negativos) indicam que, em média, o modelo tende a superestimar (subestimar) os valores observados (CARDOSO, 2005).

$$VIES = \frac{1}{n} \sum_{i=1}^n (y_p - y_o) \quad (3.12)$$

sendo n o número de observações; y_p o valor previsto e y_o o valor observado.

A Raiz do Erro Quadrático Médio fornece informações sobre o erro médio do modelo sem levar em conta o sinal do mesmo (CARDOSO, 2005). Este erro é definido por:

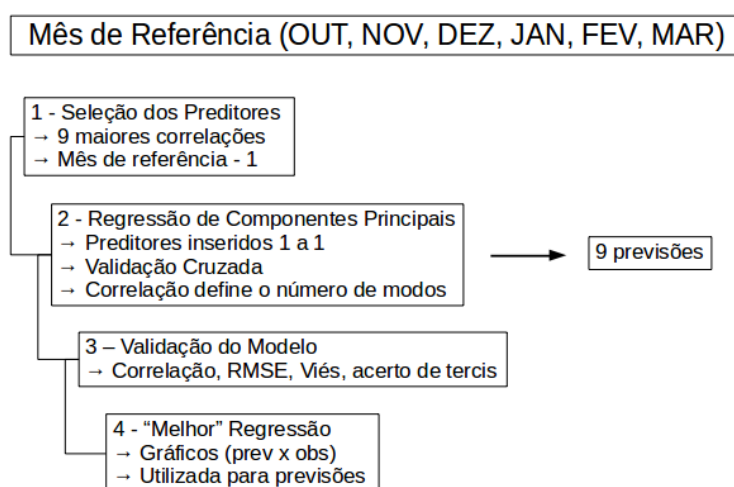
$$REM_Q = \sqrt{\left(\frac{1}{n} \sum_{i=1}^n (y_p - y_o)^2 \right)} \quad (3.13)$$

Por fim, a previsão realizada por meio do CPT fornece uma estimativa do valor previsto bem como as probabilidades de previsão para as três categorias (acima, abaixo e normal). As probabilidades são derivadas do erro da previsão do modelo com base no nível de confiança estabelecido. As previsões realizadas neste estudo utilizaram o nível de confiança padrão do software: 68,3%. A taxa de acerto de tercis é a fração percentual média de acerto de previsões nos tercis superiores, inferiores e médios. O uso de previsões categóricas por tercis fornecem previsões de produtividade acima, abaixo ou na média e são de importância fundamental para a tomada de decisões (MARTINEZ; BAIGORRIA; JONES, 2009).

Adicionalmente as informações acima listadas, há a previsão dos intervalos superiores e inferiores como alternativa a previsão de probabilidades e, também, como indicativo da incerteza da previsão, porém esta aplicação não foi utilizada neste estudo.

No total, foram realizadas 9 Regressões de Componentes Principais para cada mês de referência/defasagem (6 meses) de cada grupo homogêneo (3 grupos) e cada cultura (2), totalizando então 324 simulações diferentes. Na discussão dos resultados apenas os modelos com maior destreza para cada cultura, grupo e mês de referência serão apresentados (Figura 3.3 - 4). Além disso, estes modelos selecionados foram utilizados para realizar previsões experimentais simulando as safras de arroz (2015/2016 e 2016/2017) e soja () para avaliar sua capacidade de previsão fora da série utilizada para sua calibração.

Figura 3.3 – Fluxograma utilizado para a elaboração do modelo estatístico de previsão de produtividade.



Fonte: Próprio autor.

3.3.0.4 Previsões de Safra

Com o intuito de avaliar a aplicabilidade dos modelos desenvolvidos, foram elaboradas previsões de produtividade de soja para as safras 2013/2014 e 2014/2015 e para o arroz para as safras de 2015/2016 e 2016/2017 com base na regressão estabelecida e nos índices selecionados.

Para realizar a comparação entre a previsão e dados observados de soja, foram utilizados dados provenientes da Empresa de Assistência Técnica e Extensão Rural (EMATER). Por simplificação e baseando-se na Tabela L.1, adotou-se os municípios de Tupanciretã, São Gabriel e São Borja como referências dos Grupos 1, 2 e 3, respectivamente. Estes municípios foram selecionados por serem os maiores produtores de cada grupo homogêneo.

Para o arroz, utilizaram-se dados do IRGA. Por simplificação e com base no agrupamento demonstrado na Figura 4.25, assumiu-se que o Grupo 1 é formado pela Depressão

Central, Planície Costeira Interna e Externa, a Zona Sul constitui o Grupo 2 e a Fronteira Oeste e a Campanha constituem o Grupo 3.

Os dados de produtividade acima listados tiveram sua tendência tecnológica (tendência linear) removida com base na Equação 3.1 para possibilitar a comparação com as estimativas realizadas pelos modelos de regressão

4 RESULTADOS E DISCUSSÃO

4.1 SOJA

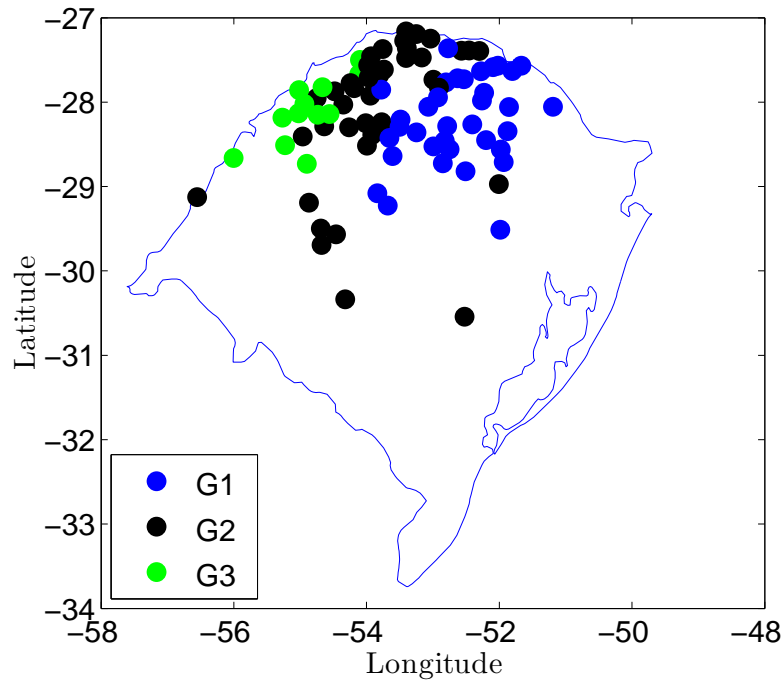
4.1.1 Regiões Homogêneas

A distribuição dos municípios deste estudo em grupos homogêneos de produtividade de soja resultante da análise de agrupamento pode ser visualizada na Figura 4.1. Na Tabela L.1 encontra-se a listagem dos municípios utilizados neste estudo e seu respectivo agrupamento. Municípios do Grupo 1 (G1) estão localizados, principalmente, no nordeste do Estado e apresentam uma produtividade média maior (Figura 4.2). Membros do Grupo 3 (G3), que apresentam a menor produtividade média (Figura 4.2), estão concentrados mais a noroeste do Estado e próximos a fronteira com a Argentina, enquanto municípios do Grupo 2 (G2), com produtividade intermediária (Figura 4.2), estão localizados entre os Grupos 1 e 3, situados próximos a região central do Estado. Um agrupamento semelhante, porém com uma base de dados menor (4 anos), foi encontrado por Melo, Fontana e Berlato (2004).

Quando comparados com o zoneamento agroclimático da soja no RS (Figura 2.2), o G1 está localizado em uma região onde a produtividade de soja é limitada pela baixa disponibilidade térmica o que, segundo Melo, Fontana e Berlato (2004), poderia ser superado pelo uso de cultivares precoces ou atraso na data de semeadura (início de novembro). Também na região onde predominam os municípios do G1, o estudo de Cunha et al. (2001) demonstrou ser menor o risco de queda de produtividade por conta do déficit hídrico. O G2 encontra-se na região preferencial para o plantio de soja e sua menor produtividade, em relação ao G1, poderia ser explicada pelo maior risco de deficiência hídrica em comparação com o G1 Cunha et al. (2001). Por outro lado, o G3 (baixo rendimento), apesar de estar localizado entre a área preferencial e tolerada, está localizado em uma região onde as perdas de rendimento estão relacionadas ao déficit hídrico e a irrigação seria recomendada para aumentar o rendimento (MELO; FONTANA; BERLATO, 2004).


Nos três grupos, a variabilidade ao longo dos anos é similar (Figura 4.2), o que sugere que fatores de larga escala podem interferir na variabilidade de soja no RS, fator que justifica a necessidade de estudos da influência de processos de teleconexão na produtividade agrícola do Estado.

Figura 4.1 – Mapa das regiões homogêneas de produtividade de soja no Rio Grande do Sul com a distribuição espacial dos grupos G1, G2 e G3 resultante da análise de agrupamento.



Fonte: Próprio autor.

Figura 4.2 – Perfis médios de produtividade de grãos de soja dos grupos: G1 (azul), G2 (preto) e G3 (verde). A área sombreada delimita o desvio padrão de cada uma das séries.



Fonte: Próprio autor.

4.1.2 Comparação Intraíndices

As Figuras 4.3, 4.4 e 4.5 fornecem um resumo da correlação entre produtividade e os índices climáticos. Como a produtividade de soja está intimamente ligada a precipitação acumulada entre os meses de janeiro e março (BERLATO; FONTANA, 1999), quando a cultura encontra-se na fase reprodutiva, pressupõe-se que os índices climáticos aqui apresentados exerçam uma influência direta na variabilidade da precipitação no RS e, conseqüentemente, estão relacionados indiretamente com a produtividade de soja.

Nas correlações baseadas nos indicadores climáticos para o mês de maio do ano anterior a colheita (Figura 4.3), o índice ATSM2 apresentou para o G2 os melhores resultados com correlação a um nível de confiança de 95%. Dada a lenta variação da Temperatura da Superfície do Mar e tendo em conta que a maior parte da soja no RS é semeada a partir de outubro, tal correlação para o G2 poderia servir como potencial indicativo da produtividade de soja na região central do Estado com considerável antecedência.

Para junho, nota-se a influência da AMM que apresenta uma correlação negativa a 95% de confiança com o Grupo 3. Em estudo sobre a variabilidade da vazão de rios no Brasil, Capozzoli, Cardoso e Ferraz (2017) demonstraram uma correlação negativa da AMM com a vazão, variável meteorológica ligada diretamente a precipitação, sobre a Bacia do Uruguai para defasagens temporais de até 4 meses com o índice precedendo a vazão. Da mesma forma que para a vazão, os resultados aqui encontrados evidenciam que anomalias positivas (negativas) de TSM no Atlântico tropical norte acompanhadas de anomalias negativas (positivas) de TSM no Atlântico tropical sul durante o mês de junho, indicariam uma potencial queda (elevação) da produtividade de soja no noroeste do RS.

Nos meses de julho e setembro, os indicadores climáticos utilizados no presente estudo não apresentaram correlação significativa com nenhum dos grupos homogêneos de produtividade de soja. Para agosto (Figura 4.4), padrões de teleconexão que possuem influência mais direta no clima do Hemisfério Norte apresentam sinal na produtividade de soja no RS. A relação destes índices do Hemisfério Norte com a produtividade agrícola no Hemisfério Sul pode sugerir influências inter-hemisféricas, mas merecem uma análise futura mais detalhada. A AO possui correlação positiva e significativa a 95% para os três grupos. O PNA também possui relação com a produtividade, porém, com sinal negativo (95% para os Grupos 1 e 2 e 99% para o Grupo 3).

A influência de padrões do Hemisfério Norte também é evidenciada entre outubro e dezembro e, destaca-se a persistência da correlação negativa entre os índices referentes à AO e NAO com a produtividade para os três grupos, sendo mais forte no mês de outubro para os dois índices. Como a maior parte da soja no RS é semeada entre outubro e novembro (FONTANA et al., 2001) e, por possuir uma persistência significativa da correlação nos meses subsequentes, os índices climáticos do mês de outubro referentes à AO e NAO se mostram como bons indicadores da produtividade de soja no RS.

Os índices climáticos a partir do mês de novembro perdem seu caráter prognóstico do ponto de vista de prevenções para eventuais quebras de safra, tendo em vista que a soja já foi semeada em todo o Estado e, por este motivo, correlações significativas a partir de novembro apresentam apenas uma visão mais diagnóstica de como a cultura da soja poderá se desenvolver nos meses seguintes.

Em novembro, a ODP apresenta correlação positiva a 95% com o G3. Sabe-se que na América do Sul a ODP intensifica (desintensifica) os efeitos do ENOS quando na mesma fase (fase oposta) (KAYANO; ANDREOLI, 1998). Embora as correlações referentes as anomalias de TSM relacionadas ao El Niño não apresentem significância estatística, de forma geral, o G3 apresenta os maiores valores, reforçando a importância do índice referente a ODP no mês de novembro para este grupo.

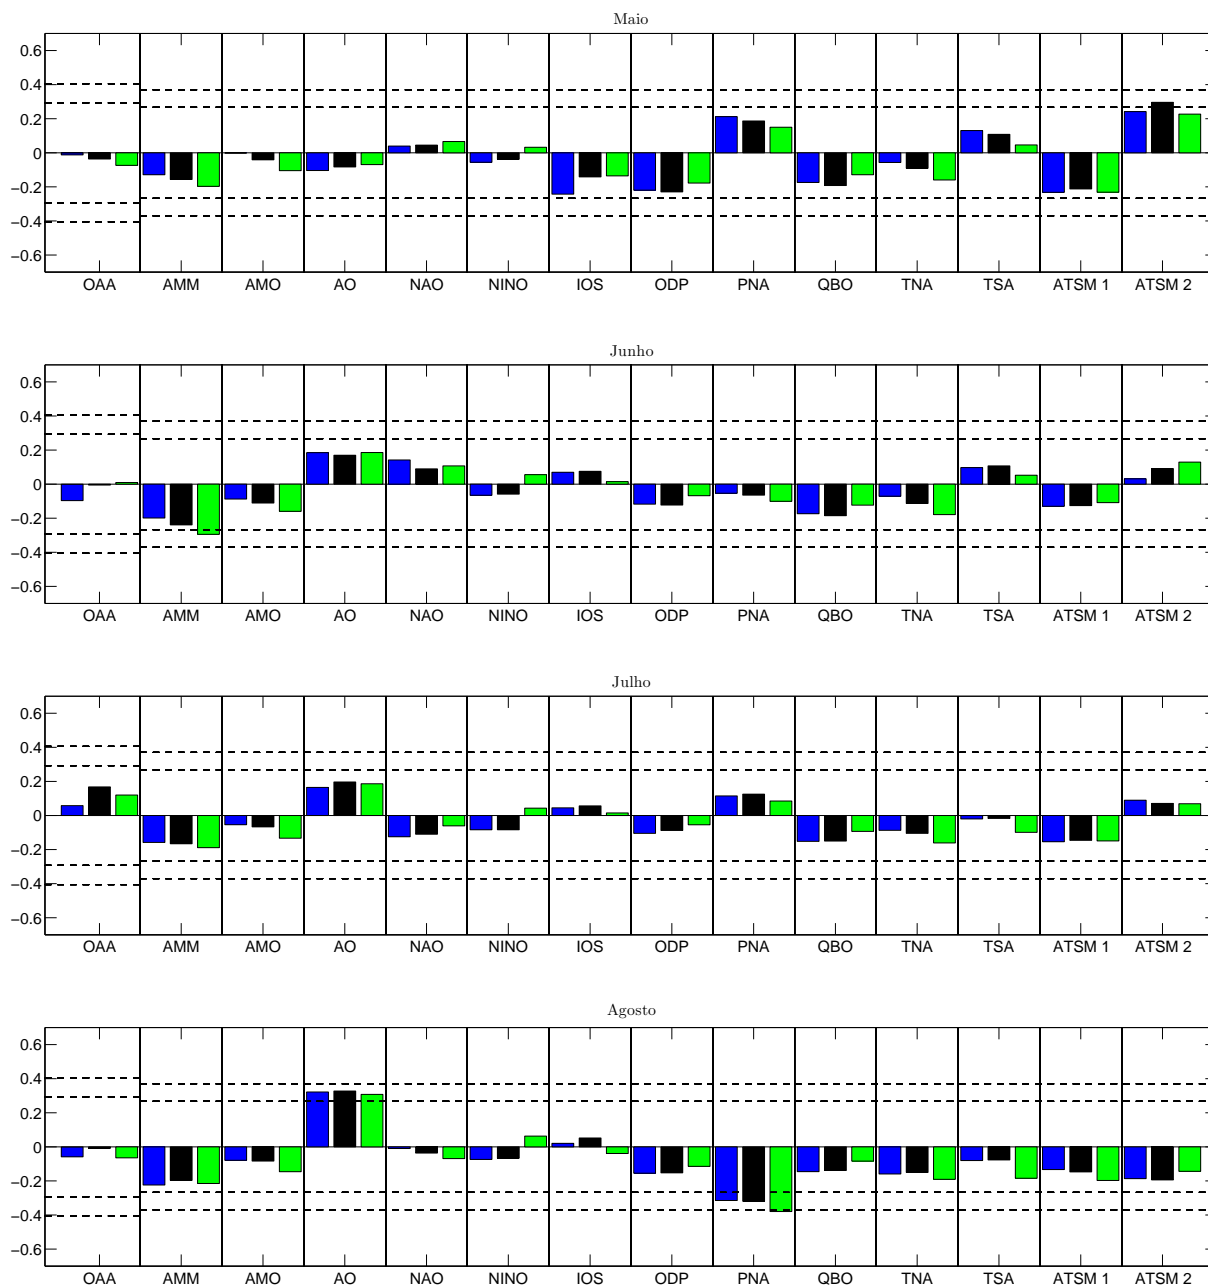
Em dezembro, além da AO e da NAO acima citadas, os índices relacionados a TSM da área ATSM1 passam a apresentar sinal significativo e positivo, pois anomalias positivas (negativas) de TSM nesta área estão relacionadas a aumento (diminuição) da precipitação de verão sobre o Estado gaúcho (SANTOS; DINIZ, 2014).

As correlações positivas relacionadas a ATSM1 persistem nos meses de janeiro, fevereiro e março (Figura 4.5) coincidindo com os meses em que a precipitação é fundamental no desenvolvimento da cultura da soja. No mês de janeiro ainda há uma correlação negativa com confiança estatística de 95% com a NAO e positiva a 95% tanto para o G2 quanto para o G3 com a PNA.

Destaca-se também a correlação negativa a 95% (G1 e G2) e 99% (G3) com a OAA no mês de janeiro. A OAA está intimamente ligada a atividade frontogenética em latitudes médias (CAVALCANTI; AMBRIZZI, 2009) e, em sua fase negativa (positiva), está associada a anomalias positivas (negativas) de precipitação sobre o RS (VASCONSELLOS, 2012). Nota-se também que o G3 apresenta a correlação mais elevada, fator que vai ao encontro de estudos prévios que demonstram que a correlação entre OAA e precipitação é mais elevada entre o noroeste do RS e norte da Argentina (SILVESTRI; VERA, 1994).

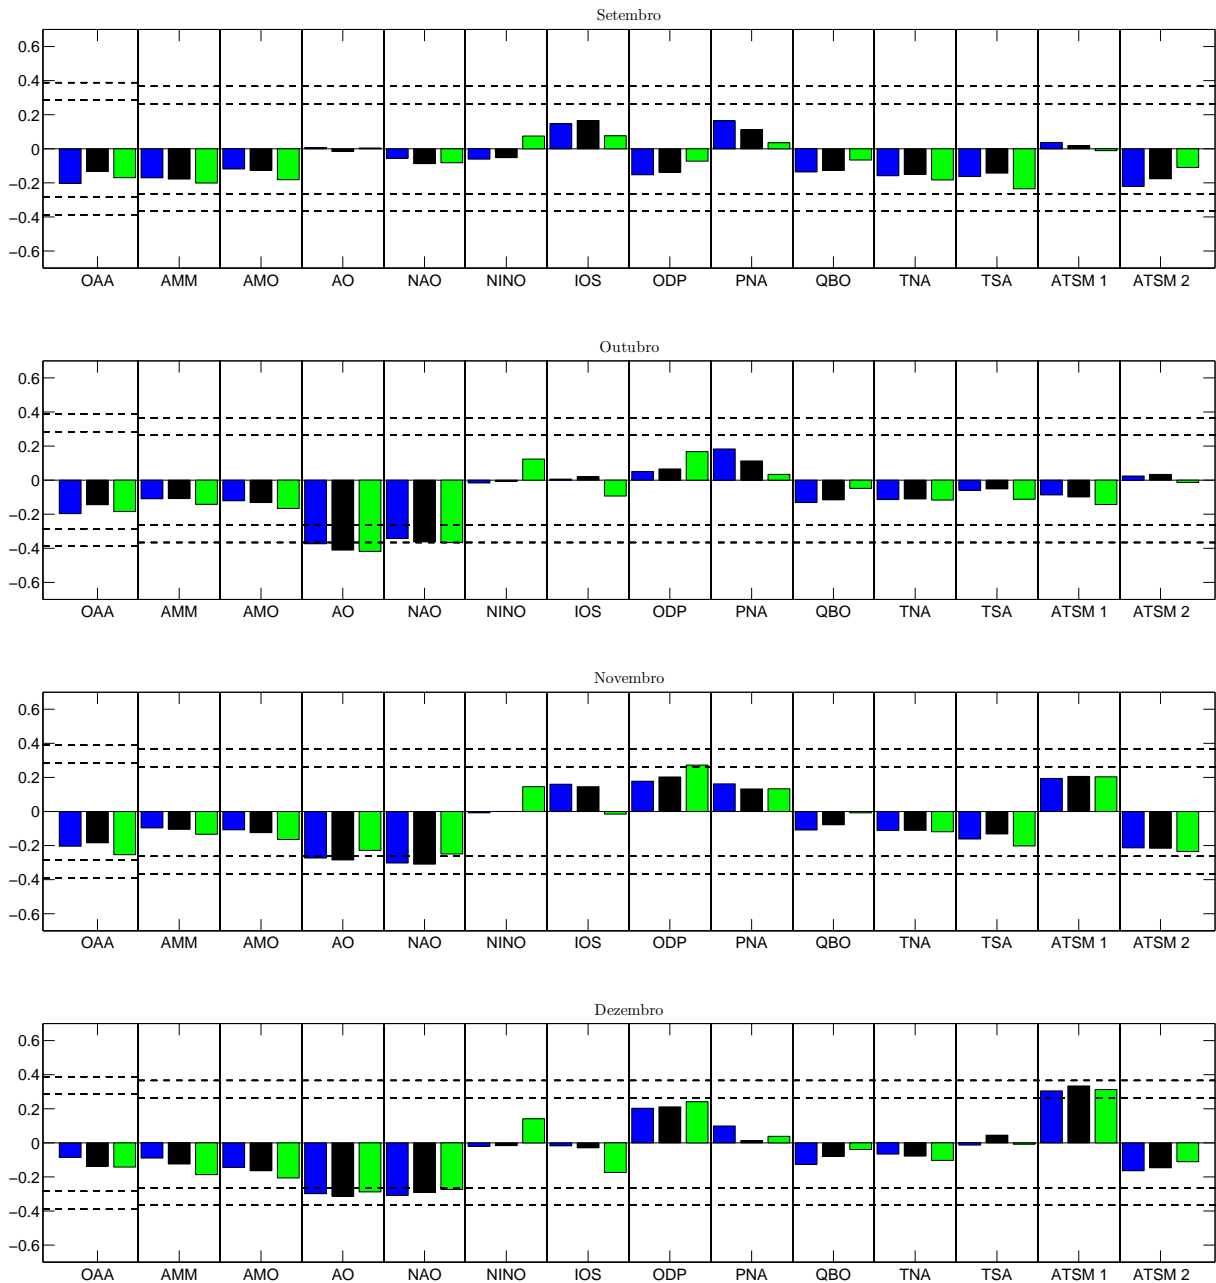
No mês de março, os índices referentes a ATSM2 apresentam correlação negativa a 95% com a produtividade de soja para o G3. Anomalias positivas de TSM na região da ATSM2 estão relacionadas a um período de diminuição da precipitação sobre parte do Sul do Brasil (CATALDI et al., 2010) e, por ser um mês onde a demanda por água vinda da precipitação ainda é alta pela cultura que está em enchimento de grãos, o G3 apresenta uma queda de rendimento nestas condições.

Figura 4.3 – Correlação entre os indicadores climáticos e a produtividade de soja entre maio e agosto para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.



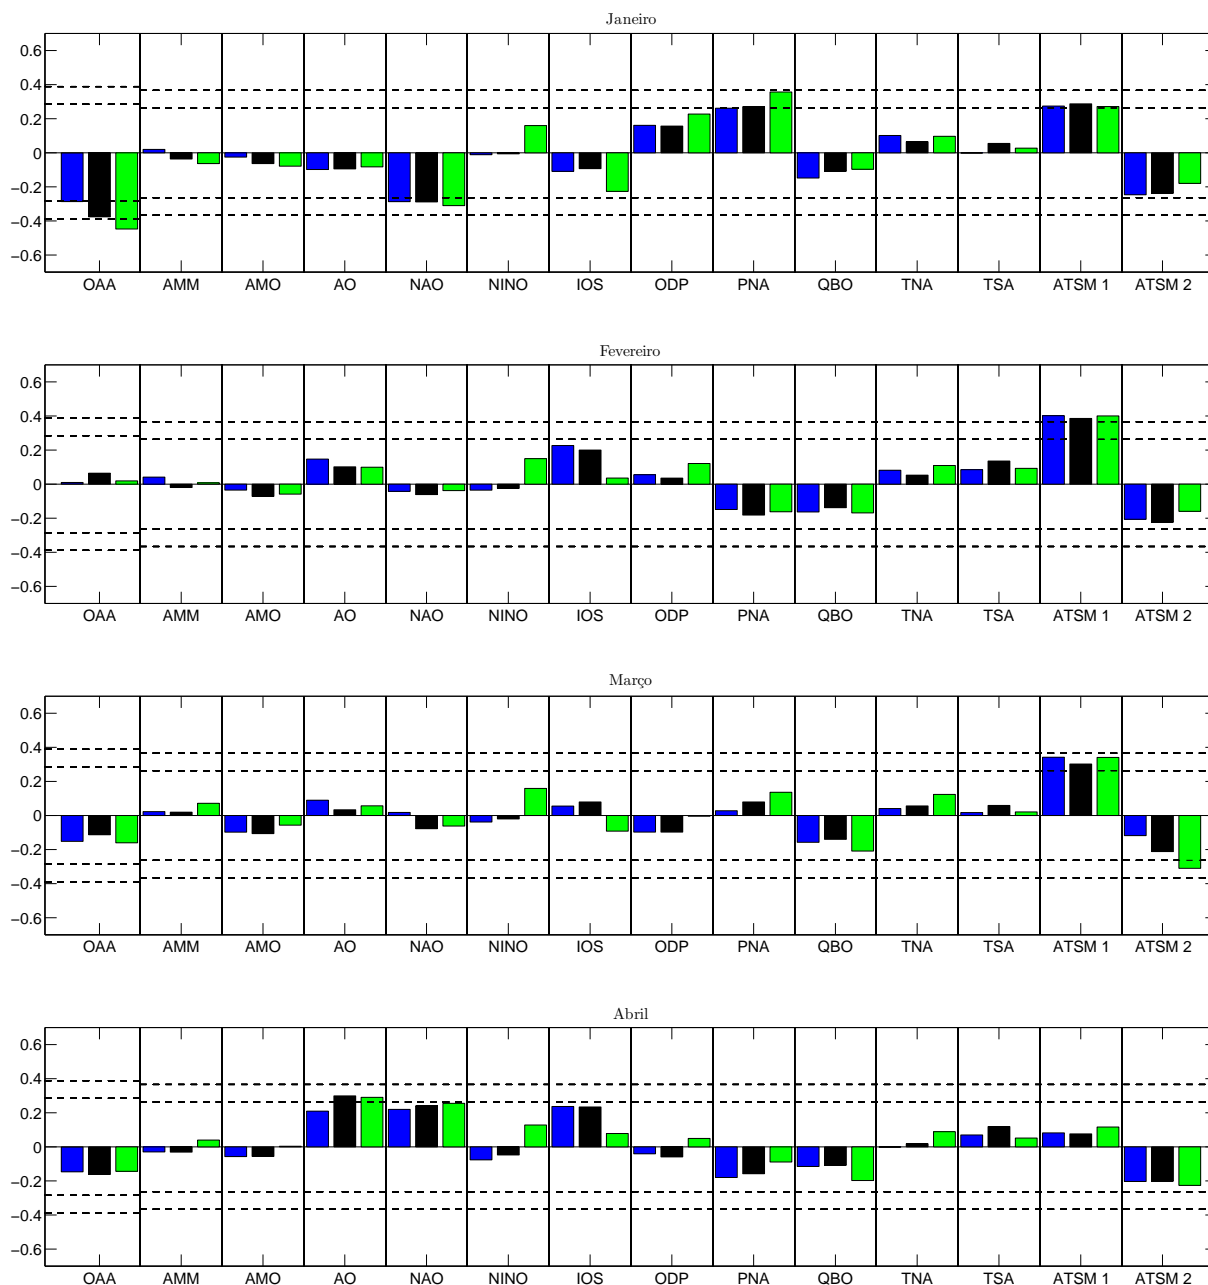
Fonte: Próprio autor.

Figura 4.4 – Correlação entre os indicadores climáticos e a produtividade de soja entre setembro e dezembro para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.



Fonte: Próprio autor.

Figura 4.5 – Correlação entre os indicadores climáticos e a produtividade de soja entre janeiro e abril para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.



Fonte: Próprio autor.

Por fim, no mês de abril, mês considerado como referência para colheita, nota-se uma correlação positiva (95%) da AO com os grupos 2 e 3. A AO apresenta correlações significativas e negativas entre os meses de outubro a janeiro e, à medida que se aproxima a época de colheita, há modificação em seu sinal e alcança sua máxima correlação positiva no mês de abril.

Na Tabela 4.1 constam os índices climáticos que apresentaram correlação com nível de confiança de, no mínimo, 95% com um dos grupos deste estudo. Embora o mecanismo físico responsável pela ligação de alguns destes índices com a produtividade ainda não seja compreendido, as correlações apresentadas justificam um olhar mais atento a variabilidade dos mesmos próximo à época de planejamento da safra de soja sobre o Rio Grande do Sul.

Tabela 4.1 – Principais resultados obtidos que evidenciam as correlações ao nível de confiança de 95% e o sinal destas correlações entre os índices climáticos mensais e a produtividade média de soja dos três grupos homogêneos.

	Grupo 1	Grupo 2	Grupo 3
	AO agosto (+)	ATSM2 maio (+)	AMM junho (-)
	PNA agosto (-)	AO agosto (+)	AO agosto (+)
	AO outubro (-)	PNA agosto (-)	PNA agosto (-)
	NAO outubro (-)	AO outubro (-)	AO outubro (-)
	AO novembro (-)	NAO outubro (-)	NAO outubro (-)
	NAO novembro (-)	AO novembro (-)	ODP novembro (+)
	AO dezembro (-)	NAO novembro (-)	AO dezembro (-)
	NAO dezembro (-)	AO dezembro (-)	NAO dezembro (-)
Índices	ATSM1 dezembro (+)	NAO dezembro (-)	ATSM1 dezembro (+)
	OAA janeiro (-)	ATSM1 dezembro (+)	OAA janeiro (-)
	NAO janeiro (-)	OAA janeiro (-)	NAO janeiro (-)
	ATSM1 janeiro (+)	NAO janeiro (-)	PNA janeiro (+)
	ATSM1 fevereiro (+)	PNA janeiro (+)	ATSM1 janeiro (+)
	ATSM1 março (+)	ATSM1 janeiro (+)	ATSM1 fevereiro (+)
		ATSM1 fevereiro (+)	ATSM1 março (+)
		ATSM1 março (+)	AO abril (+)
		AO abril (+)	

A compreensão dos padrões de teleconexão responsáveis pela variabilidade da produtividade de soja no RS é fundamental para um melhor planejamento da safra e também na mitigação de eventuais perdas de produtividade. Os resultados aqui apresentados indicam a importância de se levar em conta tais padrões no entendimento da variabilidade da produtividade de soja.

De uma forma geral, nota-se uma maior influência de padrões associados ao He-

misfério Norte para defasagens mais longas e do Hemisfério Sul para defasagens mais curtas. Desta forma, indicadores mais remotos apresentam-se como previsores potenciais da qualidade da safra de soja no RS enquanto padrões do Hemisfério Sul poderiam ser utilizados no acompanhamento do desenvolvimento da cultura.

Os indicadores relacionados a Oscilação Ártica (AO) e a Oscilação do Atlântico Norte (NAO) possuem sinal significativo para os três grupos homogêneos de produtividade de soja aqui apresentados. Além destes, as anomalias de Temperaturas de Superfície do Mar na área entre 20°S-30°S e 20°O-40°O (SANTOS; DINIZ, 2014) também apresentam significativa correlação, porém em um período no qual o plantio da soja, normalmente, já está finalizado no RS, caracterizando-se assim, como índice que poderia auxiliar em possíveis correções de estimativas da produtividade.

4.1.3 Influência do Fenômeno El Niño Oscilação Sul na Variabilidade Interanual da Produtividade de Soja no Rio Grande do Sul

Chama atenção nos resultados apresentados na Seção 4.1.2 a baixa correlação entre as componentes oceânica (NINO) e atmosférica (IOS) do fenômeno ENOS e a produtividade de soja. Tais resultados, a princípio conflitantes com estudos prévios que indicam grande influência deste padrão de teleconexão na variabilidade interanual da produtividade de soja no RS (BERLATO; FONTANA, 1999), levaram a uma análise mais aprofundada das baixas correlações apresentadas. Nesta análise, foram utilizadas as anomalias de TSM na região do Niño 3.4 para possibilitar a separação entre episódios de El Niño, La Niña e de neutralidade.

A primeira ressalva a ser feita é que o ENOS exerce maior influência sobre o regime de precipitação no RS durante a primavera (LOPES; DINIZ; MARQUES, 2007), período na qual a maior parte da soja ainda está sendo semeada (FONTANA et al., 2001). Outra característica importante a ser destacada é que ao analisarmos as correlações para um mesmo mês e para grupos diferentes, nota-se que, de uma forma geral, o G3 apresenta os valores mais significativos enquanto que o G1 é o que apresenta uma menor correlação. Estudos prévios que analisaram a influência da TSM do Pacífico na precipitação sobre a América do Sul demonstraram que, para o RS, a correlação, entre os meses de novembro e fevereiro, diminui em direção ao nordeste do Estado (DIAZ; STUDZINSKI; MECHOSO, 1997) justificando, assim, a diferença entre os grupos (Figura 4.1).

Sabe-se que as fases positivas e negativas do fenômeno ENOS possuem diferentes áreas de atuação. Por esse motivo, foi realizada uma análise de correlação, semelhante a apresentada na Seção 4.1.2, mas com a separação entre eventos de El Niño, La Niña e neutralidade e restrita aos períodos entre semeadura e colheita da soja. A Tabela 4.2 apresenta o total de eventos de El Niño, La Niña e neutralidade durante o período de

estudo e, de uma forma geral, nota-se o predomínio de eventos de neutralidade com uma distribuição mais igualitária do número de eventos entre os meses de outubro e janeiro.

Tabela 4.2 – Quantidade de ocorrência das fases positiva, negativa e de neutralidade com relação ao fenômeno El Niño durante os meses de estudo.

	El Niño	La Niña	Neutralidade
SET	10	10	19
OUT	12	12	15
NOV	12	12	15
DEZ	12	12	15
JAN	12	12	15
FEV	10	12	17
MAR	7	10	22
ABR	6	8	25

Em situações de El Niño (Tabela 4.3), anomalias positivas na TSM na região do Niño 3.4 estão associados com aumento de produtividade nos três grupos de estudo. Também pode ser notado que há uma elevação na correlação positiva a partir de novembro. Padrão semelhante entre anomalias positivas de TSM e maior produtividade de soja no RS foi observado em estudos prévios (BERLATO; FONTANA, 1999).

Tabela 4.3 – Correlação e nível de confiança da correlação entre a produtividade média dos três grupos homogêneos e anomalias de TSM na região do Niño 3.4 para eventos de El Niño. *NS: correlação não significativa.

Grupo	G1		G2		G3		
	Mês	Corr.	Conf. (%)	Corr.	Conf. (%)	Corr.	Conf. (%)
SET	-0,06		NS	-0,10	55	-0,12	60
OUT	0,12		80	0,08	55	0,10	60
NOV	0,27		80	0,22	75	0,27	80
DEZ	0,29		80	0,26	80	0,32	80
JAN	0,29		80	0,27	80	0,34	80
FEV	0,25		75	0,24	75	0,34	80
MAR	0,48		80	0,42	80	0,42	80
ABR	0,42		80	0,36	80	0,39	80

Em situações de neutralidade (Tabela 4.4), na maior parte do período de estudo, há uma significativa correlação negativa, especialmente no período entre novembro e fevereiro. Tal característica pode ser interpretada como uma evidência que, nestas situações, um decréscimo nas anomalias de TSM poderia levar a um aumento na produtividade uma vez que o ENOS poderia exercer menos influência e outros padrões de teleconexão prevaleceriam. Estes resultados são reforçados pelo baixo nível de confiança nas correlações entre anomalias de TSM e produtividade de soja durante episódios de La Niña (Tabela 4.5). Estudos prévios demonstraram que episódios de La Niña estão associados a anomalias negativas de precipitação sobre o RS durante o verão, mas esta influência é mais

restrita a metade sul do Estado (GRIMM; FERRAZ; GOMES, 1998), região esta que não está inserida neste estudo por ser responsável por menos de 6% da produtividade estadual de soja.

Tabela 4.4 – Correlação e nível de confiança da correlação entre a produtividade média dos três grupos homogêneos e anomalias de TSM na região do Niño 3.4 para situações de neutralidade. *NS: correlação não significativa.

Grupo	G1		G2		G3	
	Mês	Corr.	Conf. (%)	Corr.	Conf. (%)	Corr.
SET	-0,02	NS	0,04	55	0,06	55
OUT	-0,11	60	-0,02	NS	-0,02	NS
NOV	-0,33	80	-0,22	75	-0,15	70
DEZ	-0,44	95	-0,36	90	-0,23	80
JAN	-0,44	95	-0,36	90	-0,20	75
FEV	-0,22	80	-0,21	75	-0,09	60
MAR	0,04	55	0,03	55	0,09	60
ABR	0,01	NS	0,06	60	0,06	60

Tabela 4.5 – Correlação e nível de confiança da correlação entre a produtividade média dos três grupos homogêneos e anomalias de TSM na região do Niño 3.4 para eventos de La Niña. *NS: correlação não significativa.

Grupo	G1		G2		G3	
	Mês	Corr.	Conf. (%)	Corr.	Conf. (%)	Corr.
SET	-0,32	80	-0,42	80	-0,27	75
OUT	-0,15	60	-0,18	70	-0,02	NS
NOV	-0,12	60	-0,13	60	-0,05	55
DEZ	-0,15	60	-0,17	70	0,02	NS
JAN	-0,07	55	-0,11	55	0,10	60
FEV	-0,04	55	-0,08	55	0,16	60
MAR	0,04	NS	-0,01	NS	0,26	80
ABR	0,61	95	0,67	97,5	0,79	99,5

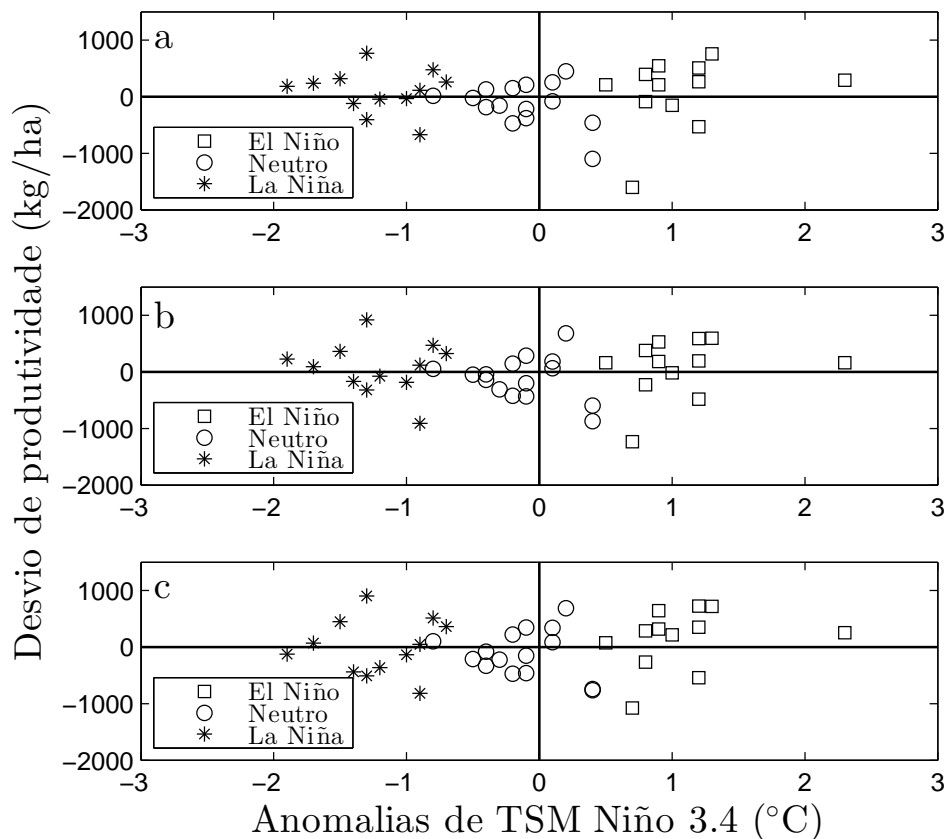
Outra forma de se visualizar a relação entre a TSM no Pacífico Equatorial e a produtividade de soja é através de um gráfico de dispersão entre as anomalias. A Figura 4.6 representa os desvios em relação a produtividade média de cada grupo e as anomalias de TSM na região do Niño 3.4 para novembro. Uma análise gráfica como a apresentada fornece a vantagem da observação da magnitude das anomalias de TSM e de produtividade e o mês de novembro foi escolhido por ser o primeiro mês com correlações significativas para os três grupos.

Concordando com estudos prévios (BERLATO; FONTANA, 1999, 2003), anos de El Niño favorecem aumento na produtividade de soja no RS na maior parte dos casos (67% dos casos para os Grupos 1 e 2 e 75% dos casos para o G3), fator que indica que nestes anos os agricultores podem aumentar os investimentos na cultura de soja no Estado com

maior probabilidade de retorno econômico.

Por outro lado, para anos de neutralidade e La Niña, tal influência não é tão evidente. Durante anos neutros em relação ao fenômeno ENOS, em 60% dos casos foi observada produtividade abaixo da média, sendo que os maiores desvios negativos em casos de neutralidade foram observados com anomalias positivas de TSM. Para eventos de La Niña, o Grupo 3 apresentou queda de produtividade em 6 anos (50% dos casos) enquanto para os Grupos 1 e 2, a maior parte dos casos de LN (58%) esteve associada a desvio positivo de produtividade. Nota-se também que em dois anos sob influência de La Niña foram observadas anomalias positivas de produtividade de mesma magnitude as observadas em alguns eventos de El Niño, fator que ajuda a explicar as baixas correlações encontradas para a fase fria do evento. Em estudo focado na região central do Estado, um resultado semelhante foi observado, sugerindo que anos de neutralidade são os que mais provavelmente resultarão em queda de produtividade devido ao déficit hídrico (ALBERTO et al., 2006).

Figura 4.6 – Relação entre anomalias de TSM na região do Niño 3.4 em novembro e anomalias de produtividade para o grupo: a) G1, b) G2 e c) G3. No gráfico, quadrados representam eventos de El Niño, círculos de neutralidade e asteriscos de La Niña.



Em um estudo global a respeito dos efeitos do ENOS na agricultura, episódios de El Niño foram associados a um aumento na produtividade média global de 2,9 a 3,5%, enquanto episódios de La Niña foram associados a uma redução de 1% (LIZUMI et al., 2014). Apesar do caráter em escala global, os resultados encontrados por Lizumi et al. (2014) são semelhantes aos aqui apresentados para a região sul do Brasil com um forte sinal positivo durante eventos de El Niño e sinal menos expressivo durante eventos de La Niña.

A baixa correlação entre a produtividade média de soja nos três grupos com as anomalias de TSM na região de influência do ENOS durante eventos de LN e neutralidade indica a necessidade da inclusão de outros padrões de teleconexão em épocas de planejamento de safra de forma a fornecer estimativas mais confiáveis. Os resultados aqui apresentados reforçam os estudos de Berlato e Fontana (1999) e Berlato e Fontana (2003) para a fase quente do ENOS, mas destacam uma menor influência em relação as fases neutras e fria do fenômeno, fator ainda não retratado na bibliografia.

4.1.4 Influência das Anomalias de TSM na Variabilidade Interanual da Produtividade de Soja no Rio Grande do Sul

As Figura 4.7 a 4.18 apresentam as correlações entre as anomalias de Temperatura da Superfície do Mar no Oceano Global com a produtividade de soja para os três grupos homogêneos. Os padrões de maior correlação e sua influência na soja serão discutidos posteriormente a medida que forem sendo utilizados na elaboração do modelo estatístico e nesta seção será apenas apresentada uma análise mais geral.

No mês de abril (Figura 4.7), destacam-se regiões de correlação negativa com a produtividade de soja para os três grupos em latitudes ao sul de 35°S. Nota-se também uma região com correlações positivas com os três grupos homogêneos próxima ao círculo polar Antártico. Também destaca-se uma região com correlação negativa com a produtividade no Oceano Atlântico Norte.

Entre os meses de maio (Figura 4.8) e agosto (Figura 4.11) os padrões de correlação diminuem destacando-se apenas uma pequena área de correlações positivas entre as anomalias de TSM e a produtividade para os três grupos ao sul da Austrália nos meses de julho e agosto.

A partir do mês de setembro 4.12, as anomalias de TSM no Oceano Índico começam a se destacar com uma correlação negativa com a produtividade. Nota-se também, que as anomalias de TSM no Oceano Atlântico Tropical começam a exercer maior influência sobre a produtividade de soja nos três grupos (correlação negativa). A faixa do Oceano Atlântico Tropical onde são notadas correlações negativas é muito próxima de onde são calculados os índices referentes a TNA e TSA. Ao analisarmos a Figura 4.4, nota-se que

no mês de setembro ambos os índices apresentaram correlação negativa com a produtividade.

No meses de outubro 4.13 e novembro 4.14, nota-se a influência do Pacífico Norte que apresenta correlações negativas com a produtividade dos três grupos. Também em novembro 4.14, destaca-se o Pacífico Sul, latitudes entre 30°S e 60°S com ampla área de correlação positiva com a produtividade de soja.

Em dezembro 4.15 e janeiro 4.16, as áreas de TSM que apresentam correlação elevada com a produtividade são semelhantes com ênfase nas áreas do Oceano Pacífico Norte e Sul.

Em fevereiro 4.17 e março 4.18, as anomalias de TSM no Oceano Atlântico sul passam a exercer influências em áreas próximas as regiões em que foram calculados os índices ATSM1 (correlação positiva) e ATSM2 (correlação negativa).

Figura 4.7 – Correlação entre anomalia da temperatura da superfície do mar no mês de abril e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

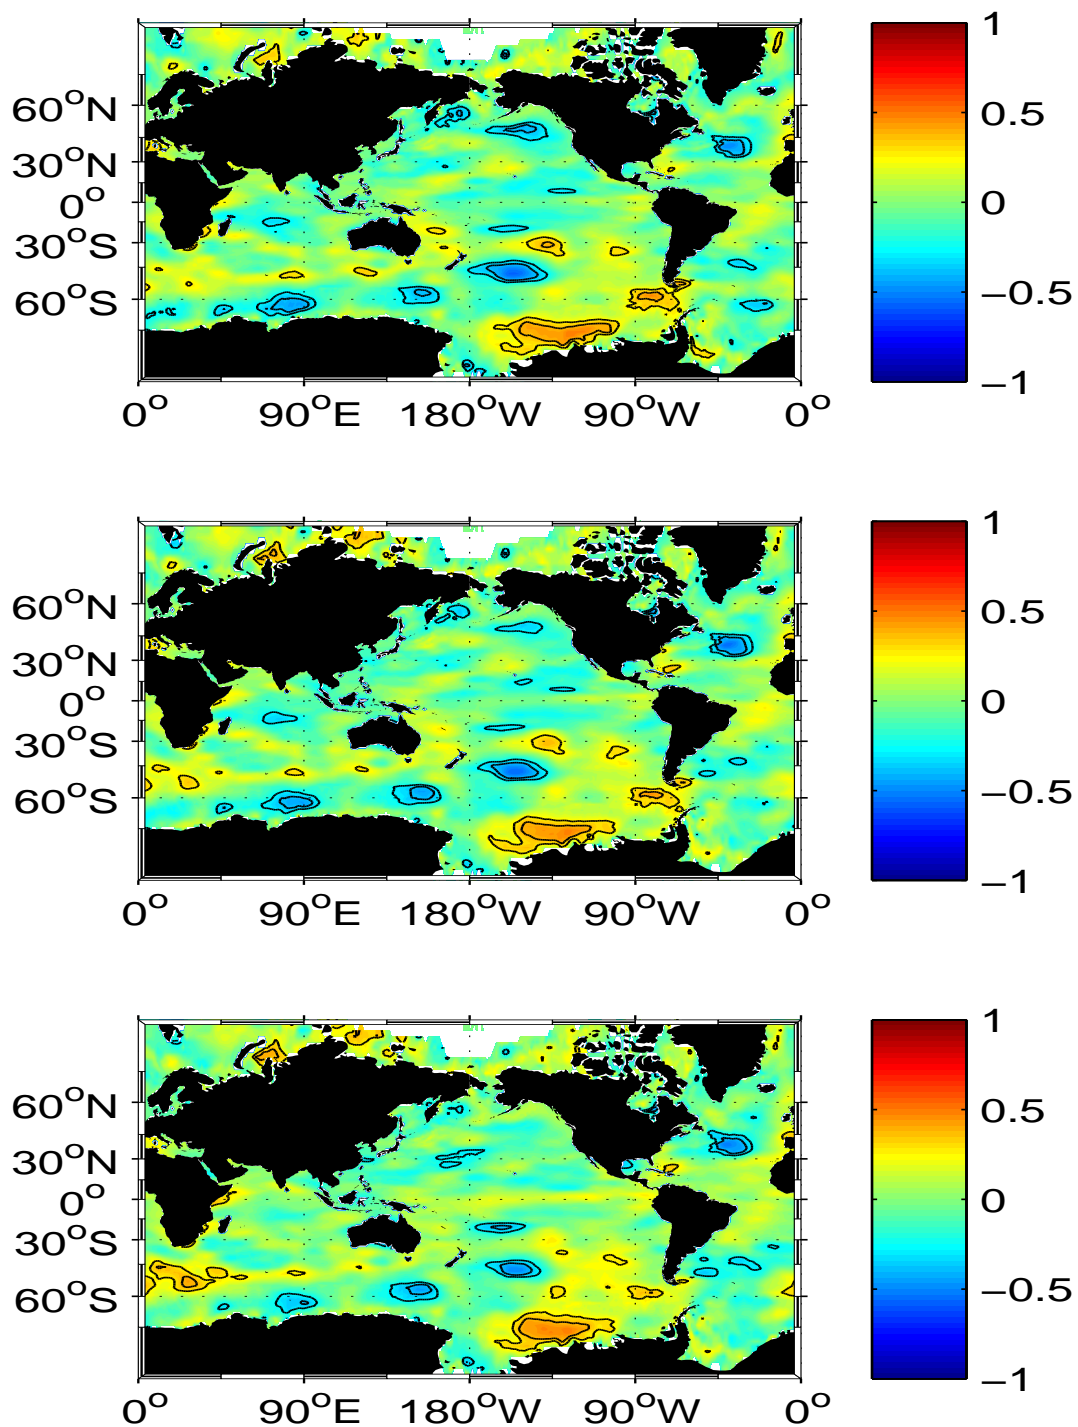


Figura 4.8 – Correlação entre anomalia da temperatura da superfície do mar no mês de maio e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

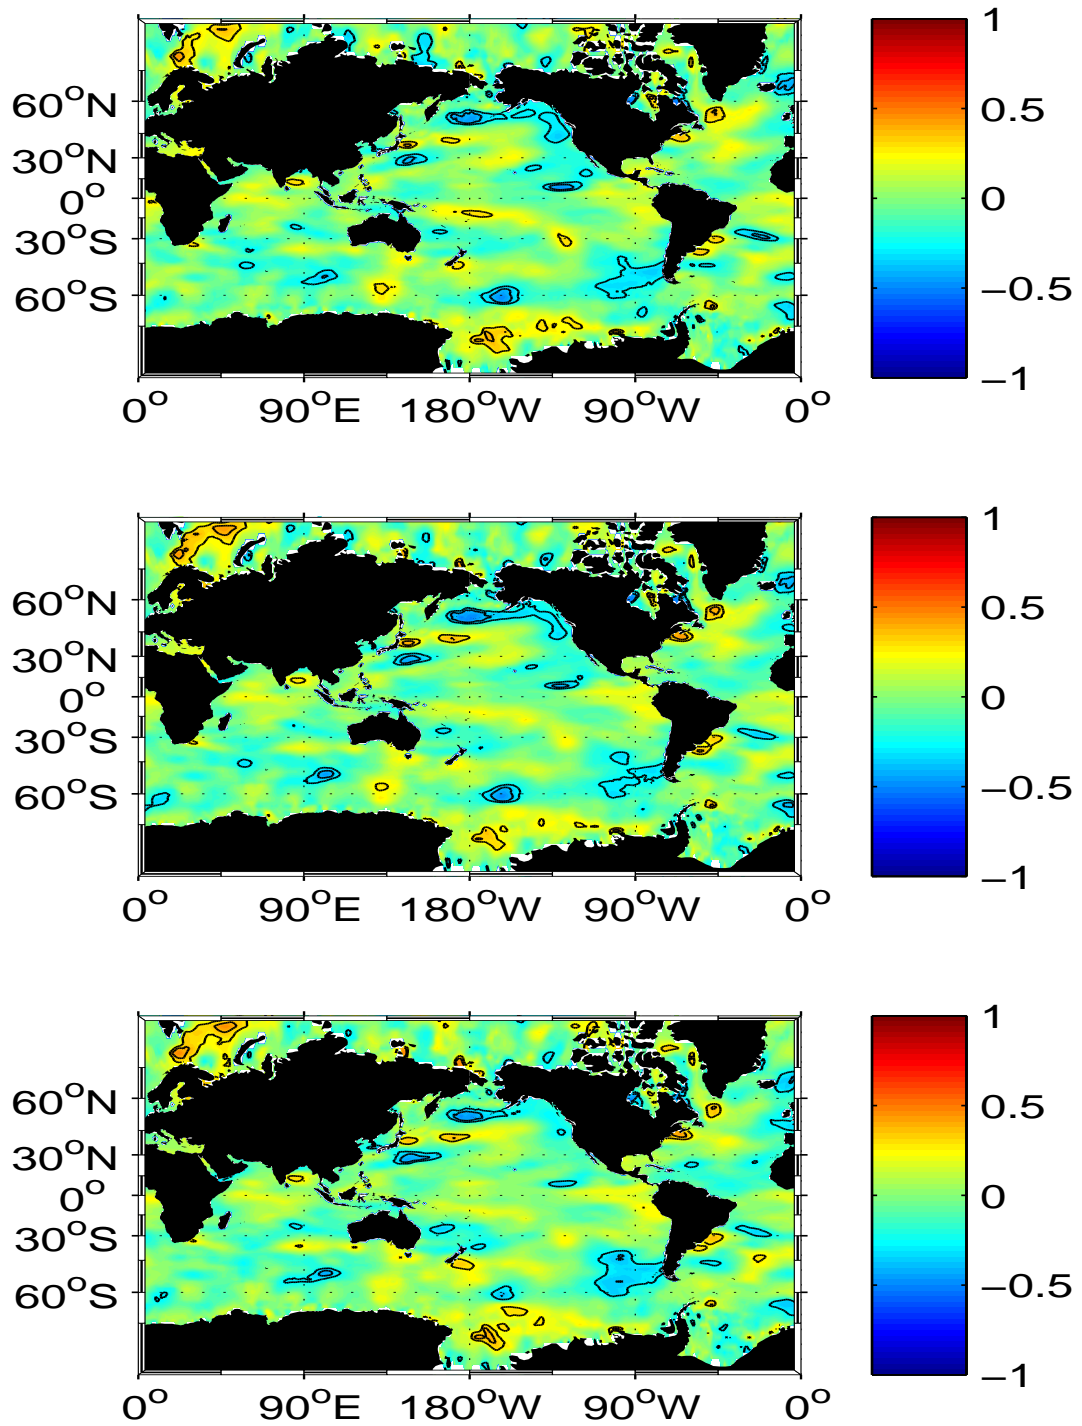


Figura 4.9 – Correlação entre anomalia da temperatura da superfície do mar no mês de junho e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

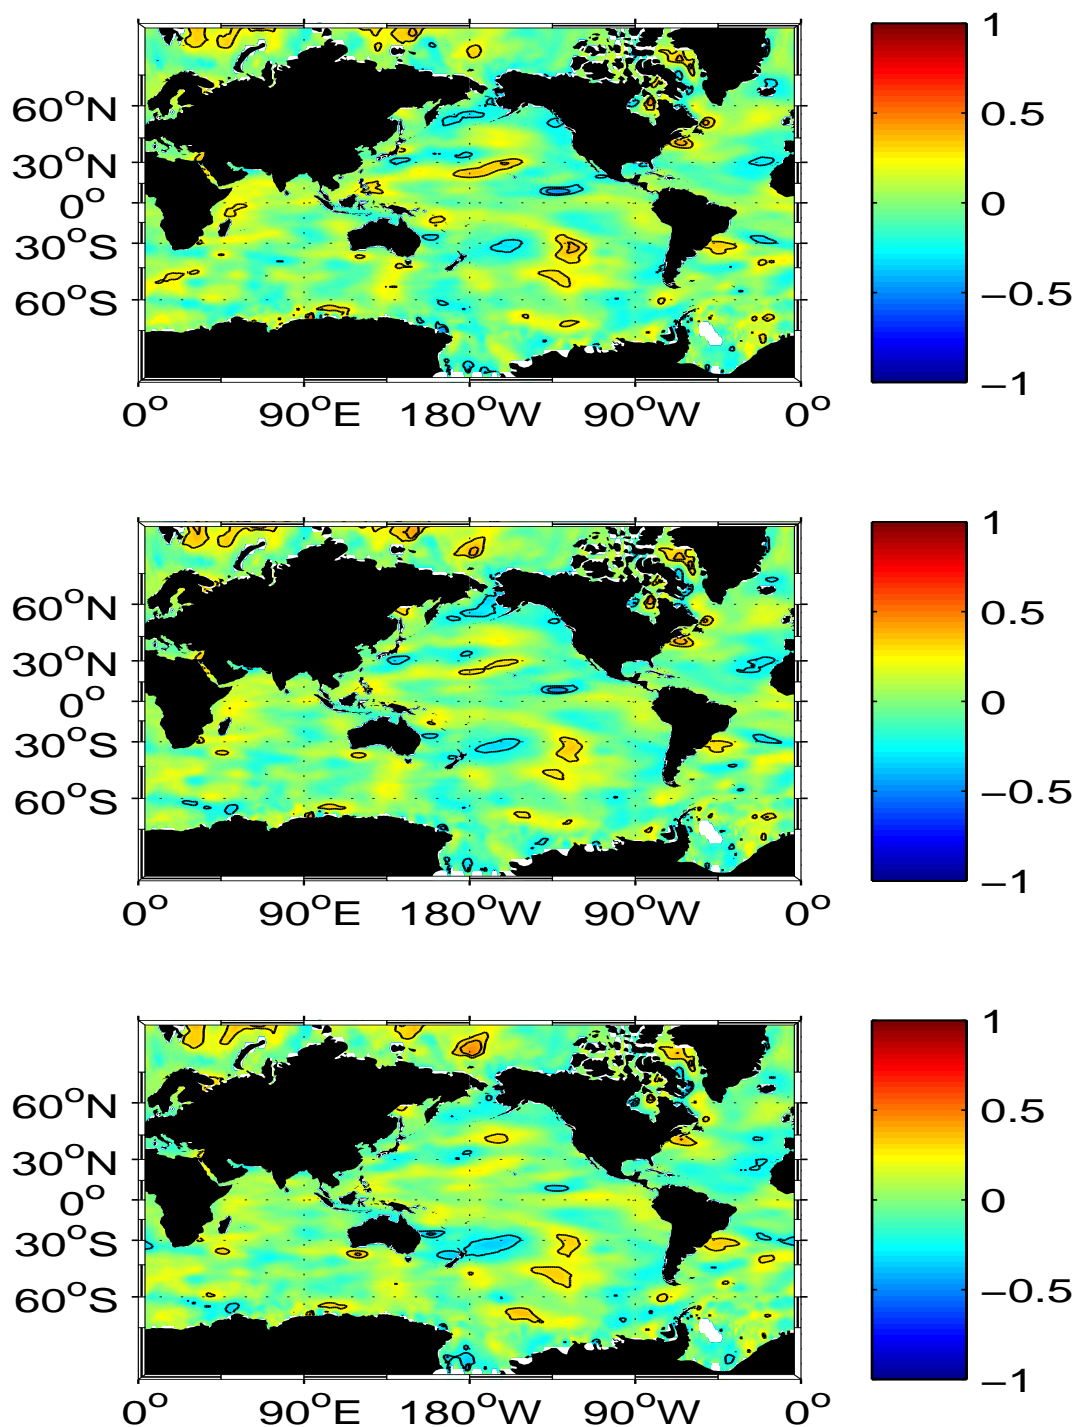


Figura 4.10 – Correlação entre anomalia da temperatura da superfície do mar no mês de julho e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

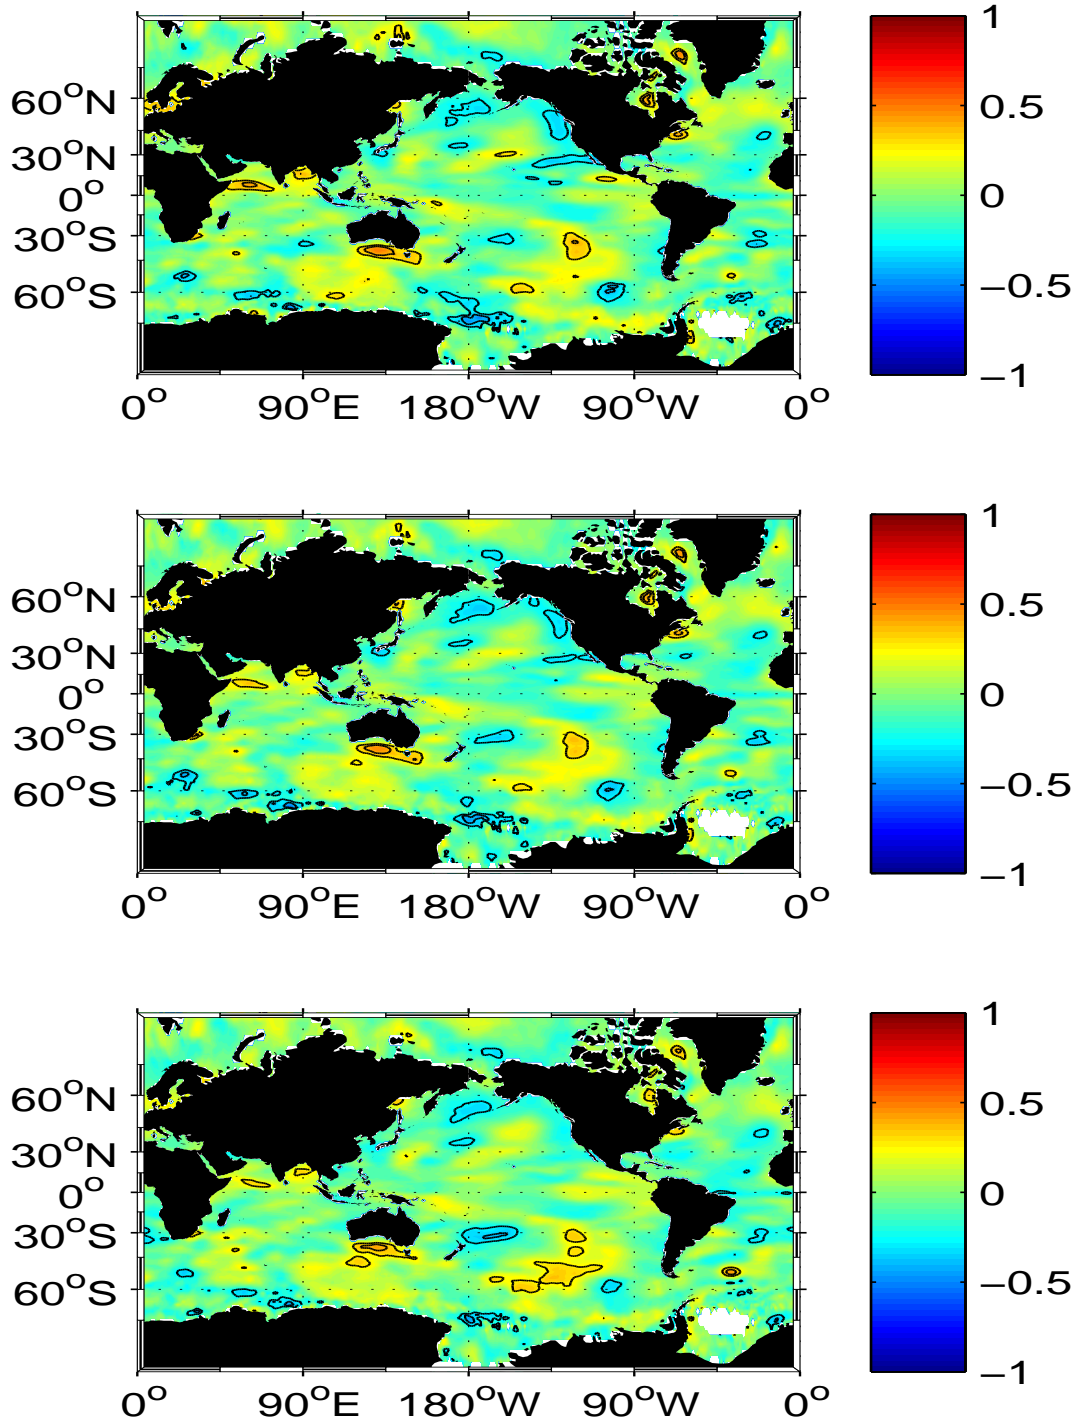


Figura 4.11 – Correlação entre anomalia da temperatura da superfície do mar no mês de agosto e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

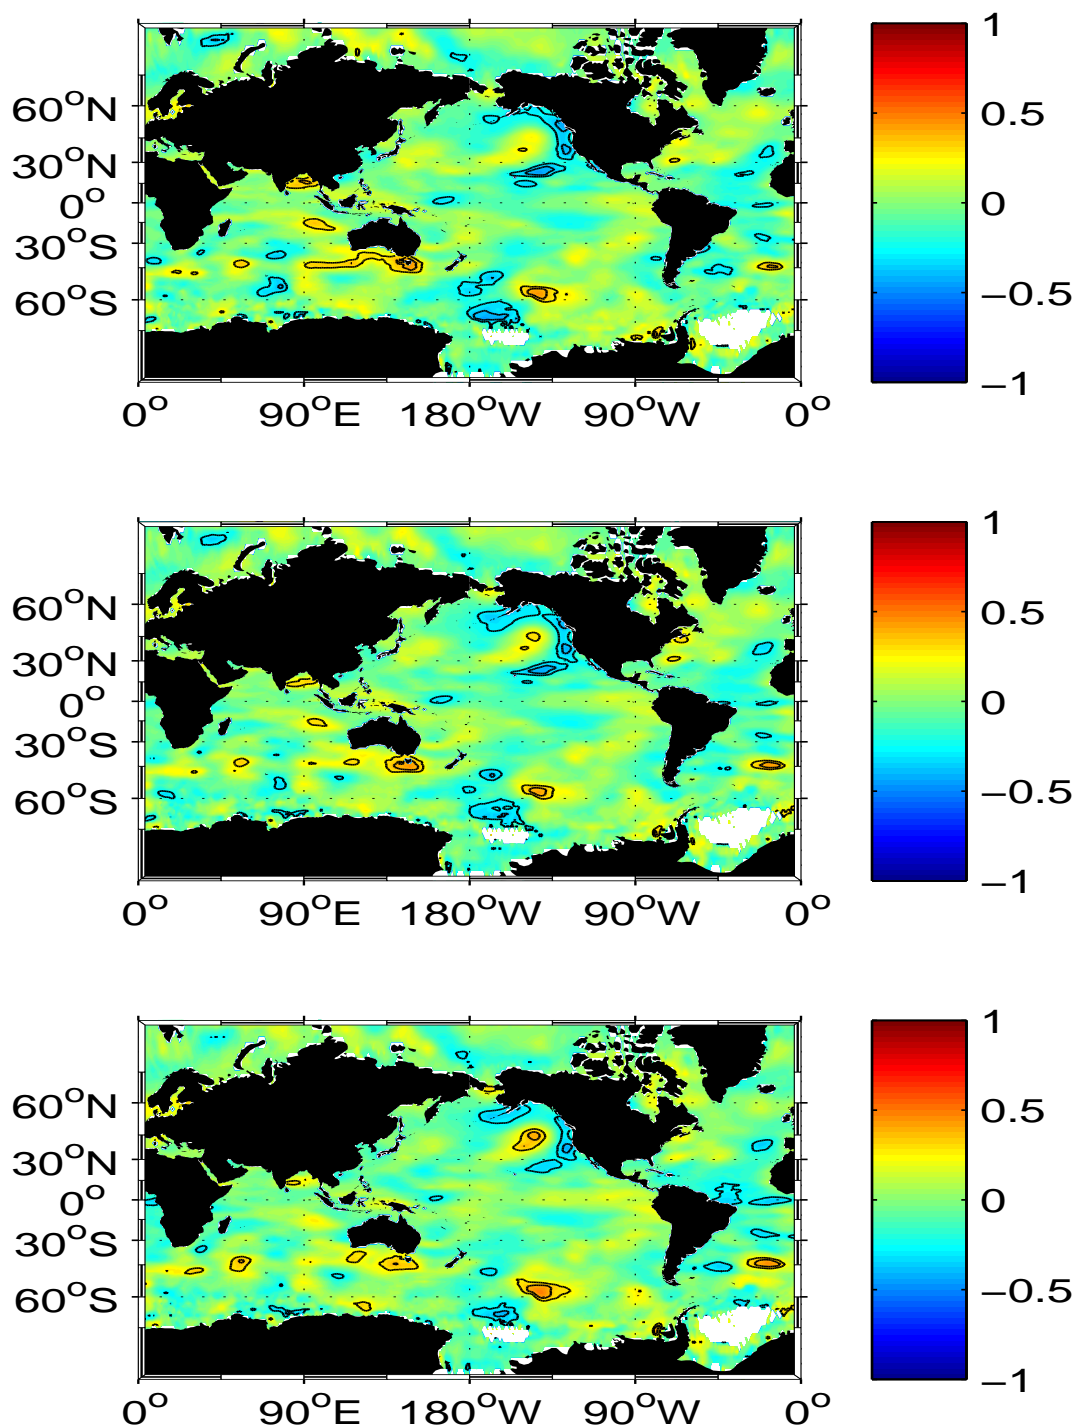


Figura 4.12 – Correlação entre anomalia da temperatura da superfície do mar no mês de setembro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

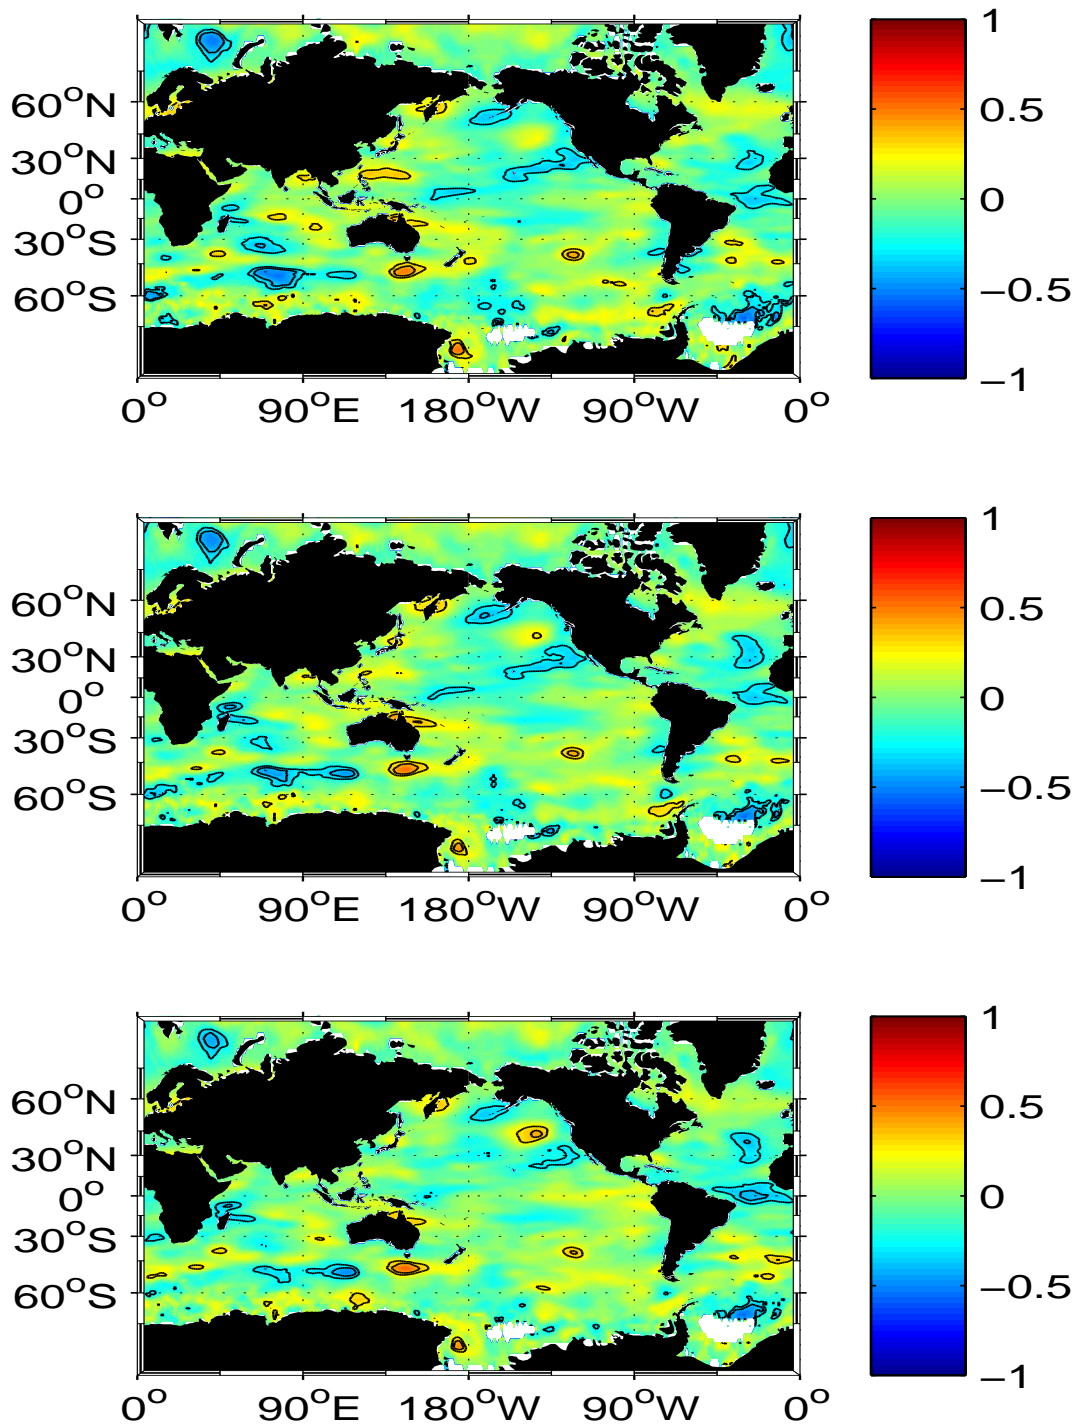


Figura 4.13 – Correlação entre anomalia da temperatura da superfície do mar no mês de outubro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

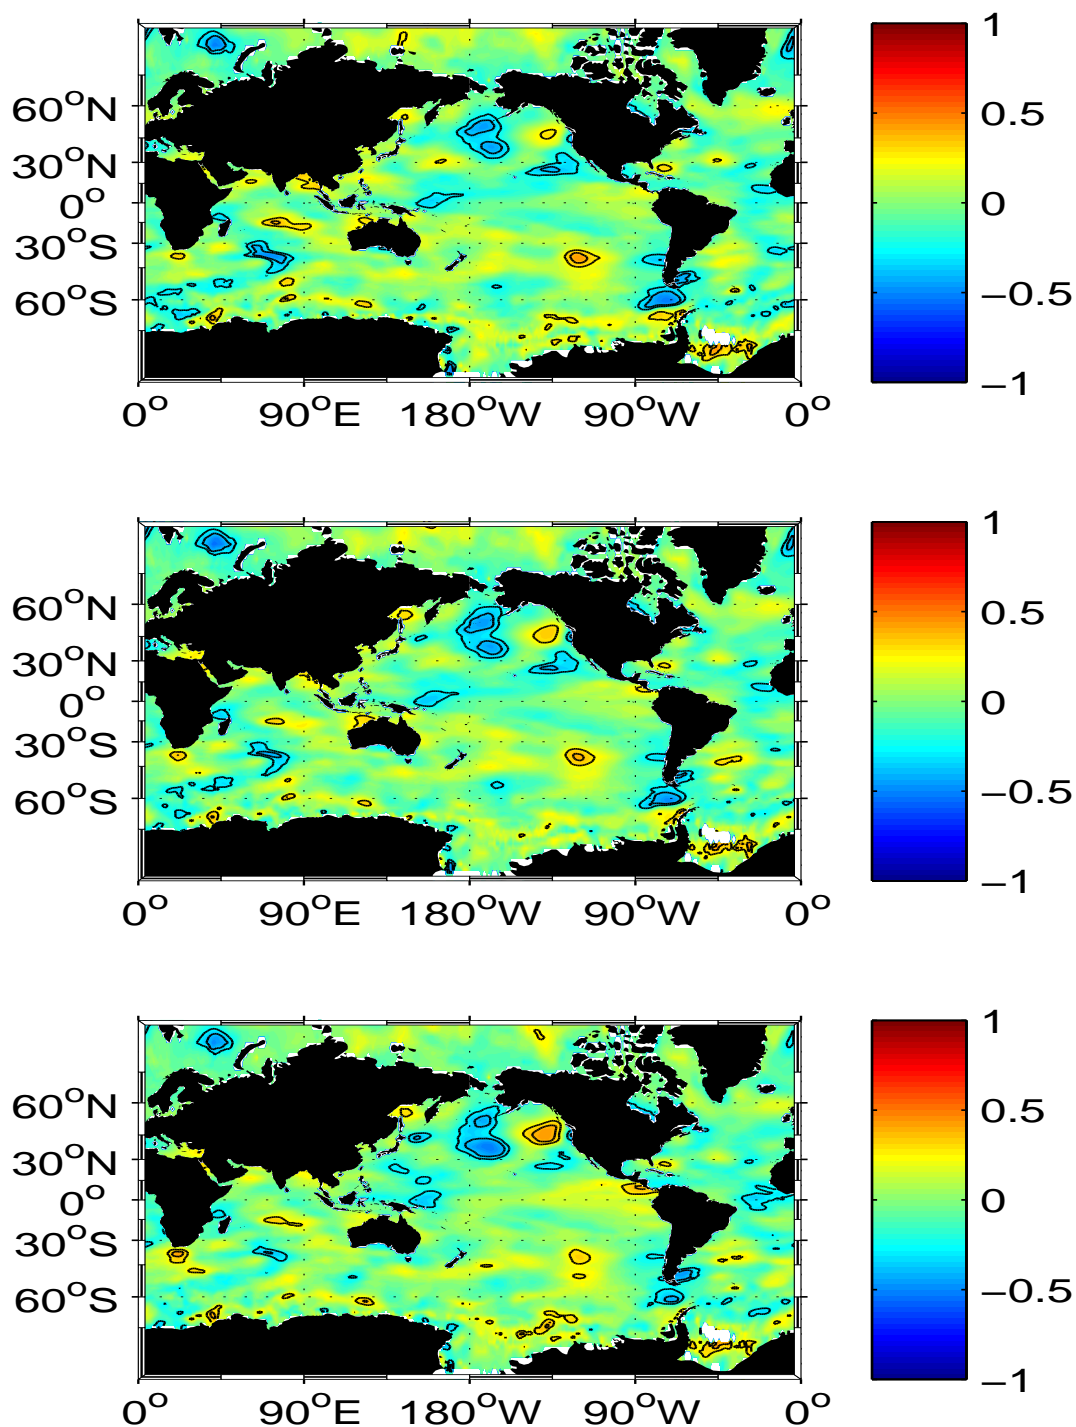


Figura 4.14 – Correlação entre anomalia da temperatura da superfície do mar no mês de novembro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

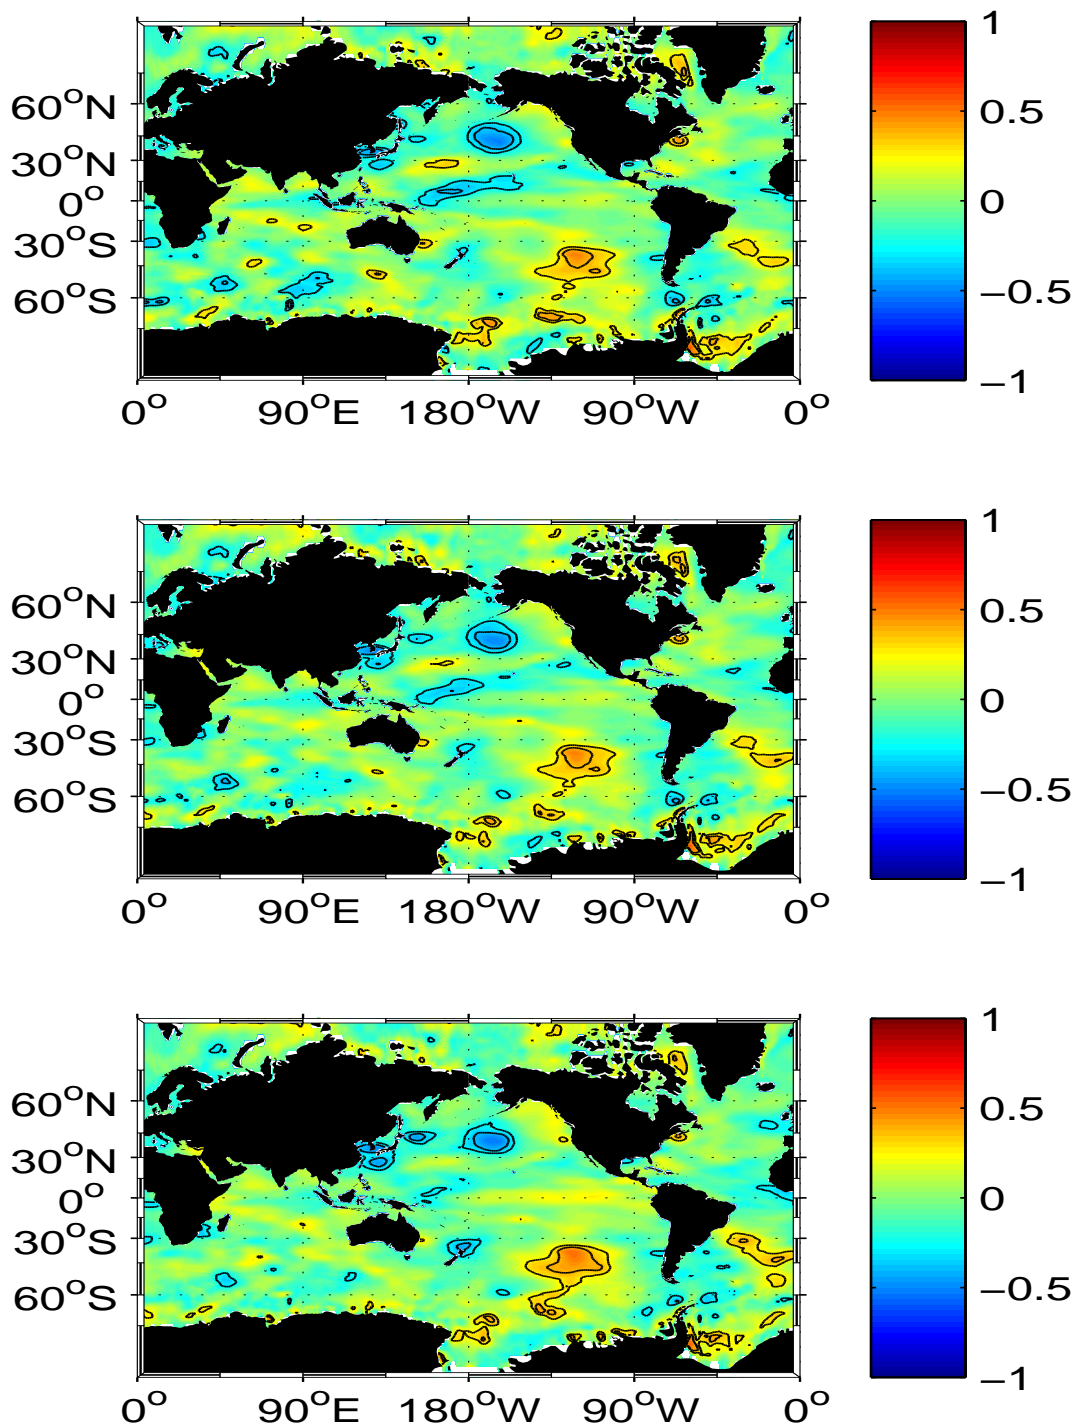


Figura 4.15 – Correlação entre anomalia da temperatura da superfície do mar no mês de dezembro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

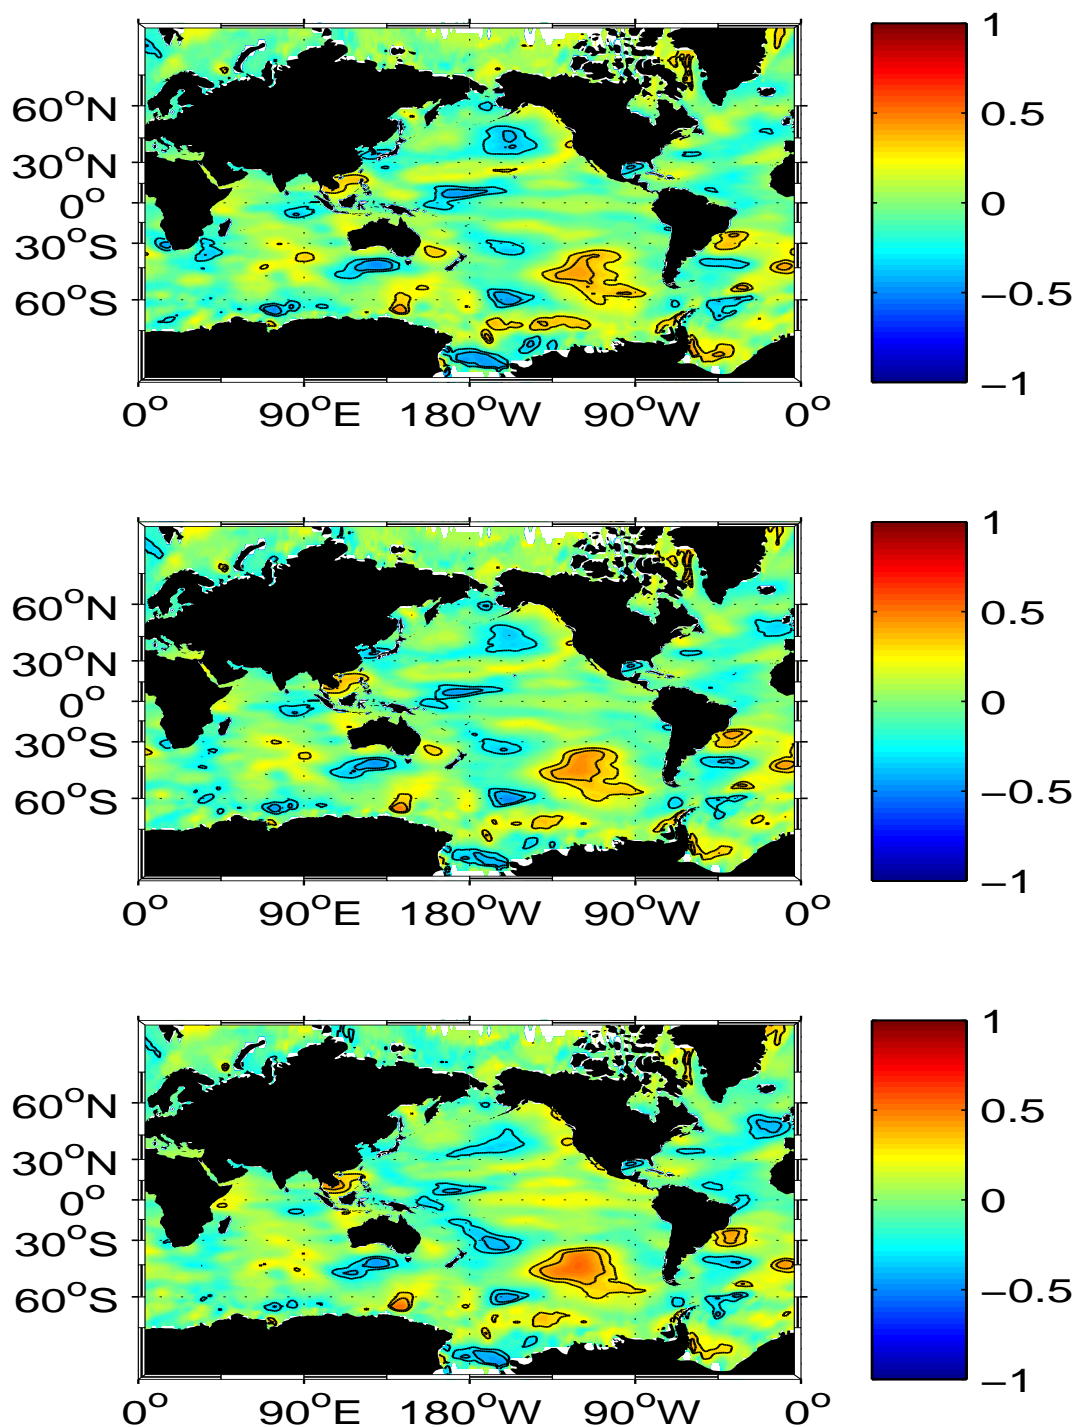


Figura 4.16 – Correlação entre anomalia da temperatura da superfície do mar no mês de janeiro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

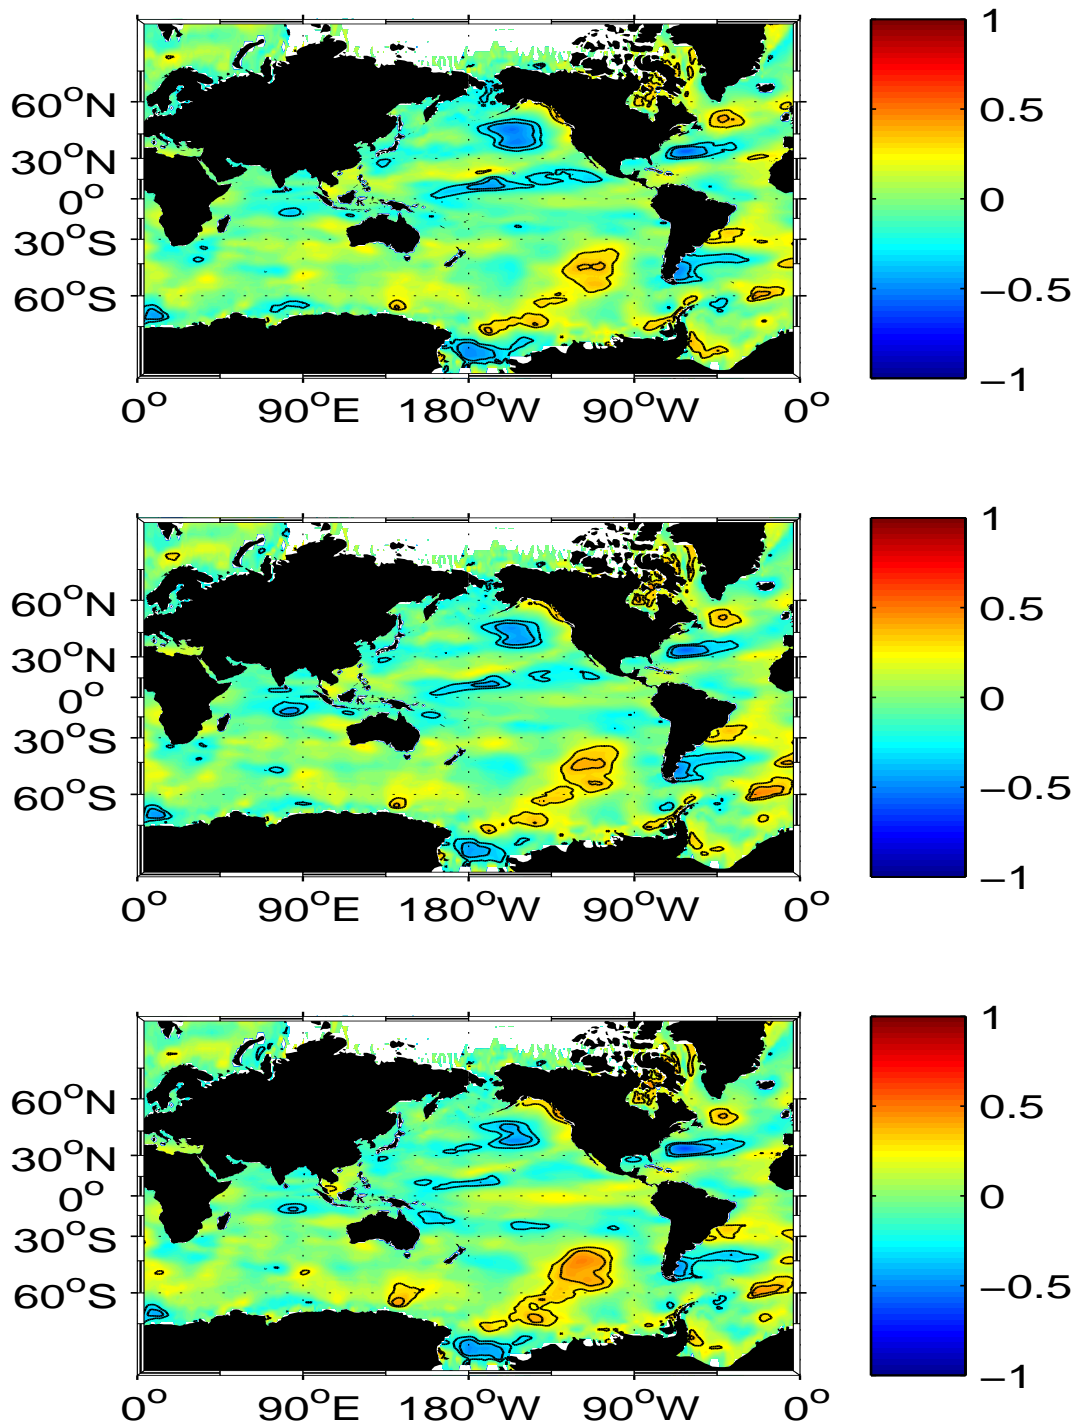


Figura 4.17 – Correlação entre anomalia da temperatura da superfície do mar no mês de fevereiro e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

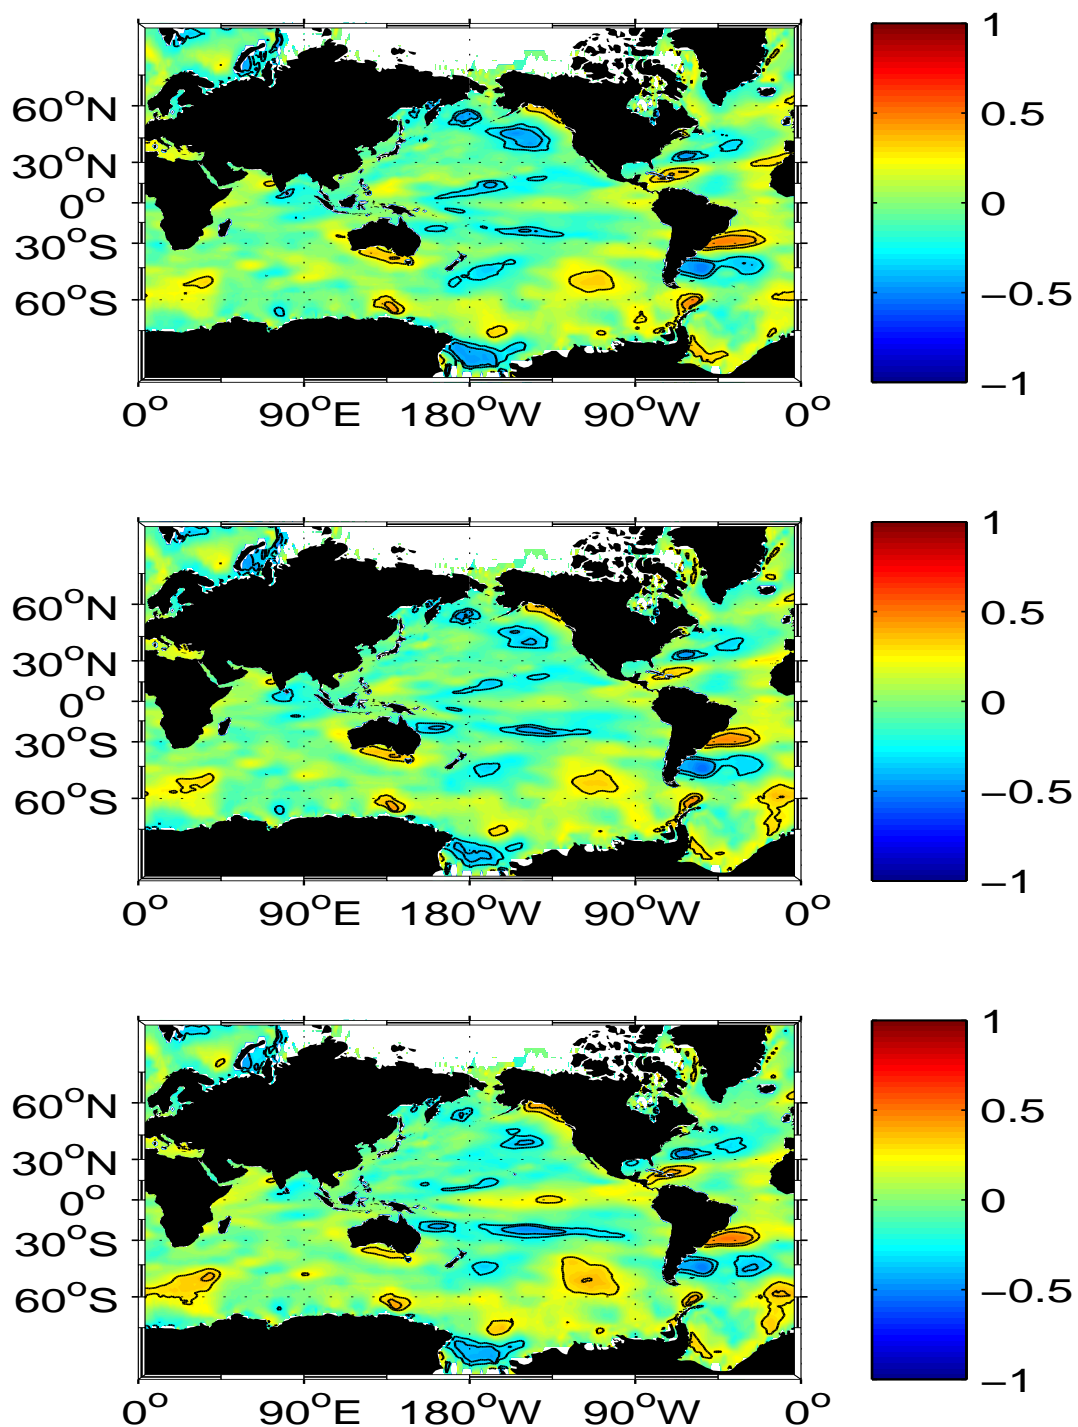
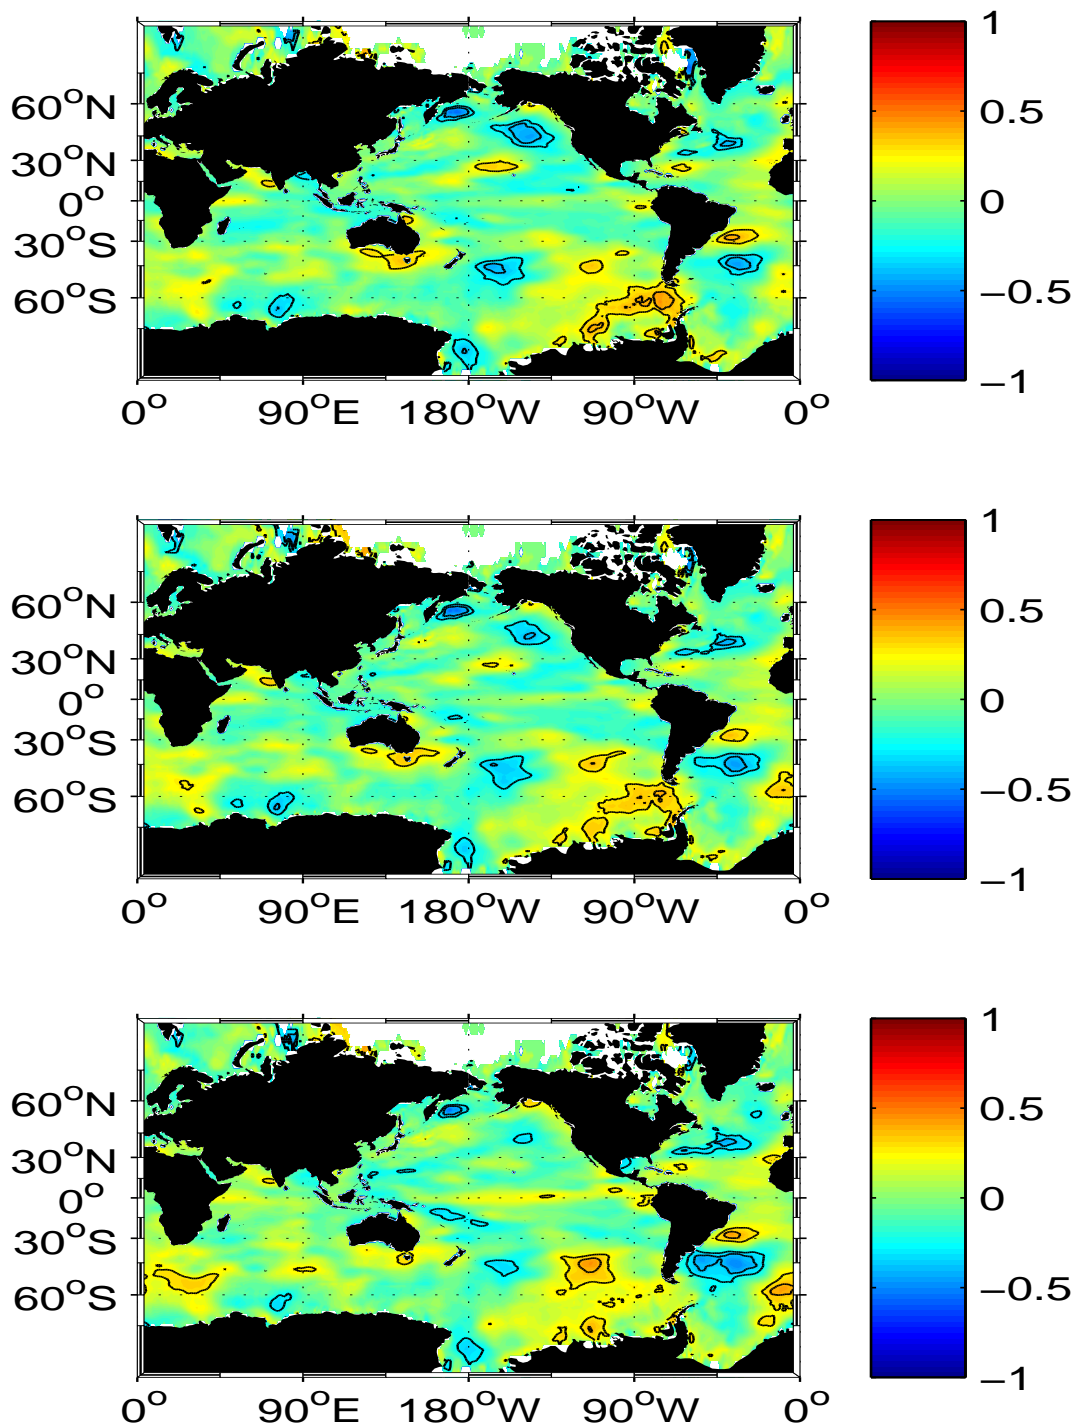


Figura 4.18 – Correlação entre anomalia da temperatura da superfície do mar no mês de março e produtividade de soja para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.




4.1.5 Previsão Estatística - G1 Soja

4.1.5.1 Preditores Selecionados

A lista de preditores selecionados para o G1 da soja para diferentes defasagens encontra-se na Tabela M.1.

A relação dos índices utilizados para as previsões para os seis meses demonstra a importância da região do Oceano Índico, próximo a 50°S/72°E, para o G1 da cultura da soja no RS. Em todas as defasagens utilizadas, índices derivados desta região oceânica apresentaram a correlação mais elevada sendo selecionado como o principal índice para a previsão da produtividade de soja neste grupo. Anomalias positivas (negativas) de TSM no mês de setembro estão correlacionadas a anomalias negativas (positivas) de produtividade de soja no nordeste do RS em 69% (59%) dos casos (Figura 4.19).

Figura 4.19 – Relação entre anomalias de TSM no mês de setembro na região próxima a 50°S/72°E e anomalias de produtividade no Grupo 1. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) de TSM nessa região.



Fonte: Próprio autor.

Outra região que atua como potencial indicativo da produtividade de soja para o G1 é a região do Oceano Pacífico sul (39°S/130°E) no mês de julho, que foi selecionada

como preditora nos modelos de outubro a dezembro. A partir do mês de dezembro essa região continua a apresentar sinal significativo, mas o índice referente a dezembro apresenta maior correlação, sendo assim utilizado no modelo de janeiro. Anomalias positivas (negativas) de TSM nessa região do Pacífico estiveram associadas a aumento (diminuição) da produtividade durante o período deste estudo.

A medida que se aproximam as principais fases fenológicas de desenvolvimento da cultura, nota-se a elevação dos padrões de correlação entre a produtividade e os padrões de TSM. Isso implica na utilização de índices de regiões próximas, como ocorre com os índices 2 e 3 da previsão de fevereiro que são baseados na mesma região do Atlântico norte. A inclusão de dois índices próximos e altamente correlacionados pode acarretar na degradação da destreza do modelo.

4.1.5.2 *Validação Cruzada*

Na Figura 4.20 pode-se observar a comparação entre a produtividade observada do G1 ao longo da série de estudo e as previsões realizadas através da validação cruzada para os diferentes meses de referência usando como base os índices acima listados. Já na Tabela 4.6 encontra-se o resumo dos parâmetros utilizados para estimar a destreza da previsão do modelo para cada um dos meses utilizados na validação cruzada e apresentada na Figura 4.20. Pode-se observar que há um aumento da correlação a medida que se adicionam ao modelo estatístico índices mais próximos a fase de colheita da cultura e que apresentam maiores correlações com a produtividade. Também é observado um incremento na destreza do modelo, configurado até o mês de fevereiro, com a redução do RMSE. Além disso, as previsões de todos os meses apresentaram um RMSE menor que o desvio padrão da série histórica de produtividade (514,59 kg/ha). Com relação ao viés, há uma tendência de pequena superestimativa, com exceção dos meses de janeiro e março onde essa tendência é muito mais elevada. Nota-se que no mês de março, apesar da correlação ser elevada e o RMSE apresentar o segundo menor valor, a taxa de acerto referente aos tercís apresenta a mais baixa destreza e, assim com o verificado na previsão de janeiro, há uma elevação no viés apresentado.

Figura 4.20 – Comparação entre a produtividade média da soja do Grupo 1 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.

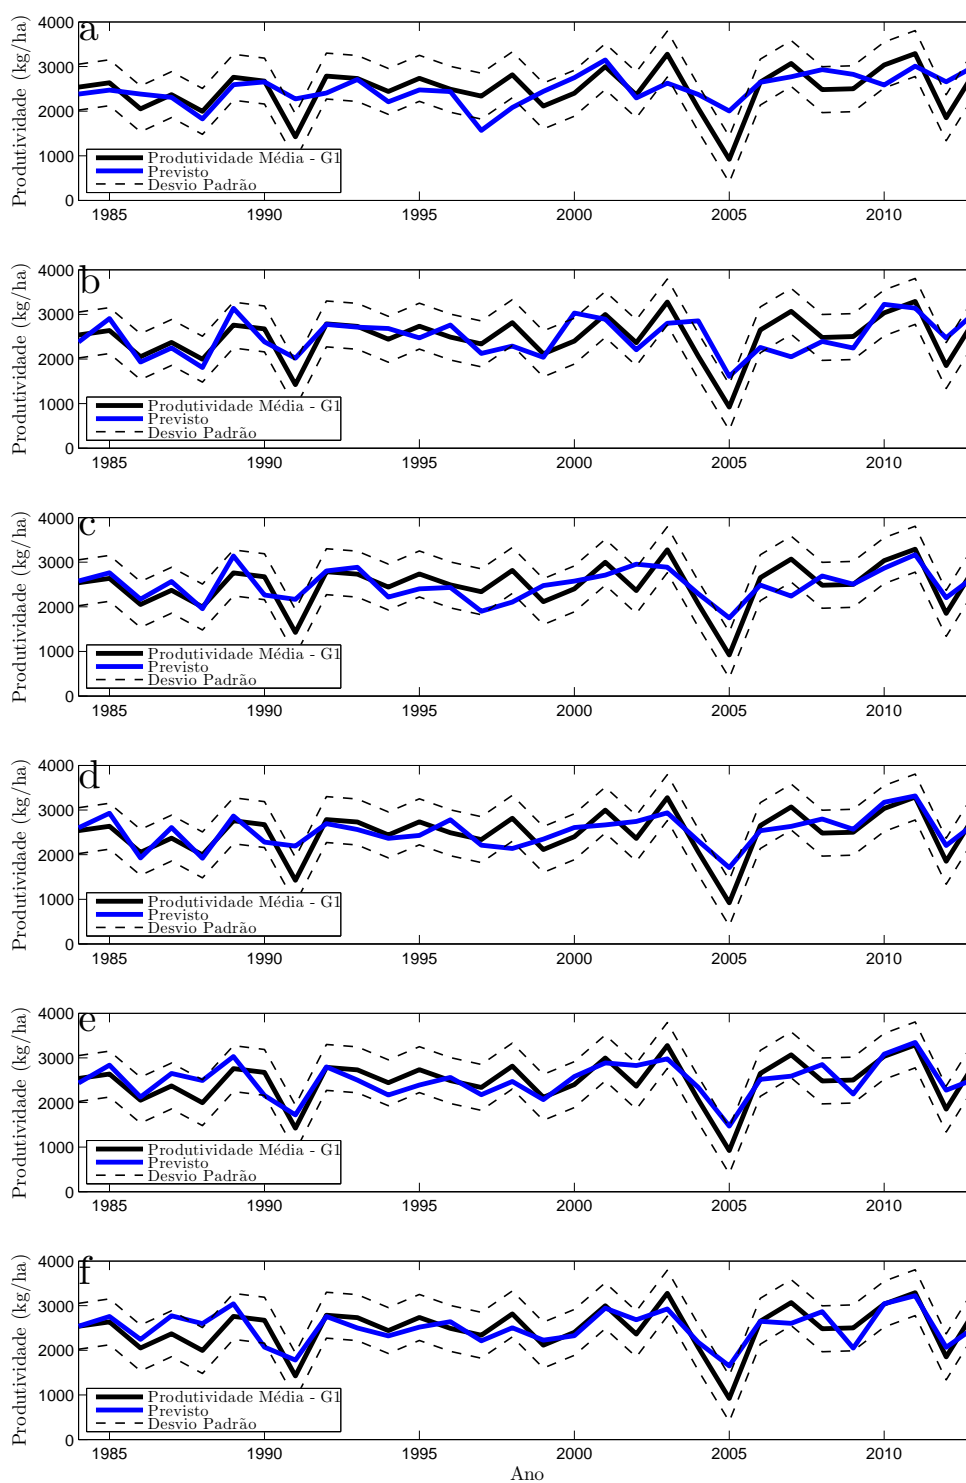


Tabela 4.6 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo da soja referente ao Grupo 1 para as previsões dos meses de outubro a março.

	Corr.	Viés	RMSE	Taxa de Acerto
OUT	0,54	3,58	432,71	60%
NOV	0,65	4,82	397,97	66,67%
DEZ	0,67	3,25	377,88	66,67%
JAN	0,76	33,92	330,15	60%
FEV	0,80	8,98	304,65	60%
MAR	0,78	15,59	315,35	56,67%

4.1.6 Previsão Estatística - G2 Soja

4.1.6.1 *Preditores Selecionados*

A lista de preditores selecionados para o G2 da soja para diferentes defasagens encontra-se na Tabela N.1.


Assim como para o G1, o Oceano Índico apresenta forte influência na variabilidade interanual do G2 da soja, mas com uma região situada mais a leste, próximo ao sul da Oceania. O índice referente a esta região (ATSM/SET/48°S/146°E) aparece como principal preditor dos meses de outubro e novembro e é inserido também nos modelos de dezembro a fevereiro. Anomalias positivas (negativas) de TSM nesta região estão associadas a um aumento (diminuição) da produtividade de soja no G2 em 75% (61%) dos casos (Figura 4.21).

Destacam-se também, anomalias de TSM do mês de novembro próximas à 41°N/166°W com correlações negativas com a produtividade de soja que se caracterizam como o principal índice preditor nos modelos de dezembro a fevereiro para o G2 da soja.

4.1.6.2 *Validação Cruzada*

Com base na Tabela 4.7 e da Figura 4.22 pode-se observar a evolução do modelo elaborado para o G2 a medida que vão sendo inseridos novos índices. Nota-se que a previsão de novembro é a que apresenta o maior RMSE, a menor correlação e também o segundo Viés mais elevado, evidenciando a necessidade de maiores cuidados ao utilizar esta previsão. Apesar disso, destaca-se que para todas as defasagens dos modelos de

Figura 4.21 – Relação entre anomalias de TSM no mês de setembro na região próxima a 48°S/146°E e anomalias de produtividade no Grupo 2. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias positivas (negativas) de TSM nessa região.



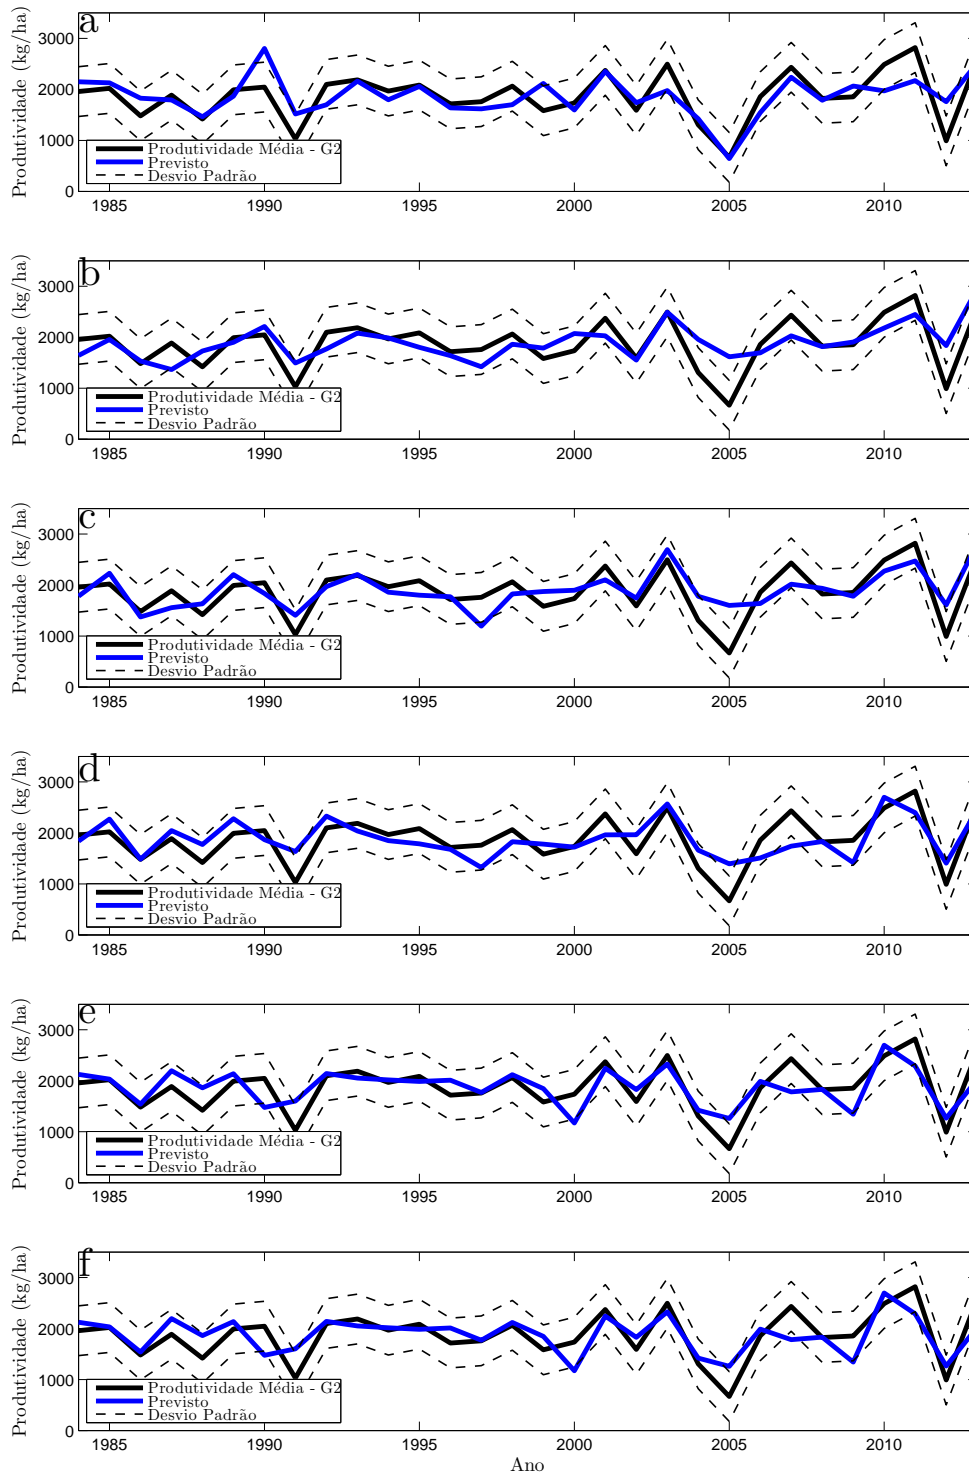
Fonte: Próprio autor.

regressão utilizadas o RMSE foi menor que o desvio padrão da série de produtividade do grupo 2 (487,56 kg/ha).

Tabela 4.7 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo da soja referente ao Grupo 2 para as previsões dos meses de outubro a março.

	Corr.	Viés	RMSE	Taxa de Acerto
OUT	0,71	-5,82	338,38	60%
NOV	0,65	14,57	363,49	60%
DEZ	0,74	18,93	323,75	63,33%
JAN	0,72	7,27	334,08	66,67%
FEV	0,73	-2,49	329,01	60%
MAR	0,71	2,13	336,08	53,33%

Figura 4.22 – Comparação entre a produtividade média da soja do Grupo 2 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.



4.1.7 Previsão Estatística - G3 Soja


4.1.7.1 Preditores Selecionados

A lista de preditores selecionados para o G3 da soja para diferentes defasagens encontra-se na Tabela O.1.

A comparação dos índices utilizados na elaboração dos modelos sinaliza a importância da região oceânica próxima a 48°S/146°E cujas anomalias no mês de setembro foram selecionadas como preditoras em todos os meses. Esta mesma região também foi selecionada como preditora para o G2 e apresenta correlações positivas com a produtividade de soja no RS. Embora a correlação seja mais baixa e menos abrangente, nesta mesma área na Figura 4.12 são observadas correlações positivas com o G1. A importância desta faixa oceânica para a previsão de produtividade sugere o acompanhamento das anomalias de TSM em períodos de preparativos de safra. Para o G3, em 75% (61%) dos casos de anomalias positivas (negativas) nesta região foram observados desvios positivos (negativos) de produtividade (Figura 4.23).

Mais próximo as fases de floração e enchimento de grãos (janeiro a março), as anomalias de TSM do mês de dezembro no Oceano Pacífico sul (46°S/122°W) constituem o índice que exerce maior influência na cultura com elevada correlação positiva.

Figura 4.23 – Relação entre anomalias de TSM no mês de setembro na região próxima a 48°S/146°E e anomalias de produtividade no Grupo 3. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias positivas (negativas) de TSM nessa região.



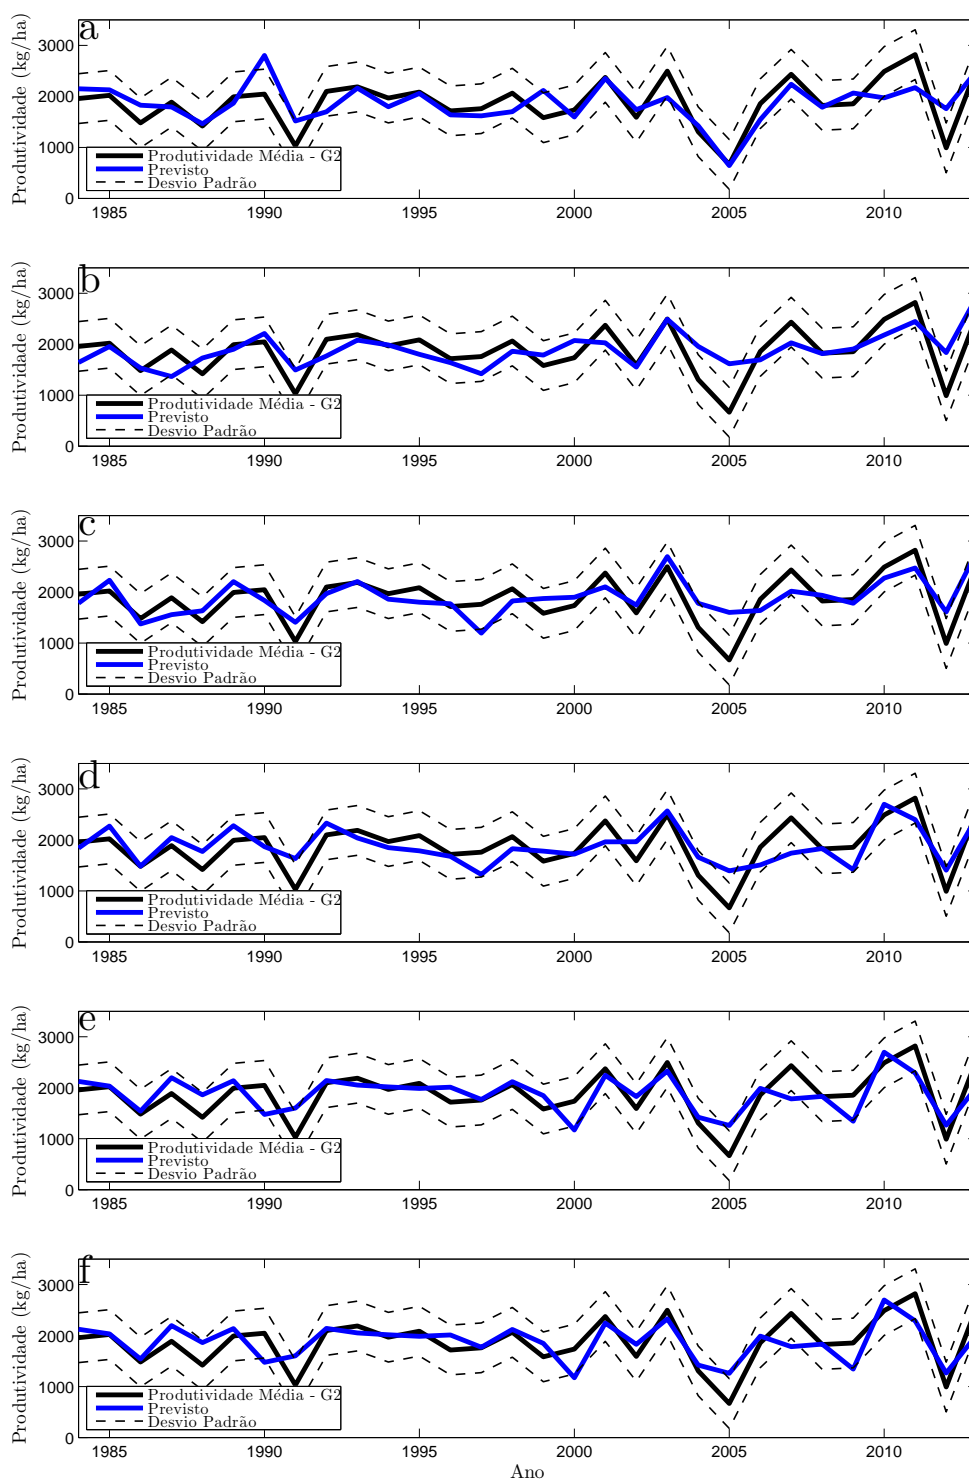
4.1.7.2 Validação Cruzada

Os resultados das medidas de destreza do modelo (Tabela 4.8) demonstram, de uma forma geral, a melhora do modelo a medida que vão sendo inseridos novos índices na previsão. A exceção é a previsão do mês de fevereiro que apresenta uma diminuição da correlação entre a produtividade média observada e a produtividade prevista (Figura 4.24), a elevação do Viés e do RMSE, apesar de apresentar uma das maiores taxas de acerto. A elevada correlação da produtividade prevista com a observada, o baixo Viés, a taxa de acerto superior a 60% (na maior parte dos casos) e o RMSE menor que o desvio padrão da série de produtividade do Grupo 3 (518,60 kg/ha) sinalizam a utilidade do modelo como ferramenta de apoio aos agricultores e no momento de tomada de decisões.

Tabela 4.8 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo da soja referente ao Grupo 3 para as previsões dos meses de outubro a março.

	Corr.	Viés	RMSE	Taxa de Acerto
OUT	0,65	14,37	389,26	63,33%
NOV	0,66	-5,17	381,45	63,33%
DEZ	0,72	7	357,23	66,67%
JAN	0,73	-1,45	351,12	56,67%
FEV	0,68	9,75	373,37	66,67%
MAR	0,79	2,58	313,99	66,67%

Figura 4.24 – Comparação entre a produtividade média da soja do Grupo 3 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; e) janeiro e f) fevereiro. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.



4.1.8 Previsão das safras de soja de 2013/2014 e 2014/2015

Para a safra de 2013/2014, a previsão com índices até o mês de setembro (modelo de outubro) indicava tendência de produtividade acima da média para o Grupo 1 (Tabela 4.9). A partir do mês de dezembro, as projeções passaram a ser de produtividade abaixo da média para este grupo homogêneo. Para a safra 2014/2015, ocorreram mais variações na previsão elaborada para o G1. As previsões de outubro, fevereiro e março indicavam produtividade acima da média enquanto nos meses de dezembro e janeiro a previsão foi de produtividade próxima a média climatológica.

Para o Grupo 2, grande parte das previsões para a safra 2013/2014 (Tabela 4.9) foram de produtividade acima da média com exceção a previsão de fevereiro que indicava valores mais próximos a média da série histórica do grupo. Na safra de 2014/2015, assim como para o G1, houve maior alternância entre as previsões com três previsões indicando elevação da produtividade (novembro, janeiro e março), duas produtividade abaixo da média (outubro e fevereiro) e a previsão de dezembro com previsões próximas a média histórica.

Por fim, para o Grupo 3, a maior parte das previsões (4 previsões) indicou valores próximos a média histórica deste grupo homogêneo para a safra 2013/2014 (Tabela 4.9). Por outro lado, para a safra de 2014/2015, 4 previsões indicaram uma tendência de produtividade acima da média.

Os resultados apresentados para o G1 (Tabela 4.10) demonstram que apenas os modelos de outubro e novembro conseguiram prever a situação de produtividade pouco acima da média e dentro da normal climatológica na safra 2013/2014. As previsões dos meses subsequentes que indicavam queda de produtividade não se confirmaram. Para a safra de 2014/2015, apenas um modelo (novembro) conseguiu estimar com precisão a elevação da produtividade.

Para o G2, os dados observados apontaram para a elevação da produtividade tanto na safra 2013/2014 como na safra 2014/2015 (Tabela 4.10). Para este grupo, os resultados foram melhores com a maior parte das previsões com tendência de produtividade acima da média para as duas safras.

As previsões para a safra 2013/2014 no G3 indicavam produtividade próxima a normal climatológica. Apesar disso, verificou-se ligeira queda da produtividade neste ano agrícola. Por outro lado, para 2014/2015, a maior parte das previsões apontava para produtividade acima da média, fator confirmado posteriormente.

Tabela 4.9 – Previsão estatística de produtividade de soja para as safras 2013/2014 e 2014/2015 para os Grupos 1, 2 e 3. Os valores indicam a probabilidade da produtividade ser acima, abaixo ou dentro da normal climatológica do período de estudo.

		2013/2014			2014/2015		
		acima (%)	normal (%)	abaixo (%)	acima (%)	normal (%)	abaixo (%)
G1	OUT	49	28	23	11	21	68
	NOV	32	34	34	54	27	19
	DEZ	18	27	55	35	31	34
	JAN	16	34	50	25	38	37
	FEV	1	2	97	10	31	59
	MAR	1	7	92	19	38	43
			acima	normal	abaixo	acima	normal
G2	OUT	83	12	5	7	13	80
	NOV	63	24	13	41	30	29
	DEZ	58	27	15	37	31	32
	JAN	56	28	16	66	23	11
	FEV	28	33	39	16	28	56
	MAR	60	27	13	86	11	3
			acima	normal	abaixo	acima	normal
G3	OUT	69	25	6	40	40	20
	NOV	39	46	15	59	34	7
	DEZ	25	51	24	90	9	1
	JAN	11	45	44	91	8	1
	FEV	11	42	47	23	49	28
	MAR	1	4	95	77	18	5
			acima	normal	abaixo	acima	normal

Tabela 4.10 – Produtividade registrada nos Grupos 1, 2 e 3 nas safras de 2013/2014 e 2014/2015 e média climatológica de produtividade dos três grupos ao longo do período de estudo.

	2013/2014	2014/2015	Média
G1	2688 kg/ha	3253 kg/ha	2524 kg/ha
G2	2074 kg/ha	2548 kg/ha	1903 kg/ha
G3	1370 kg/ha	2457 kg/ha	1506 kg/ha

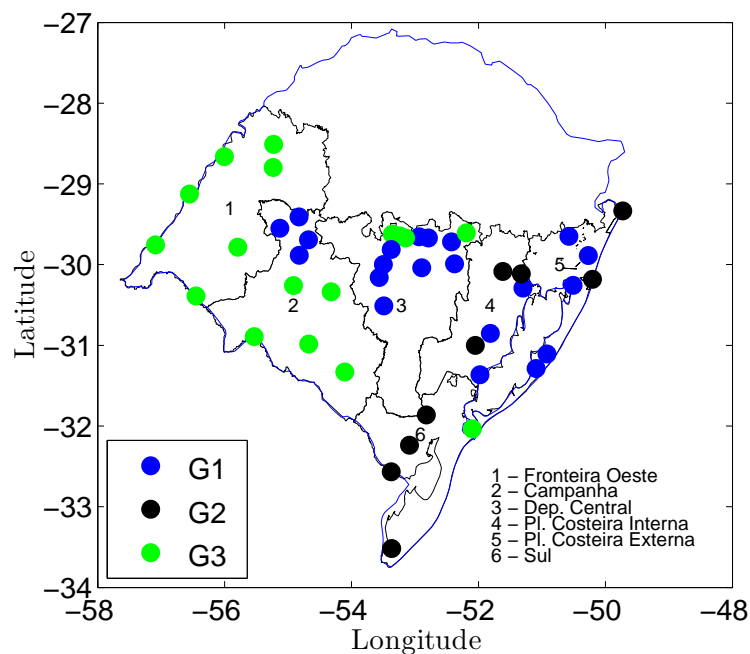
4.2 ARROZ

4.2.1 Regiões Homogêneas

O resultado da distribuição dos municípios em grupos homogêneos de produtividade de arroz pode ser visualizada na Figura 4.25. Na Tabela P.1 encontra-se a listagem dos municípios utilizados neste estudo e seu respectivo agrupamento. Nesta Figura os grupos homogêneos estão sobrepostos as regiões orizícolas segundo o Instituto Rio Grandense do Arroz (IRGA). Os municípios do Grupo 1 (G1), grupo de menor produtividade média, encontram-se, em sua maior parte, entre a Depressão Central e nas Planícies Interna e Externa a Lagoa dos Patos (Figura 4.26). O Grupo 2, de produtividade intermediária, encontra-se, principalmente, no Sul do Estado e, de forma mais isolada, em pontos das Planícies em torno da Lagoa dos Patos (Figura 4.26). Por fim, o Grupo 3, grupo de maior produtividade, apresenta a maior parte de seus integrantes sobre as regiões da Fronteira Oeste e Campanha gaúcha (Figura 4.26).


A Figura 2.4 ajuda a explicar parte das diferenças observadas entre os três grupos homogêneos. Nota-se que, pelo zoneamento do arroz, as regiões que apresentam maior disponibilidade de radiação solar são as regiões onde predominam os grupos 3 (Fronteira Oeste, principalmente) e 2 (Sul do Estado). A combinação da disponibilidade de radiação com o risco de frio evidencia que, além de apresentar mais radiação disponível durante o período de cultivo do arroz, a Fronteira Oeste apresenta também menor suscetibilidade ao frio, fatores que resultam em uma maior produtividade média. A Depressão Central apesar de apresentar baixo risco de frio, encontra-se em uma faixa onde a disponibilidade de radiação solar é mais baixa e, por isso, apresenta menores produtividades médias em comparação com as outras regiões do Estado.

Figura 4.25 – Mapa das regiões homogêneas de produtividade de arroz no Rio Grande do Sul com a distribuição espacial dos grupos G1, G2 e G3 resultante da análise de agrupamento. Os limites e a numeração referem-se as regiões orizícolas do Estado segundo o IRGA.



Fonte: Próprio autor.

Figura 4.26 – Perfis médios de produtividade de grãos de arroz dos grupos: G1 (azul), G2 (preto) e G3 (verde). A área sombreada delimita o desvio padrão de cada uma das séries.



Fonte: Próprio autor.

4.2.2 Comparação Intraíndices

Nas Figuras 4.27, 4.28 e 4.29 estão dispostas as correlações entre os índices climáticos e a produtividade de arroz nos três grupos homogêneos onde as linhas pontilhadas na horizontal delimitam os níveis de confiança de 95 e 99%. Muitos dos resultados aqui apresentados são inéditos do ponto de vista agrometeorológico tendo em vista que, apenas as influências do ENOS na variabilidade da produtividade do arroz irrigado no RS foram estudadas anteriormente. No caso do arroz, há uma relação indireta com a precipitação que, associada a maior presença de nebulosidade, atua na diminuição da chegada de radiação em superfície e, com isso, afeta o melhor desenvolvimento da cultura.

No mês de abril, destacam-se as correlações entre a OAA e o G2 (negativa), QBO e os grupos 1 e 3 (negativa) e as anomalias de TSM na região da ATSM1 e o G3 (positiva). Entre os índices acima citados, destaca-se a QBO com sinal persistente para os meses de maio e junho para os grupos 1 e 3 e no mês de julho apenas para o G3. No Brasil, há uma ampla correlação negativa entre a QBO e a precipitação na costa leste do Nordeste (BERNARDO; MOLION, 2004). Para regiões extratropicais, a influência da QBO foi observada em campos de precipitação, frequência de vórtices ciclônicos e produtividade de trigo na parte europeia da Rússia (CHERENKOVA; BARDIN; ZOLOTOKRYLIN, 2015). Apesar dos sinais apresentados, em ambos os estudos, os autores não conseguiram explicar os mecanismos físicos responsáveis por esta variabilidade.

A partir do mês de maio, começa-se a notar a influência do ENOS na produtividade de arroz. Em maio, apenas a sua componente atmosférica (IOS) exerce influência (correlação positiva) sobre os três grupos. O sinal associado ao IOS persiste com correlações significativas até o mês de outubro, alternando sua intensidade entre os grupos. Tal correlação estaria associada a persistência de um padrão de tempo mais seco durante o período de desenvolvimento da cultura que favoreceria a elevação da produtividade. Esta ideia pode ser confirmada pela correlação negativa entre o as anomalias de TSM no Niño 3.4 (Niño) configurada entre junho e março com pequenas alterações em sua intensidade e significância ao longo dos meses. Os resultados aqui encontrados para o evento ENOS corroboram estudos anteriores que sinalizaram que eventos de La Niña estão associados a aumento da produtividade de arroz no sul do Estado (MOTA, 2000). A ligeira diferença entre as correlações dos grupos poderia ser explicada, em parte, pela menor correlação entre as TSMs do Pacífico Equatorial e a precipitação no sul do Estado (G2) durante os meses de janeiro a março em comparação com os grupos 1 e, principalmente, G3 (LOPES; DINIZ; MARQUES, 2007).

Para os indicadores climáticos do mês de junho, nota-se a influência das anomalias de TSM referentes ao índice ATSM2 significativa a 99% com o G1 e 95% com o G3. Esta região do Atlântico sul está negativamente correlacionada com a precipitação no RS (CATALDI et al., 2010). Este sinal negativo no mês de junho e a não persistência para

os meses seguintes poderia indicar que anomalias positivas (negativas) nesta região estariam associadas a uma diminuição (elevação) da precipitação no período de enchimento dos reservatórios e, por este motivo, resultariam em queda (aumento) da produtividade do arroz.

Entre julho e agosto, de forma semelhante ao que ocorre com a soja (Figuras 4.3, 4.4 e 4.29), indicadores climáticos associados a padrões de teleconexão com maior influência sobre o Hemisfério Norte passam a exercer influência reforçando a hipótese de influências inter-hemisféricas. A AO possui correlação positiva com a produtividade do G1 para julho. Após um período com ausência de sinal significativo, a AO volta a apresentar correlação com seu índice do mês de outubro (positiva para G1 e G3), dezembro (positiva para o G1), janeiro (positiva para G1 e G3) e fevereiro (positiva para G1).

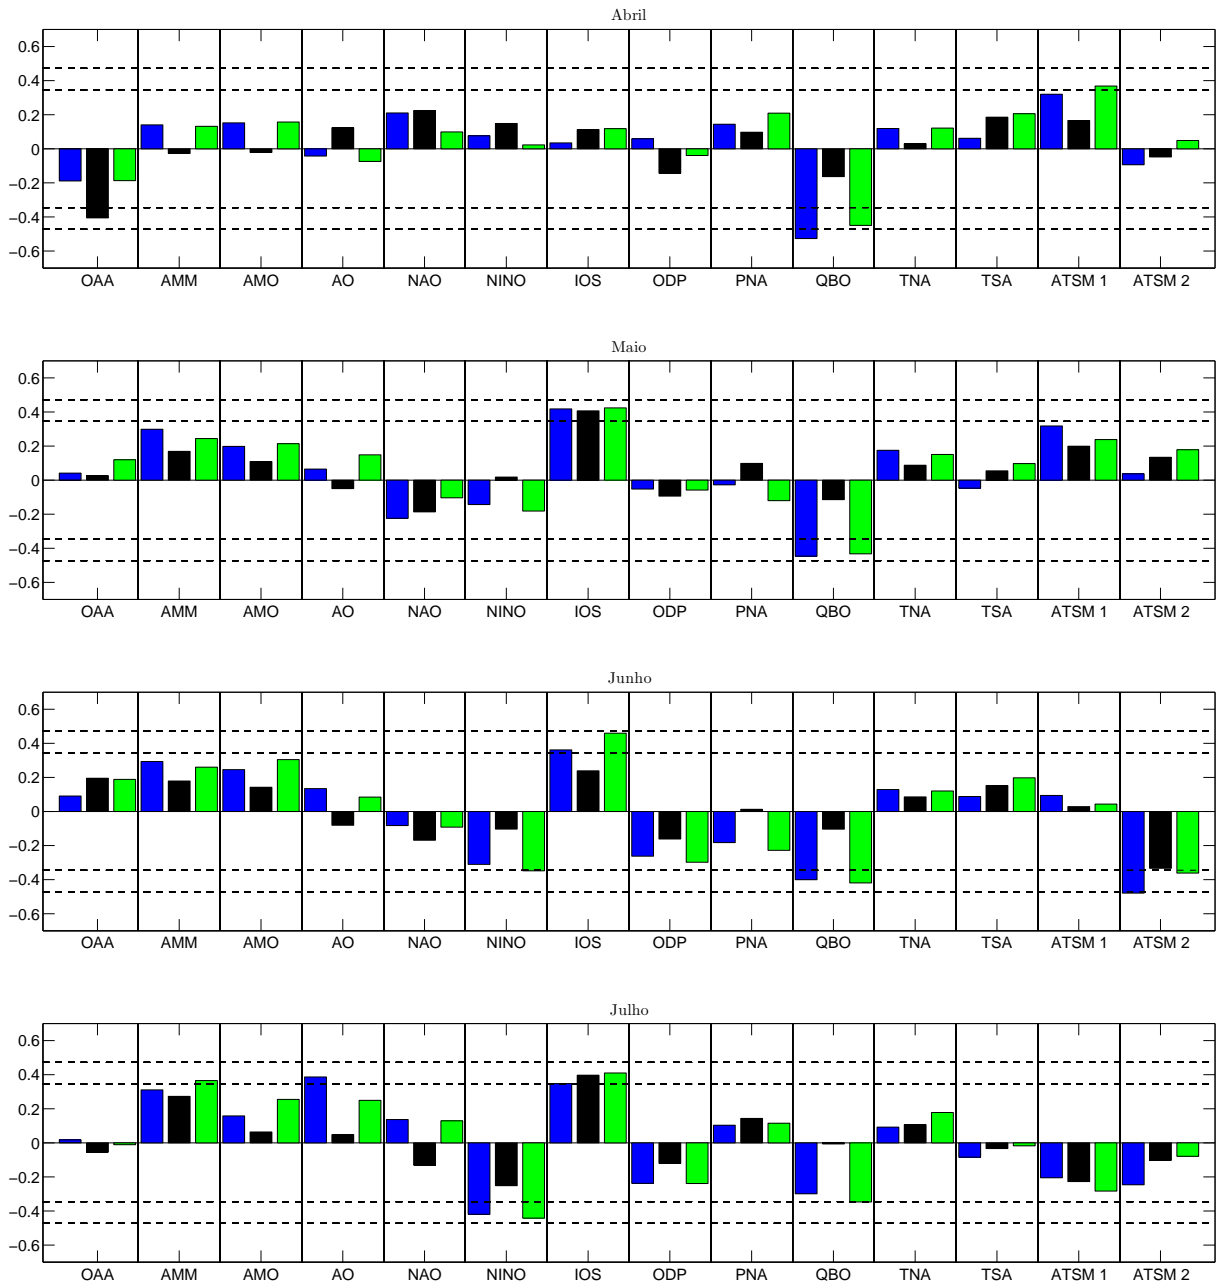
A AMM apresenta correlação positiva com o G3 no mês de julho e com o G1 e G3 em agosto e setembro. A partir do mês de agosto a ODP começa a apresentar significativo e persistente sinal sobre a produtividade de arroz, quando também se destaca o índice oceânico do Niño. Para o G1 e G3 a correlação é significativa a 95% entre os meses de agosto a março. Para o G2, a correlação passa a ser significativa a partir do mês de dezembro e persiste até o mês de março. Quando ODP e ENOS estão em fase, os episódios de El Niño e La Niña podem ser mais intensos e frequentes (KAYANO; ANDREOLI, 1998) e, por este motivo, o sinal negativo da ODP com a produtividade de arroz já era esperado. De fato, Streck et al. (2009) já haviam demonstrado a correlação positiva entre a ODP e a precipitação na região central do RS (G1) nas escalas interanual, sazonal e mensal.

A região do Atlântico delimitada pelos indicadores referentes ao índice ATSM1 passa a apresentar correlação negativa a partir do mês de setembro. O sinal negativo e sua persistência ao longo do desenvolvimento da cultura já eram esperados por conta de sua influência direta na precipitação sobre o Estado (SANTOS; DINIZ, 2014). Entre outubro e março, nota-se a influência da TSA com correlação negativa com a produtividade de arroz nos grupos 1 e 3. O PNA exerce influência negativa para os três grupos em novembro e dezembro e para os grupos 2 e 3 em fevereiro.

A OAA apresenta correlação positiva com o G3 em outubro e com os grupos 1 e 3 no mês de novembro. Este resultado era esperado em virtude de sua relação direta com o avanço de sistemas frontais sobre o RS e, conseqüentemente, influencia na precipitação do Estado (CAVALCANTI; AMBRIZZI, 2009).

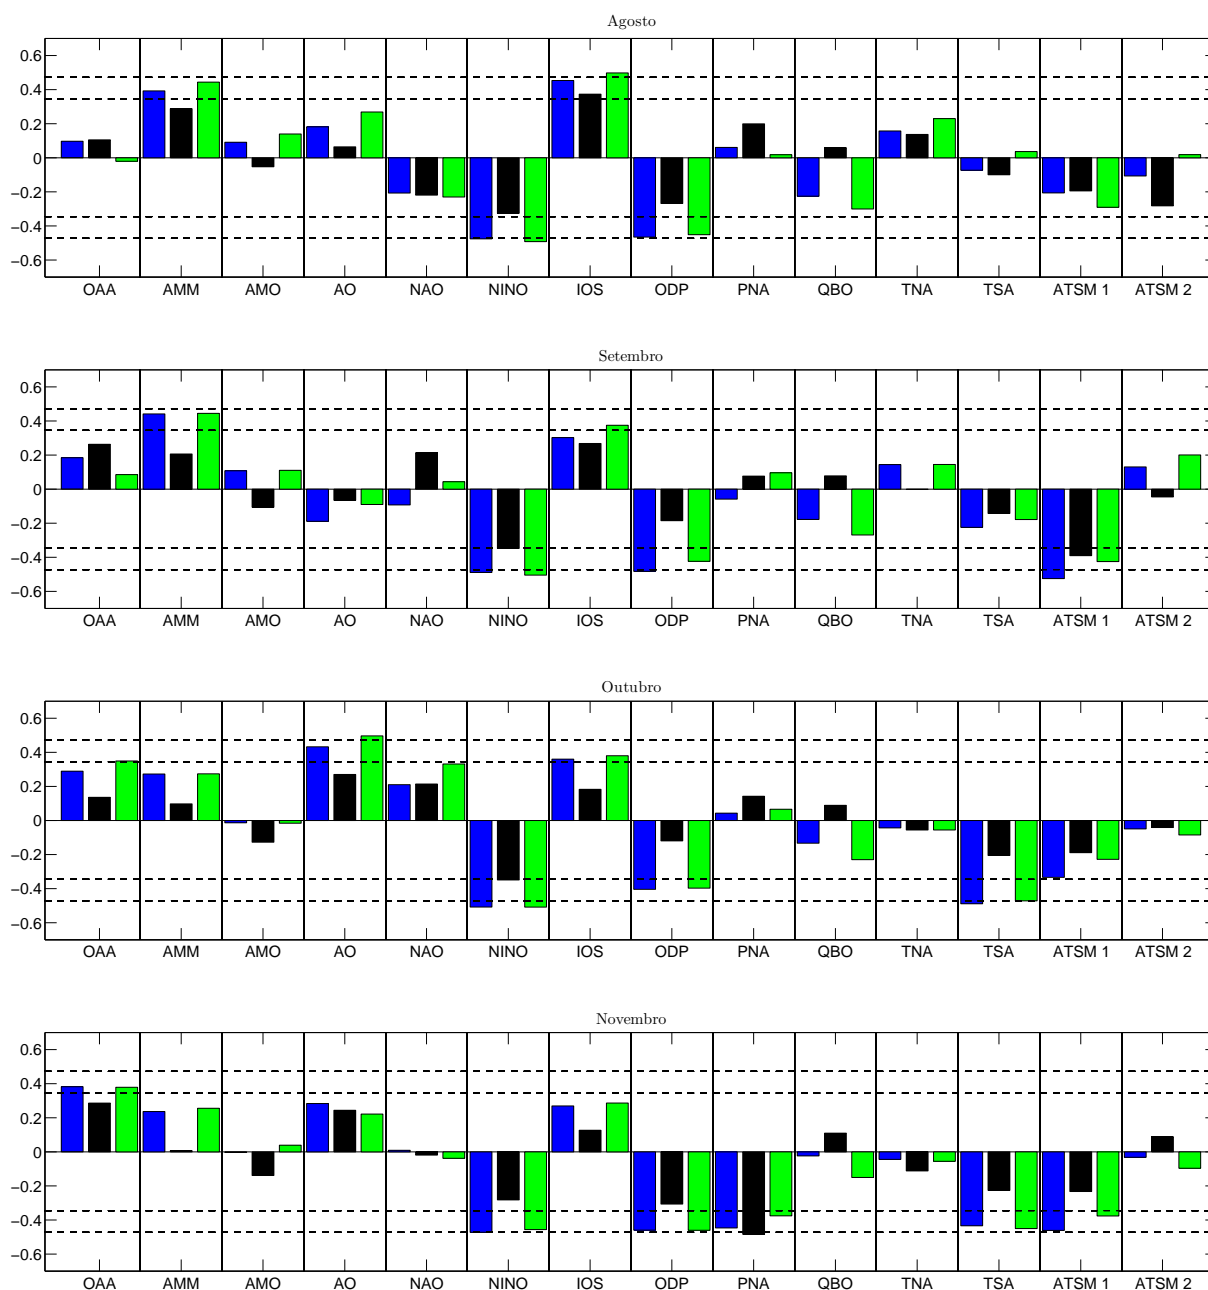
Por fim, nos meses de janeiro a março, nota-se a influência da AMO (correlação negativa) com o G2 para todo o período e com os grupos 1 e 3 apenas para março. A TNA apresenta correlação significativa (negativa) apenas no mês de março com o G1.

Figura 4.27 – Correlação entre os indicadores climáticos e a produtividade de arroz entre abril e julho para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.



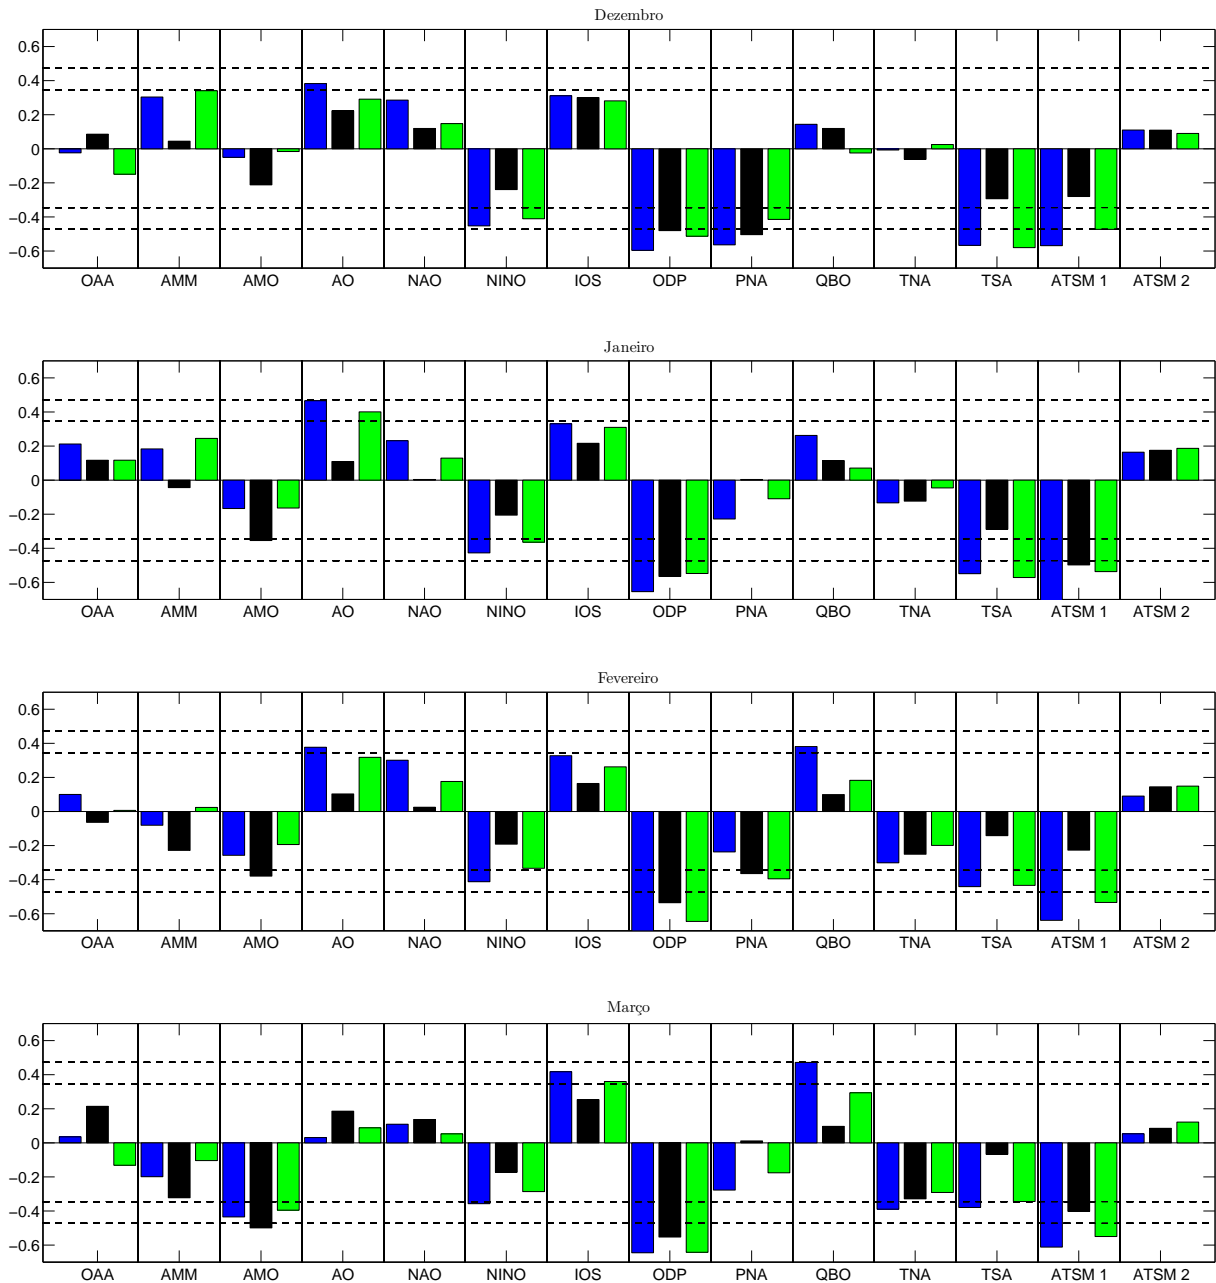
Fonte: Próprio autor.

Figura 4.28 – Correlação entre os indicadores climáticos e a produtividade de arroz entre agosto e novembro para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.



Fonte: Próprio autor.

Figura 4.29 – Correlação entre os indicadores climáticos e a produtividade de arroz entre dezembro e março para os três grupos homogêneos: G1 (azul), G2 (preto) e G3 (verde). As linhas horizontais pontilhadas delimitam os níveis de confiança de 95 e 99%.



Fonte: Próprio autor.

Em comparação com as correlações encontradas para a soja (Figuras 4.3, 4.4 e 4.5), nota-se que para padrões que possuem influência mais direta na precipitação no RS (Niño, IOS, OAA, ATSM1 e ATSM2), como já era esperado, o sinal entre as duas culturas é inverso tendo em vista que uma necessita precipitação durante seu período de desenvolvimento (soja) e a outra, por ser irrigada, apresenta maiores produtividades em períodos mais secos (arroz).

Na Tabela 4.11 consta um resumo dos índices climáticos que apresentaram correlação a um nível de confiança de, no mínimo, 95% com um dos grupos deste estudo e o sinal desta correlação. Assim como para a soja, alguns dos mecanismos físicos responsáveis por tal correlação ainda não são compreendidos o que não inviabiliza a utilização destes índices como ferramenta complementar no momento do planejamento da safra de arroz para o Rio Grande do Sul.

As análises aqui apresentadas demonstram que alguns indicadores climáticos que ainda não haviam sido estudados do ponto de vista de sua influência na variabilidade interanual da produtividade apresentam impacto significativo sobre a cultura do arroz no RS. A utilização de tais índices pode sinalizar um avanço nas estimativas de produtividade bem como melhoras nos preparativos para a safra de arroz no Estado gaúcho.

De uma forma geral, o fenômeno acoplado ENOS apresentou correlações significativas tanto com sua componente oceânica (negativa) quanto atmosférica (positiva), fator este que corrobora estudos prévios sobre a influência de tal fenômeno. A presença de mais indicadores, pode ajudar no desenvolvimento de previsões empíricas mais acuradas. Os padrões de teleconexões climáticos, dependendo de suas fases, podem potencializar alguns impactos.

Dentre os novos índices inseridos neste estudo, destacam-se, principalmente a Oscilação Decadal do Pacífico (correlação negativa) e anomalias de TSM na região do Oceano Atlântico delimitada entre 20°S-30°S e 20°O-40°O (correlação negativa). Embora alguns dos mecanismos físicos responsáveis pelas correlações observadas ainda não sejam compreendidos, o sinal apresentado neste trabalho pode ser levado em conta em previsões e discussões na época de planejamento da safra para, assim, contribuir para melhores estimativas de produtividade de arroz para a metade sul do Rio Grande do Sul.

Tabela 4.11 – Principais resultados obtidos que evidenciam as correlações ao nível de confiança de 95% e o sinal destas correlações entre os índices climáticos mensais e a produtividade média de arroz dos três grupos homogêneos.

	G1	G2	G3
OAA	Nov (+)	Abr (-)	Out (+); Nov (+)
AMM	Ago (+); Set (+)		Jul (+); Ago (+); Set (+)
AMO	Mar (-)	Jan (-); Fev (-); Mar (-)	Mar (-)
AO	Jul (+); Out (+); Dez (+) Jan (+); Fev (+)		Out (+); Jan (+)
NINO	Jul (-); Ago (-); Set (-) Out (-); Nov (-); Dez (-) Jan (-); Fev (-); Mar (-)	Set (-); Out (-)	Jun (-); Jul (-); Ago (-); Set (-); Out (-); Nov (-) Dez (-); Jan(-)
IOS	Mai (+); Jun (+); Jul (+) Ago (+); Out (+); Mar (+)	Mai (+); Jul (+); Ago (+)	Mai (+); Jun (+); Jul (+) Ago (+); Set (+); Out (+) Mar (+)
ODP	Ago (-); Set (-); Out (-) Nov (-); Dez (-); Jan (-) Fev (-); Mar(-)	Dez (-); Jan (-); Fev (-) Mar (-)	Ago (-); Set (-); Out (-) Nov (-); Dez (-); Jan (-) Fev (-); Mar(-)
PNA	Nov (-); Dez (-)	Nov (-); Dez (-); Fev (-)	Nov (-); Dez (-); Fev (-)
QBO	Abr (-); Mai (-); Jun (-) Fev (+); Mar (+)		Abr (-); Mai (-); Jun (-) Jul (-);
TNA	Mar (-)		
TSA	Out (-); Nov (-); Dez (-) Jan (-); Fev (-); Mar (-)		Out (-); Nov (-); Dez (-) Jan (-); Fev (-); Mar (-)
ATSM1	Set (-); Nov (-); Dez (-) Jan (-); Fev (-); Mar (-)	Set (-); Jan (-); Mar (-)	Abr (+); Set (-); Nov (-) Dez (-); Jan (-); Fev (-) Mar (-)
ATSM2	Jun (-)		Jun (-)

4.2.3 Influência das Anomalias de TSM na Variabilidade Interanual da Produtividade de Arroz no Rio Grande do Sul

As Figura 4.30 a 4.41 apresentam as correlações entre as anomalias de Temperatura da Superfície do Mar no Oceano Global com a produtividade de arroz para os três grupos homogêneos.

No mês de abril (Figura 4.30), nota-se uma região de correlações negativas com a produtividade de arroz nos três grupos no Oceano Índico, próxima a 40 °S/60 °E. Destaca-se

também, para o G2, uma região de correlações negativas no Oceano Atlântico Norte. Por fim, para os três grupos, é notada uma região de correlações positivas próxima a Antártica, ao sul de 60°S.

As anomalias de TSM do mês de maio (Figura 4.31) apresentam correlações mais baixas com a variabilidade de produtividade de arroz no RS destacando-se, apenas, uma região de correlações negativas com os Grupos 1 e 3 próxima a 60°S/45°W e a manutenção de uma região de correlações negativas com o G2 a sudeste da África.

A partir do mês de junho (Figura 4.32), fica evidente a importância do Oceano Pacífico Equatorial na produtividade de arroz (correlações negativas) como já era esperado em virtude das elevadas correlações apresentadas pelo índice NINO (correlação negativa) nas Figuras 4.27 a 4.29, especialmente, para os Grupos 1 e 3. Para o G2, destaca-se também uma região do Oceano Índico, aproximadamente 30°S/70°W, com correlações positivas com a produtividade.

Entre setembro (Figura 4.35) e março (Figura 4.41), nota-se também a intensificação da influência do Oceano Atlântico Tropical Sul (correlação negativa) com a produtividade de arroz dos Grupos 1 e 3 e em menor intensidade com o Grupo 2. Estes resultados acompanham as correlações negativas encontradas, principalmente, com a TSA nas Figuras 4.28 e 4.29. Ainda a partir de setembro (Figura 4.35), nota-se uma região do Oceano Pacífico, próxima a 30°S/160°W com correlações positivas com a produtividade de arroz.

Entre outubro (Figura 4.36) e março (Figura 4.41), o Oceano Pacífico Norte passa a apresentar elevada correlação (positiva) com a produtividade de arroz para os três grupos homogêneos. O Oceano Pacífico também apresenta uma ampla área de correlações negativas com a produtividade de arroz próxima a 50°S/120°W.

Entre novembro (Figura 4.37) e março (Figura 4.41), o Oceano Atlântico Sul, próximo a 45°S/25°W apresenta correlações positivas com os três grupos, mas mais intensa e ampla com o G3. A partir de dezembro (Figura 4.38), a região Tropical do Oceano Índico também passa a apresentar elevada correlação negativa com a produtividade de arroz para os três grupos.

Figura 4.30 – Correlação entre anomalia da temperatura da superfície do mar no mês de abril e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

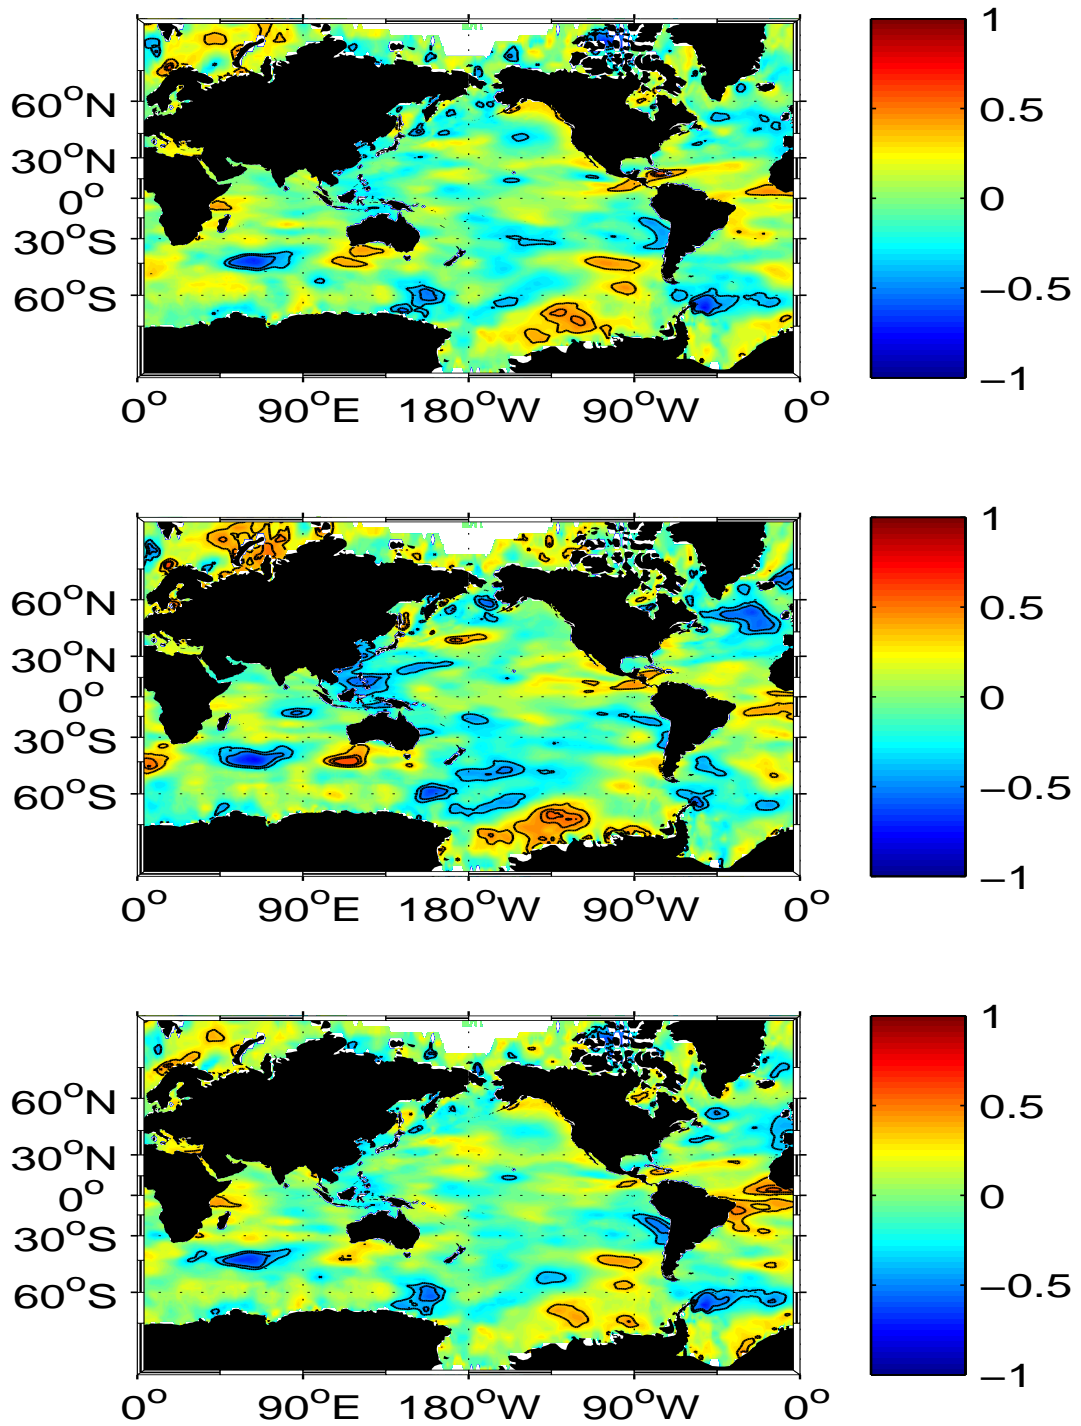


Figura 4.31 – Correlação entre anomalia da temperatura da superfície do mar no mês de maio e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

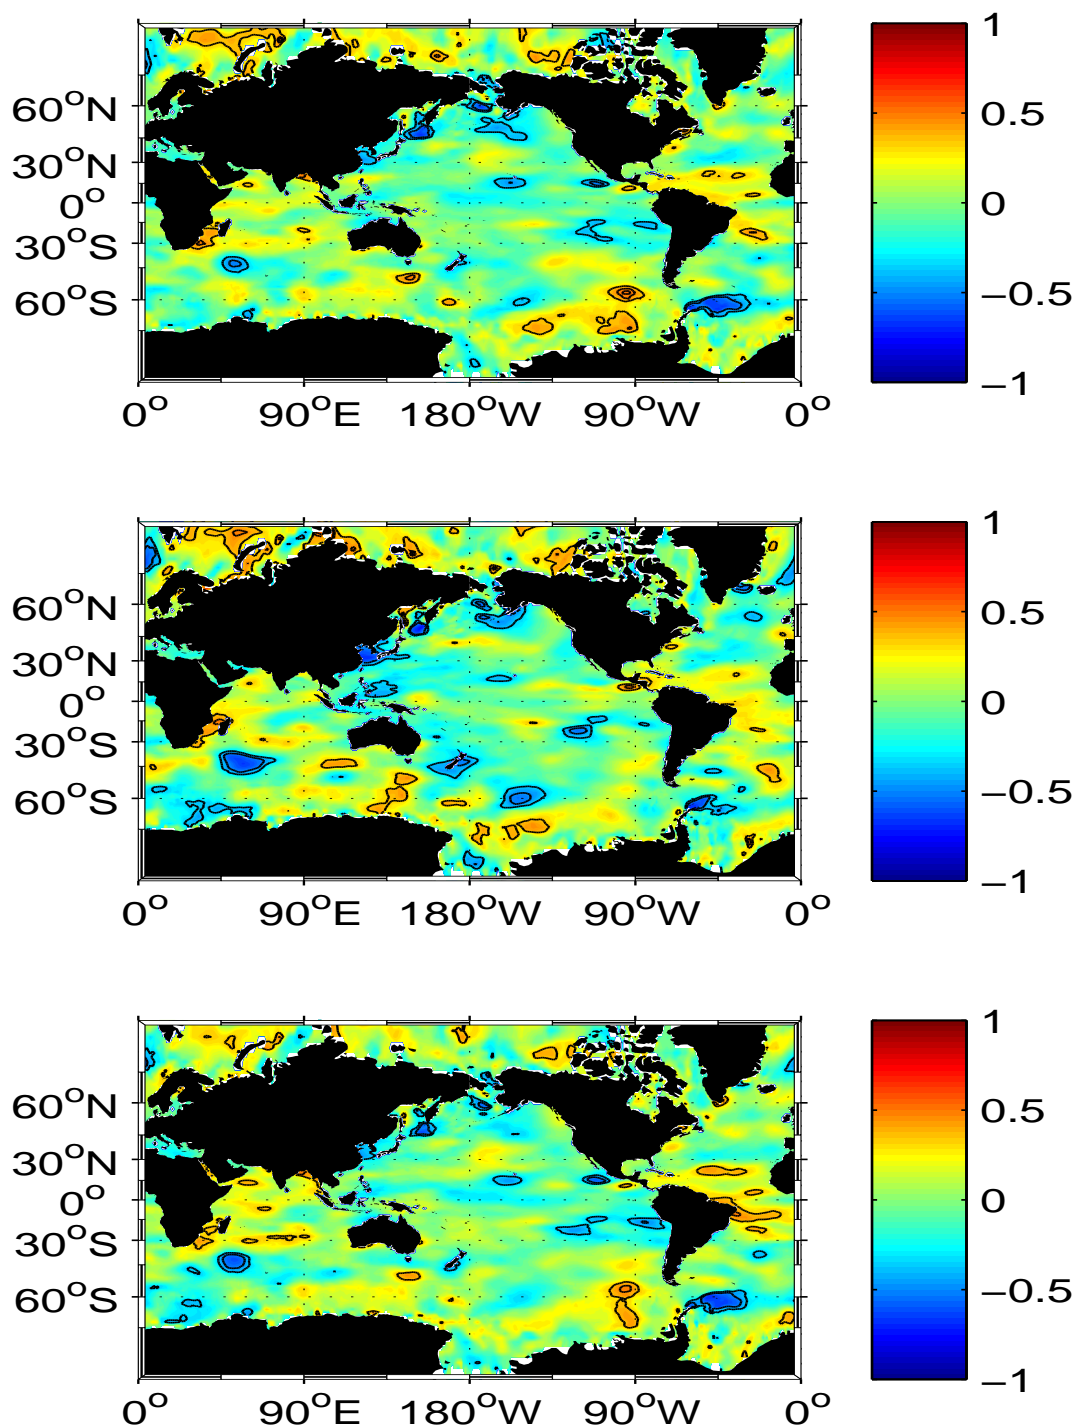


Figura 4.32 – Correlação entre anomalia da temperatura da superfície do mar no mês de junho e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

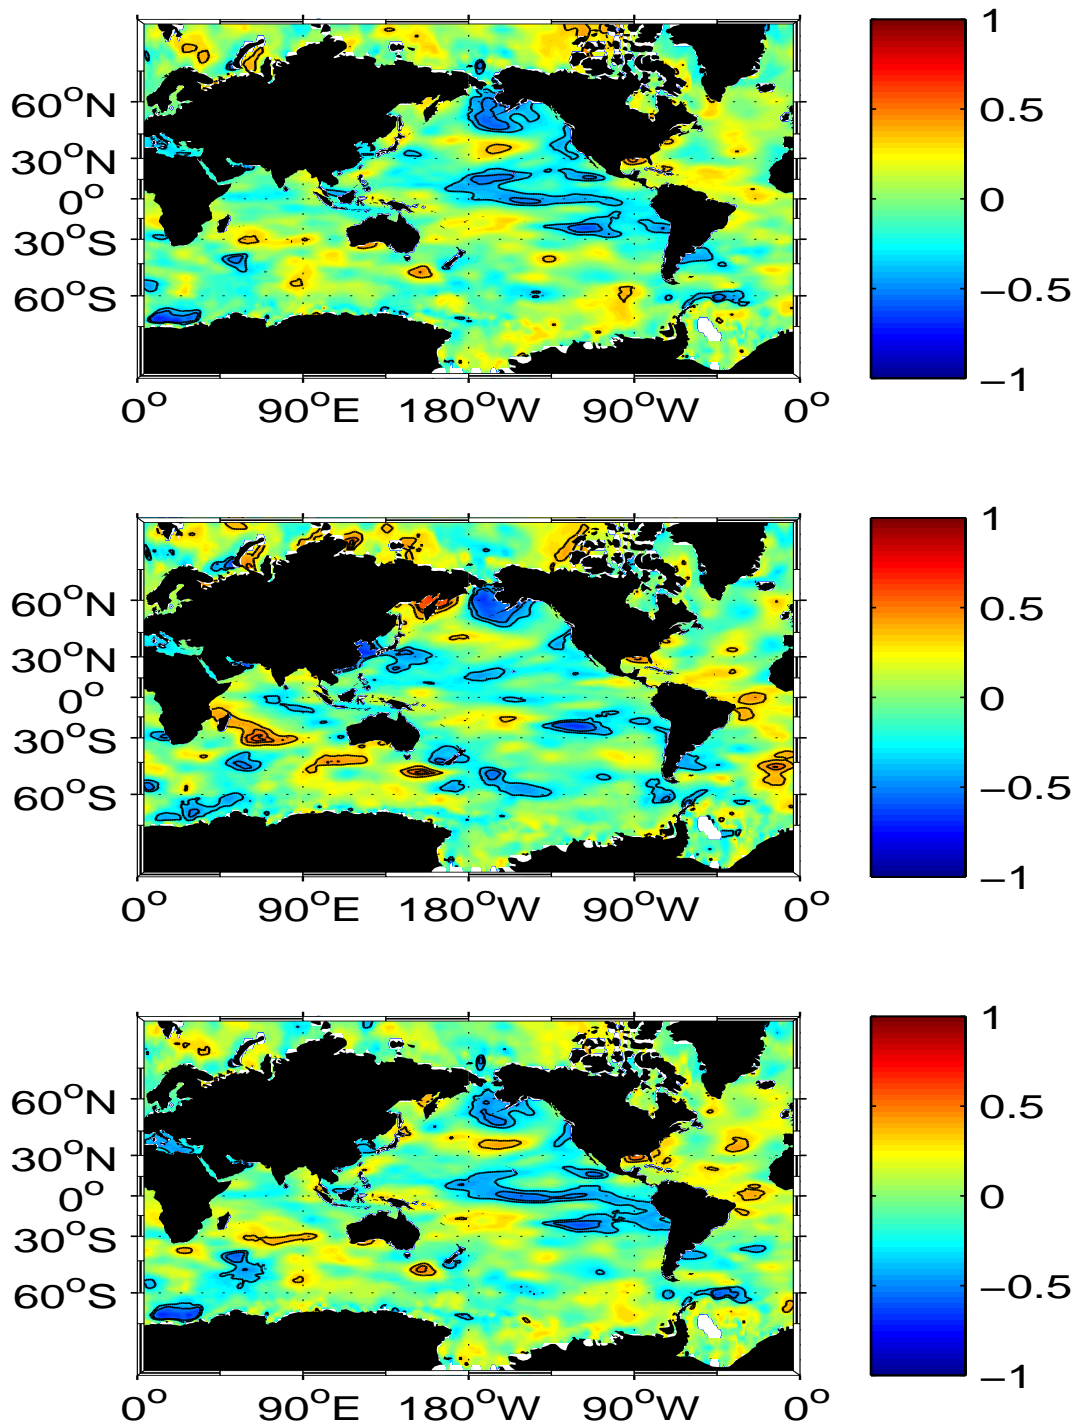


Figura 4.33 – Correlação entre anomalia da temperatura da superfície do mar no mês de julho e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

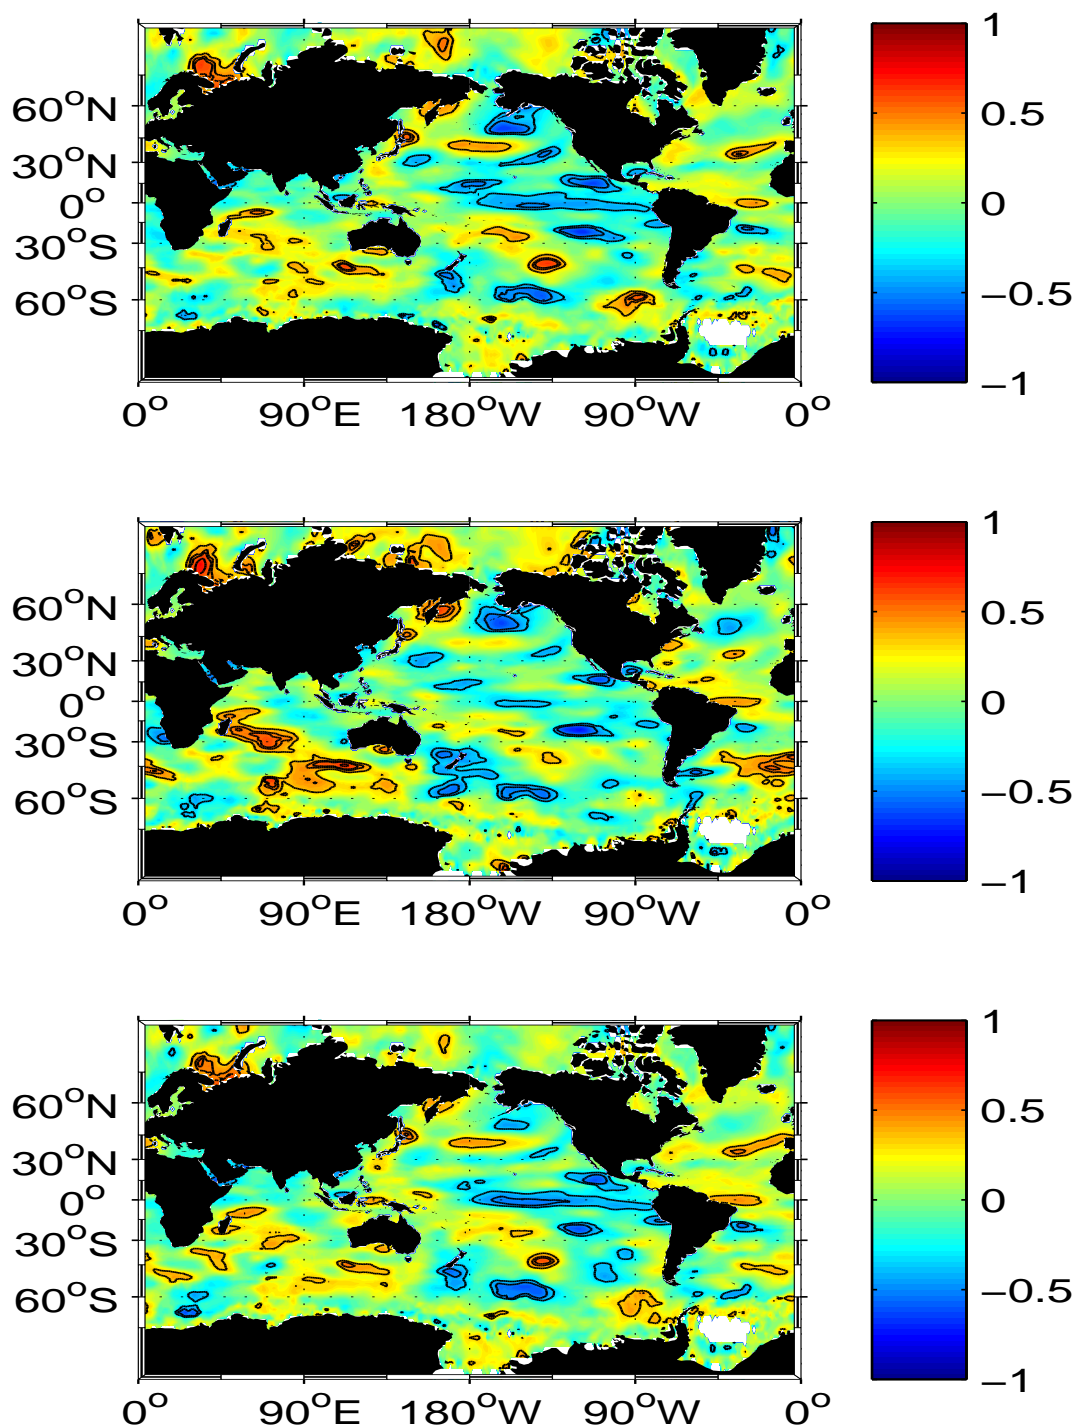


Figura 4.34 – Correlação entre anomalia da temperatura da superfície do mar no mês de agosto e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

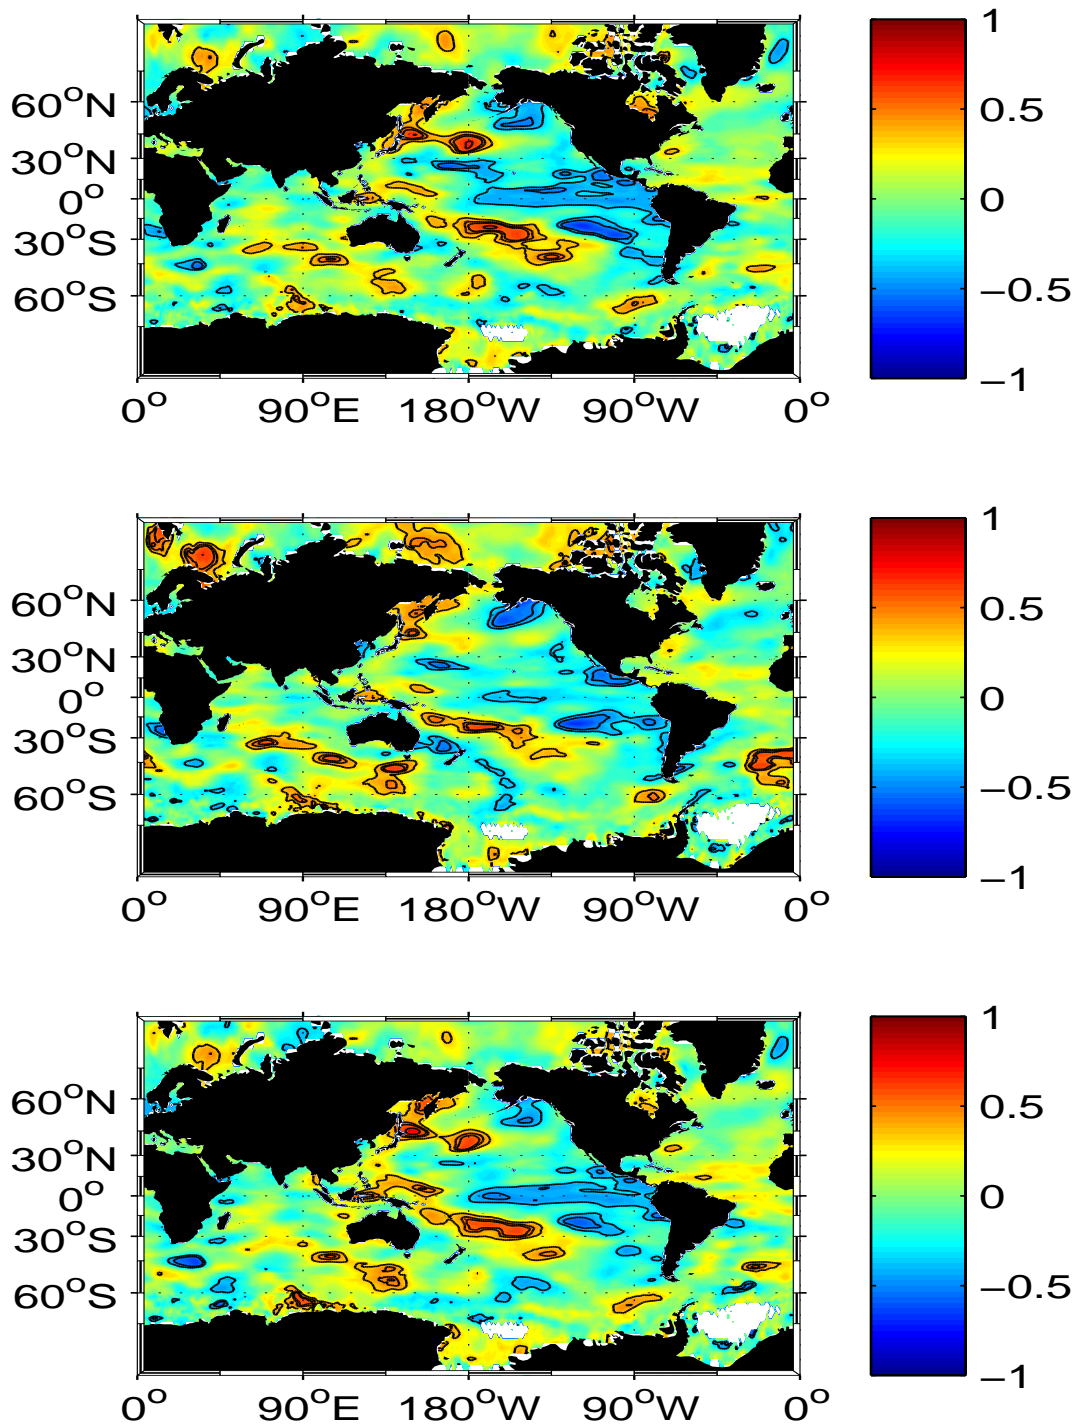


Figura 4.35 – Correlação entre anomalia da temperatura da superfície do mar no mês de setembro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

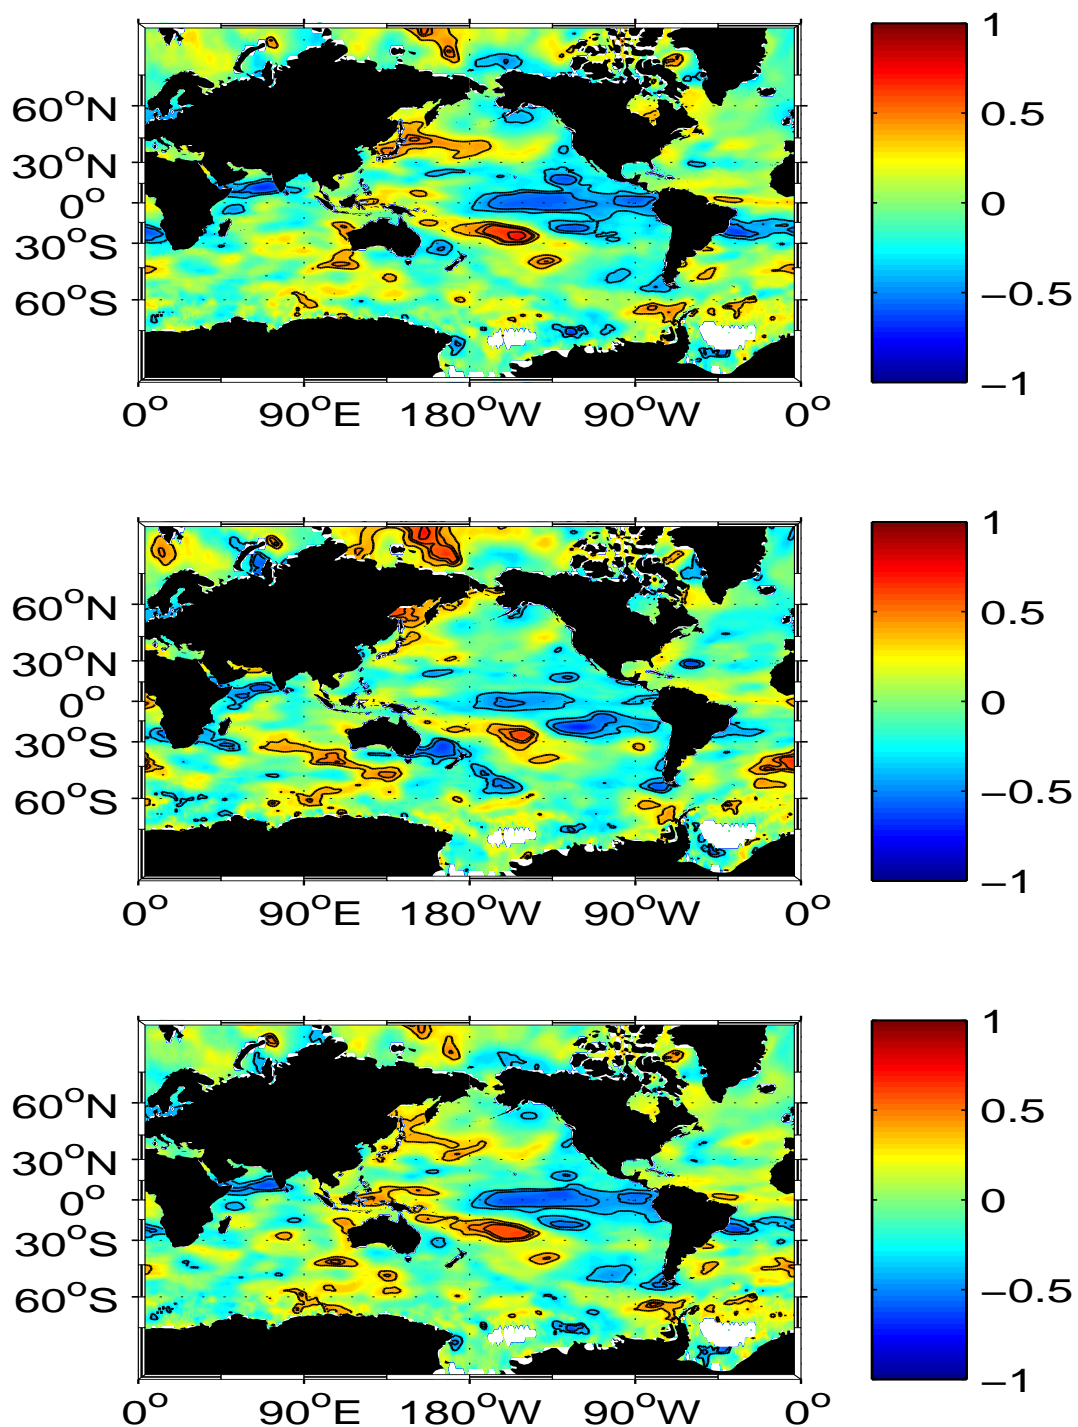


Figura 4.36 – Correlação entre anomalia da temperatura da superfície do mar no mês de outubro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

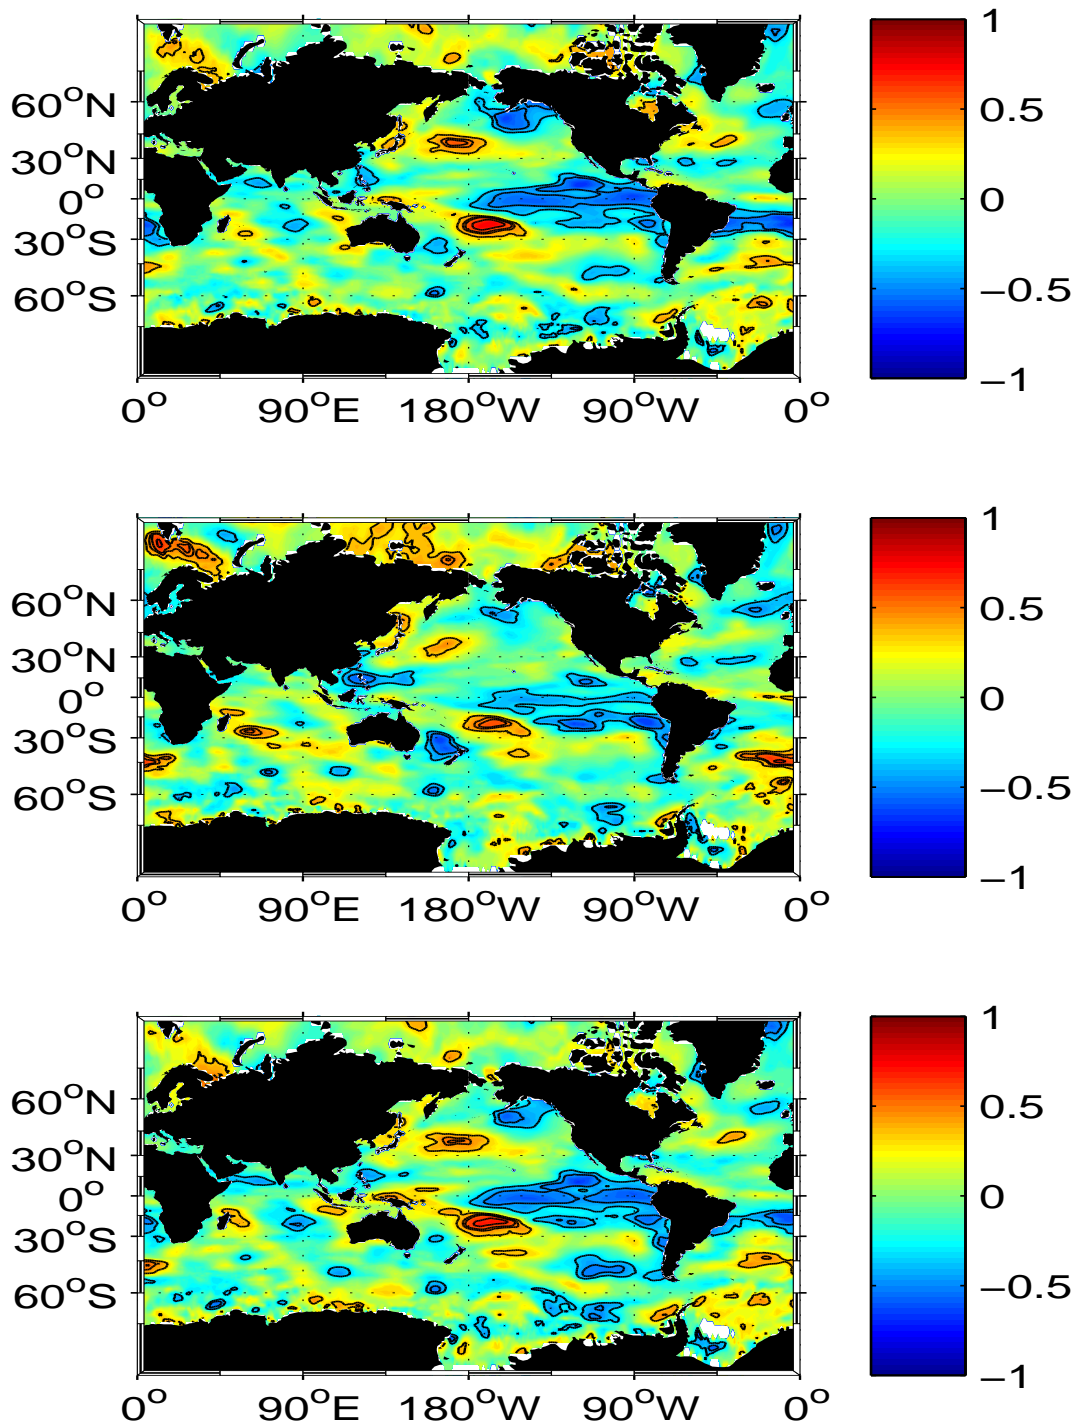


Figura 4.37 – Correlação entre anomalia da temperatura da superfície do mar no mês de novembro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

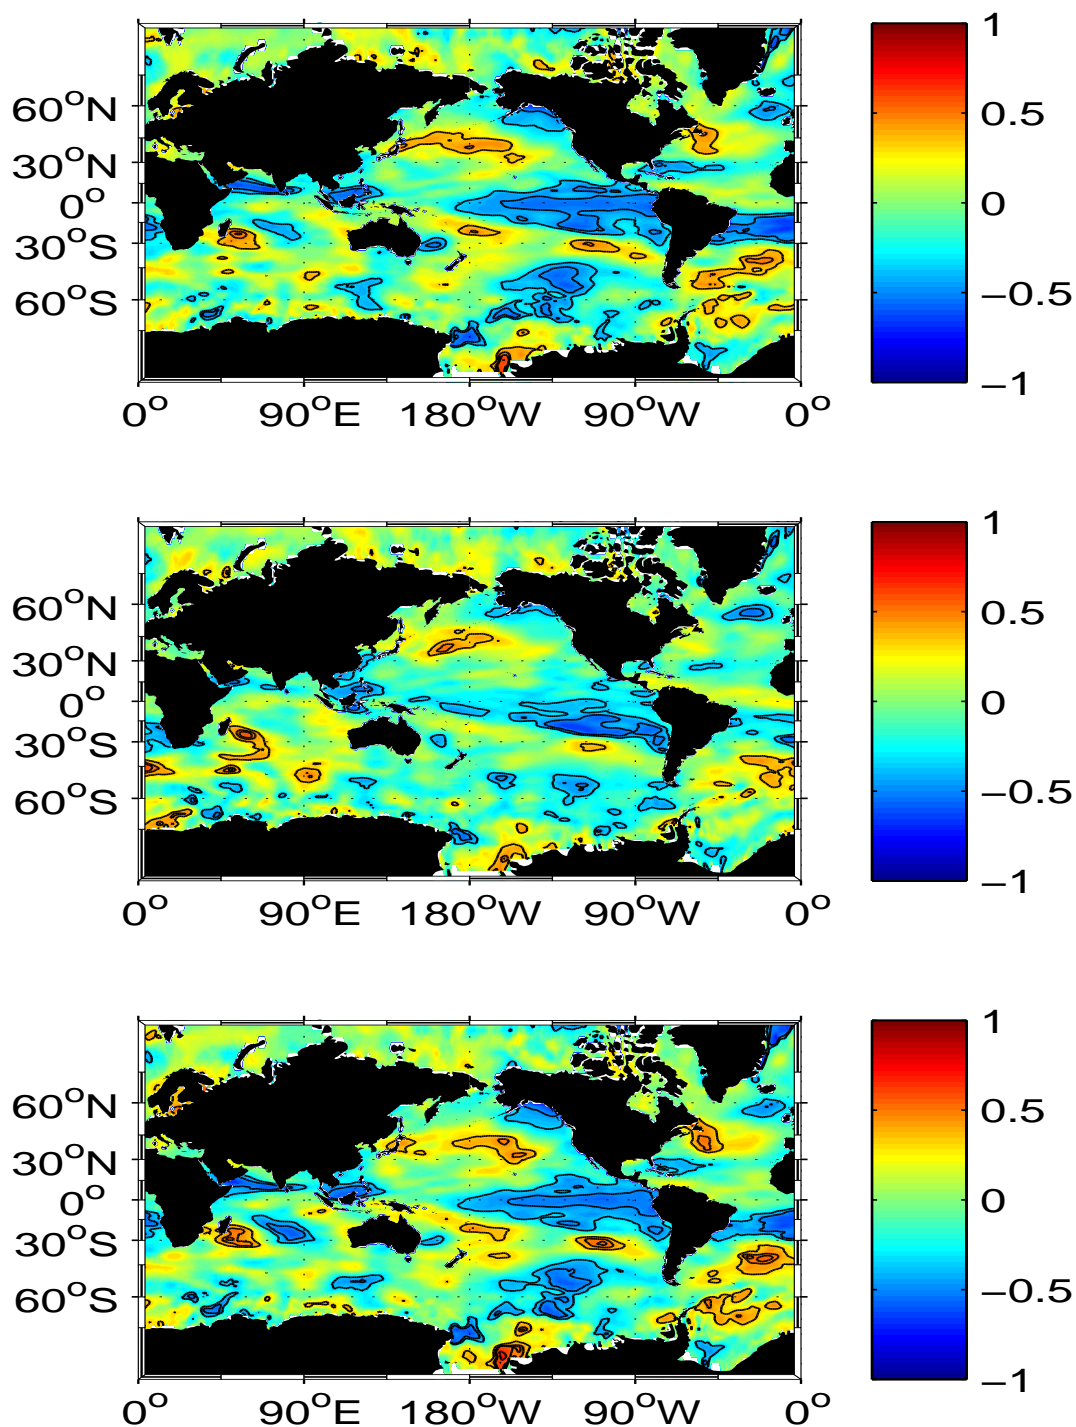


Figura 4.38 – Correlação entre anomalia da temperatura da superfície do mar no mês de dezembro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

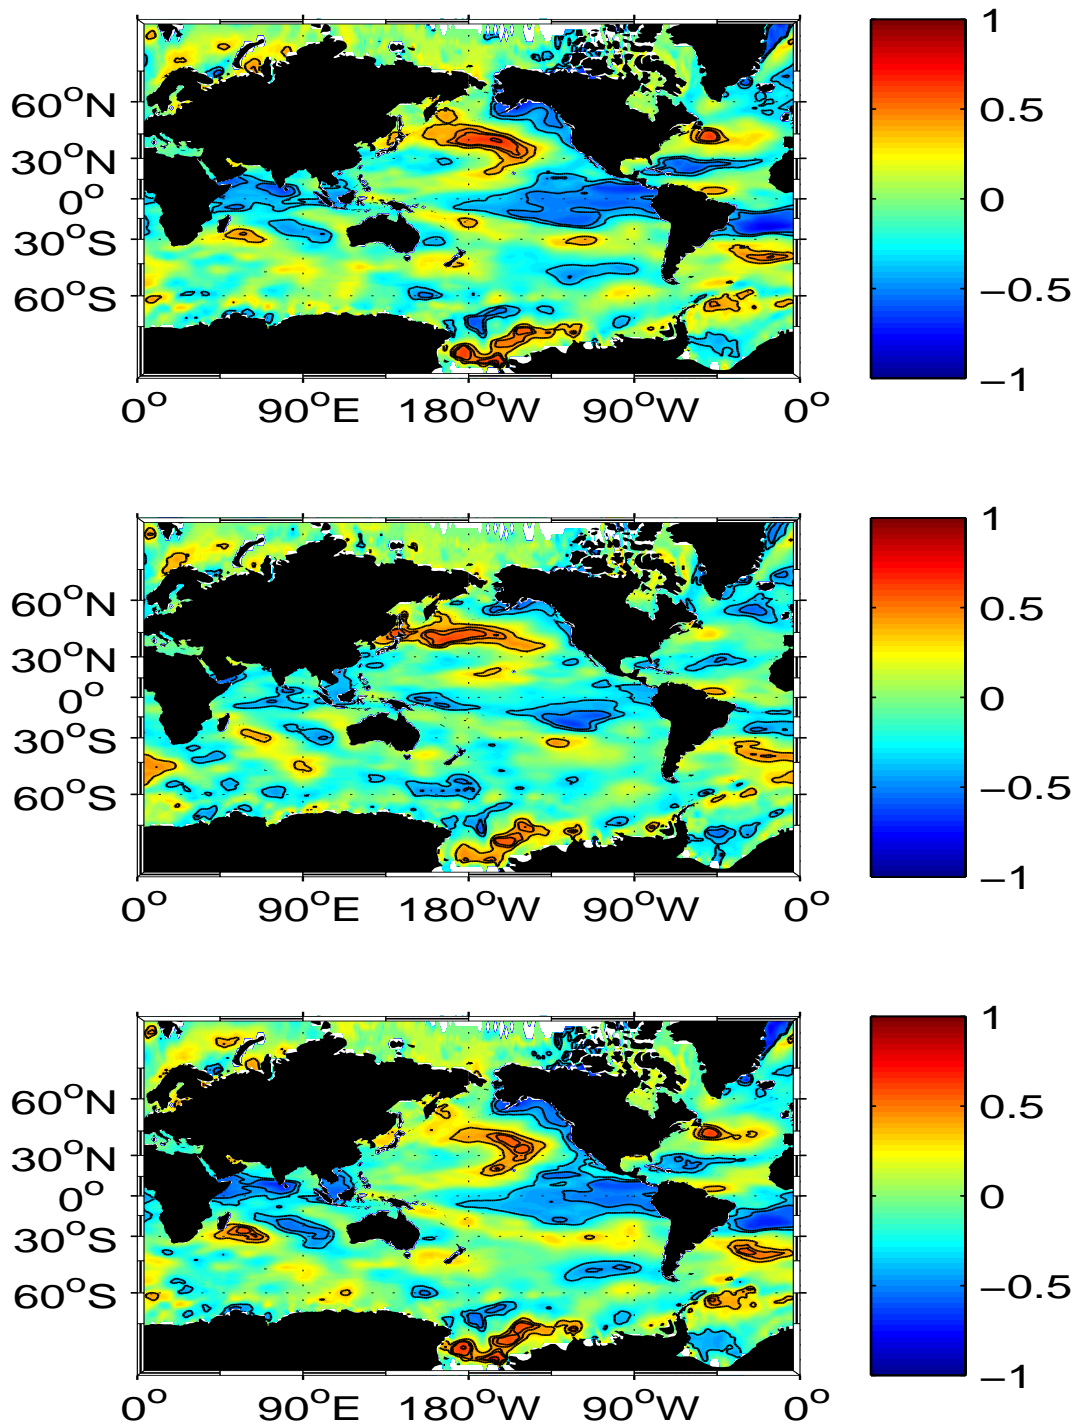


Figura 4.39 – Correlação entre anomalia da temperatura da superfície do mar no mês de janeiro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

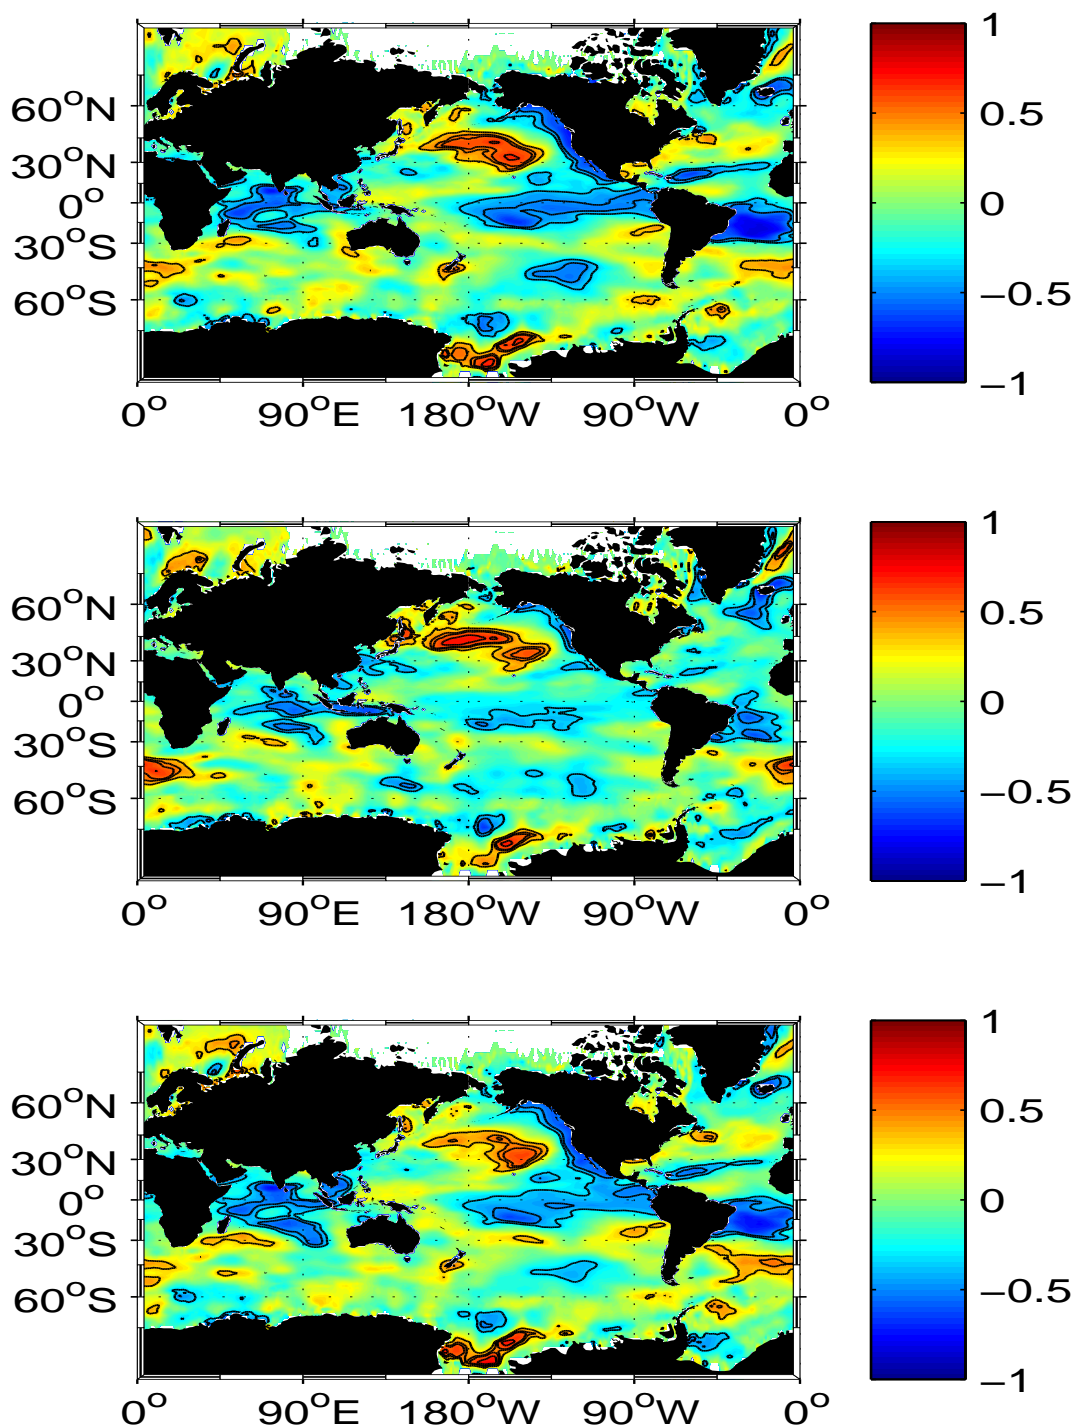


Figura 4.40 – Correlação entre anomalia da temperatura da superfície do mar no mês de fevereiro e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.

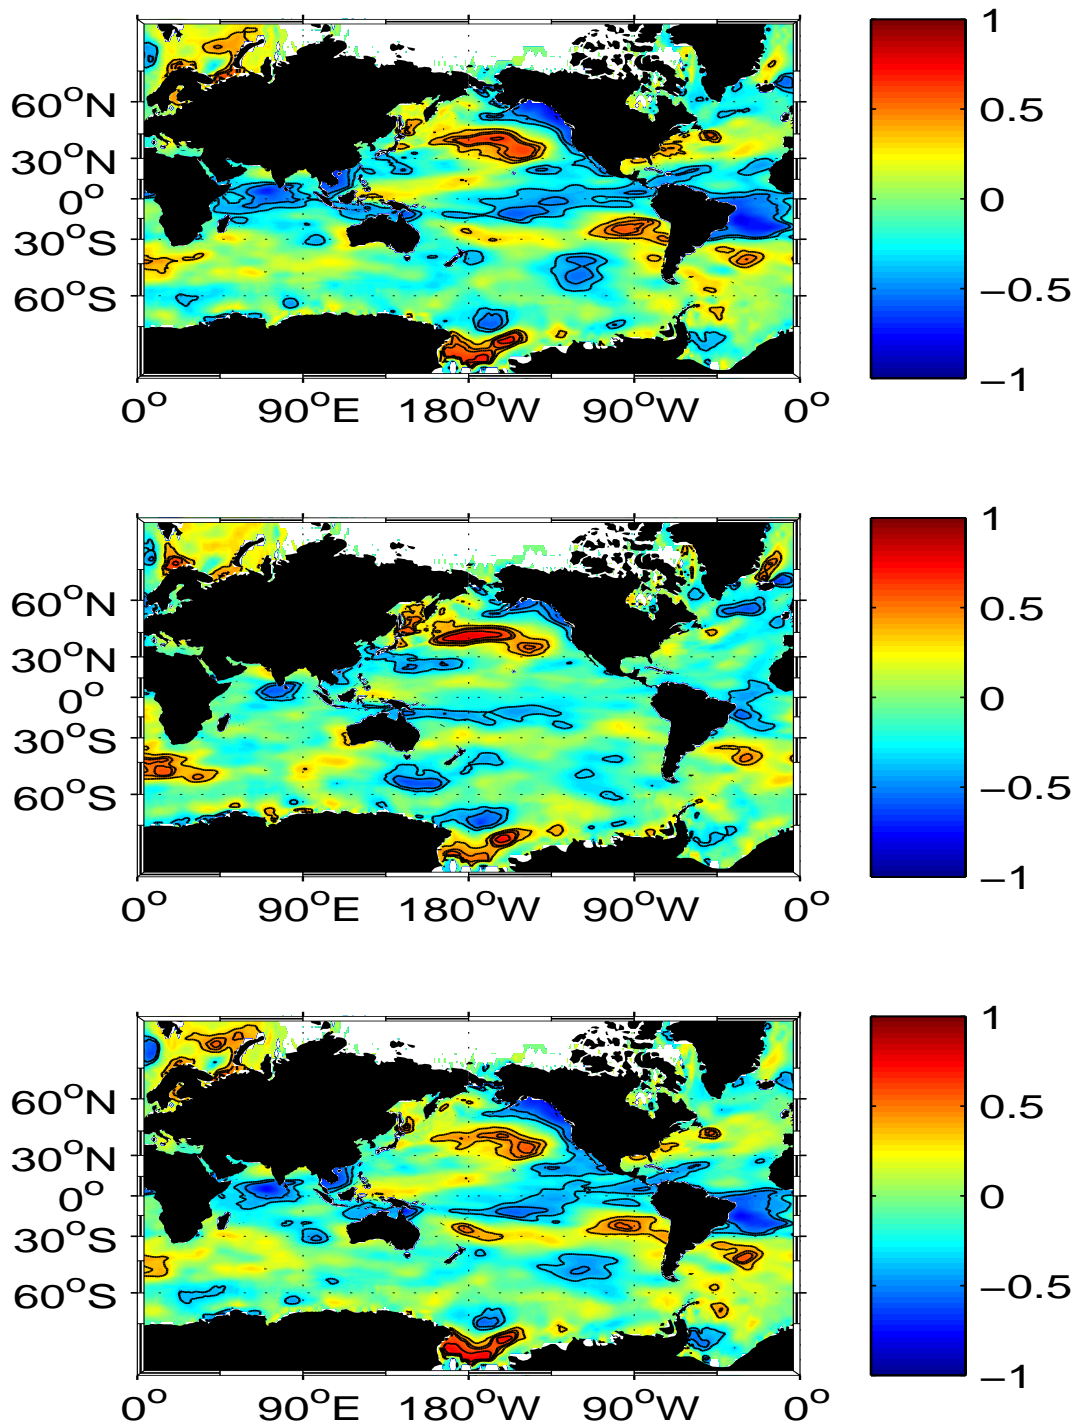
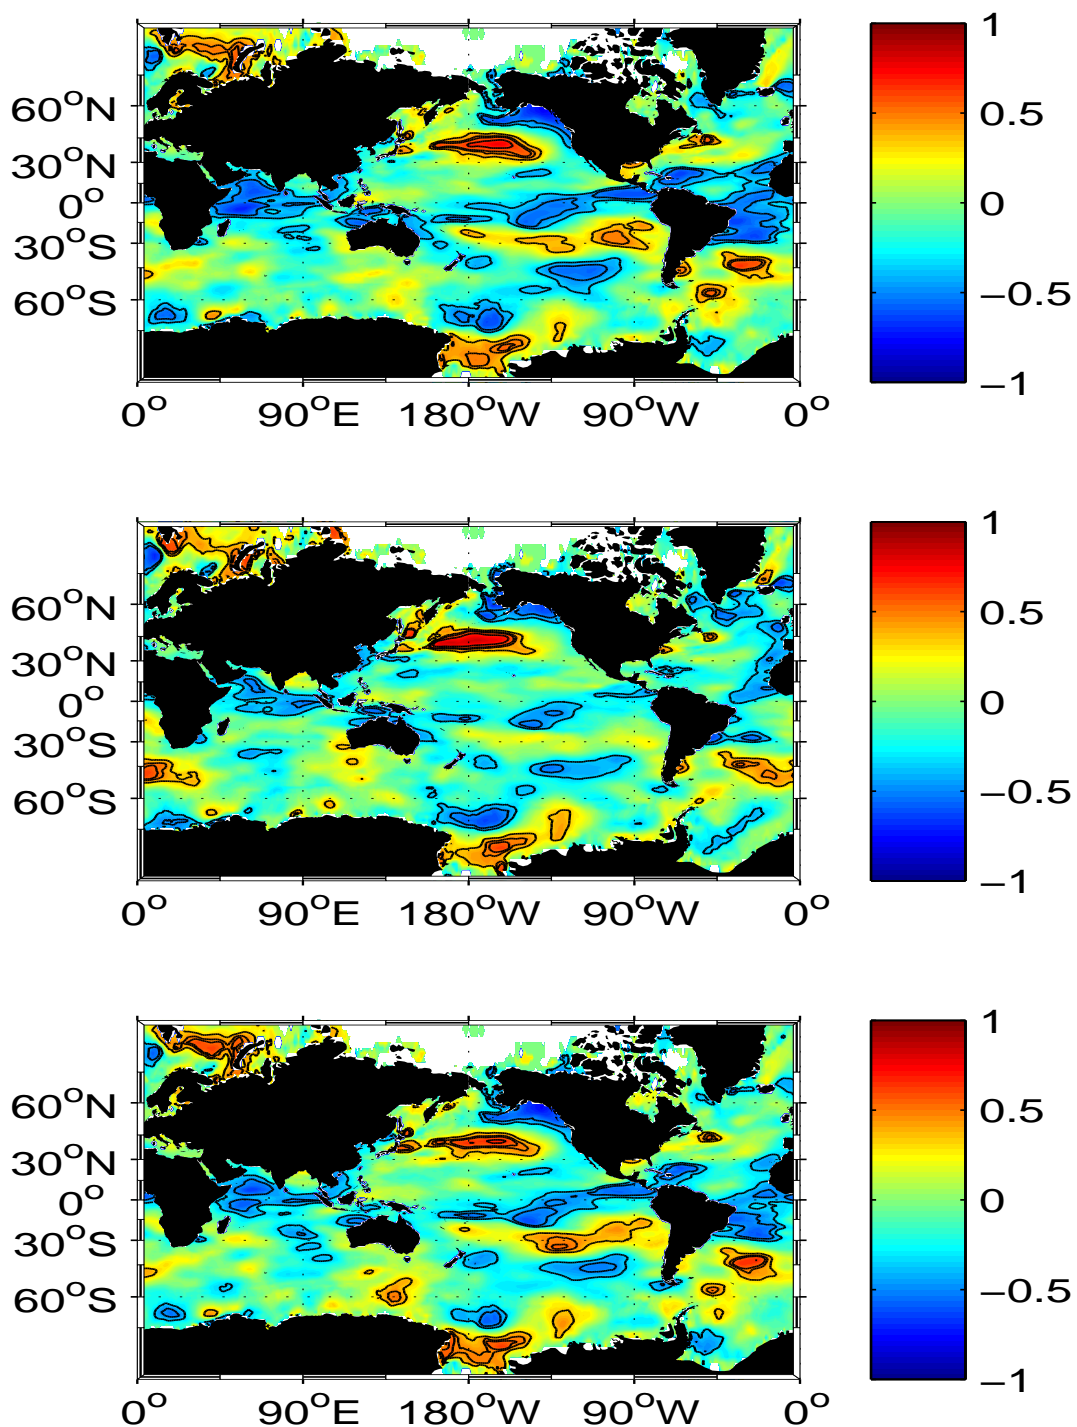


Figura 4.41 – Correlação entre anomalia da temperatura da superfície do mar no mês de março e produtividade de arroz para os Grupos 1 (painel superior), 2 (painel intermediário) e 3 (painel inferior). As linhas pretas sólidas delimitam os níveis de confiança de 95% e 99%.




4.2.4 Previsão Estatística - G1 Arroz

4.2.4.1 Preditores Seleccionados

O Grupo 1 do arroz, grupo de menor produtividade média, foi o único em que foi possível realizar uma previsão com razoável destreza apenas com indicadores climáticos já reconhecidos na literatura e listados na Seção 3.2. A lista de preditores seleccionados para diferentes defasagens encontra-se na Tabela Q.1.


Dada a relação dos índices seleccionados para a previsão de produtividade do G1 do arroz, fica evidente a importância da região do Oceano Atlântico destacada por Santos e Diniz (2014) (ATSM1) no mês de setembro. Este índice é o principal preditor para os três primeiros modelos (outubro a dezembro) em virtude da sua correlação positiva com a precipitação no RS e, conseqüentemente, negativa com a produtividade de arroz. Nesta faixa do Oceano Atlântico Sul, anomalias positivas (negativas) de TSM estão associadas a desvios negativos (positivos) de produtividade de arroz no G1 em 78% (60%) dos casos (Figura 4.42). Essa mesma região continua sendo utilizada como preditora nos meses de janeiro (anomalias de dezembro) fevereiro e março (anomalias de janeiro) demonstrando a necessidade de monitoramento desta faixa oceânica ao longo do cultivo do arroz na Região Central e nas Planícies Costeiras Interna e Externas a Lagoa dos Patos (Figura 4.25).

Figura 4.42 – Relação entre anomalias de TSM no mês de setembro na região delimitada por Santos e Diniz (2014) (ATSM1) e anomalias de produtividade de arroz no Grupo 1. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) de TSM nessa região.



As primeiras projeções de produtividade de arroz no G1 poderiam se basear no índice da QBO do mês de abril (lag 11) que é o segundo preditor utilizado nos modelos dos meses de outubro, novembro e dezembro. No mês de abril, em, aproximadamente, 73% (62%) dos casos em que a QBO apresentou sinal negativo (positivo) ocorreu produtividade acima (abaixo) da média no G1 (Figura 4.43). Próximo as fases críticas da cultura (janeiro a março) os índices referentes a ODP passam a se comportar como bons indicadores.

Figura 4.43 – Relação entre o índice do mês de abril referente a Oscilação Quase-Bienal e anomalias de produtividade de arroz no Grupo 1. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) do índice.



Fonte: Próprio autor.

4.2.4.2 Validação Cruzada

Com base na Tabela de destreza do modelo (Tabela 4.12), nota-se que a medida que são adicionados índices preditores mais próximos aos períodos críticos da cultura (índices com maior correlação), há uma redução do RMSE. Além disso, destaca-se que em todas as projeções o RMSE é inferior ao desvio padrão da série histórica (456,39 kg/h). Apesar disso, a taxa de acerto da previsão por tercís é inferior a 60% para os modelos de novembro e janeiro. Nota-se também que o modelo de novembro é o único que tende a subestimar a produtividade (Tabela 4.12 e Figura 4.44) sendo também o que apresenta a menor destreza quando analisado o Viés. Desta forma, a previsão do mês de novembro é a que requer maiores cuidados quando utilizada.

Figura 4.44 – Comparação entre a produtividade média do arroz do Grupo 1 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.

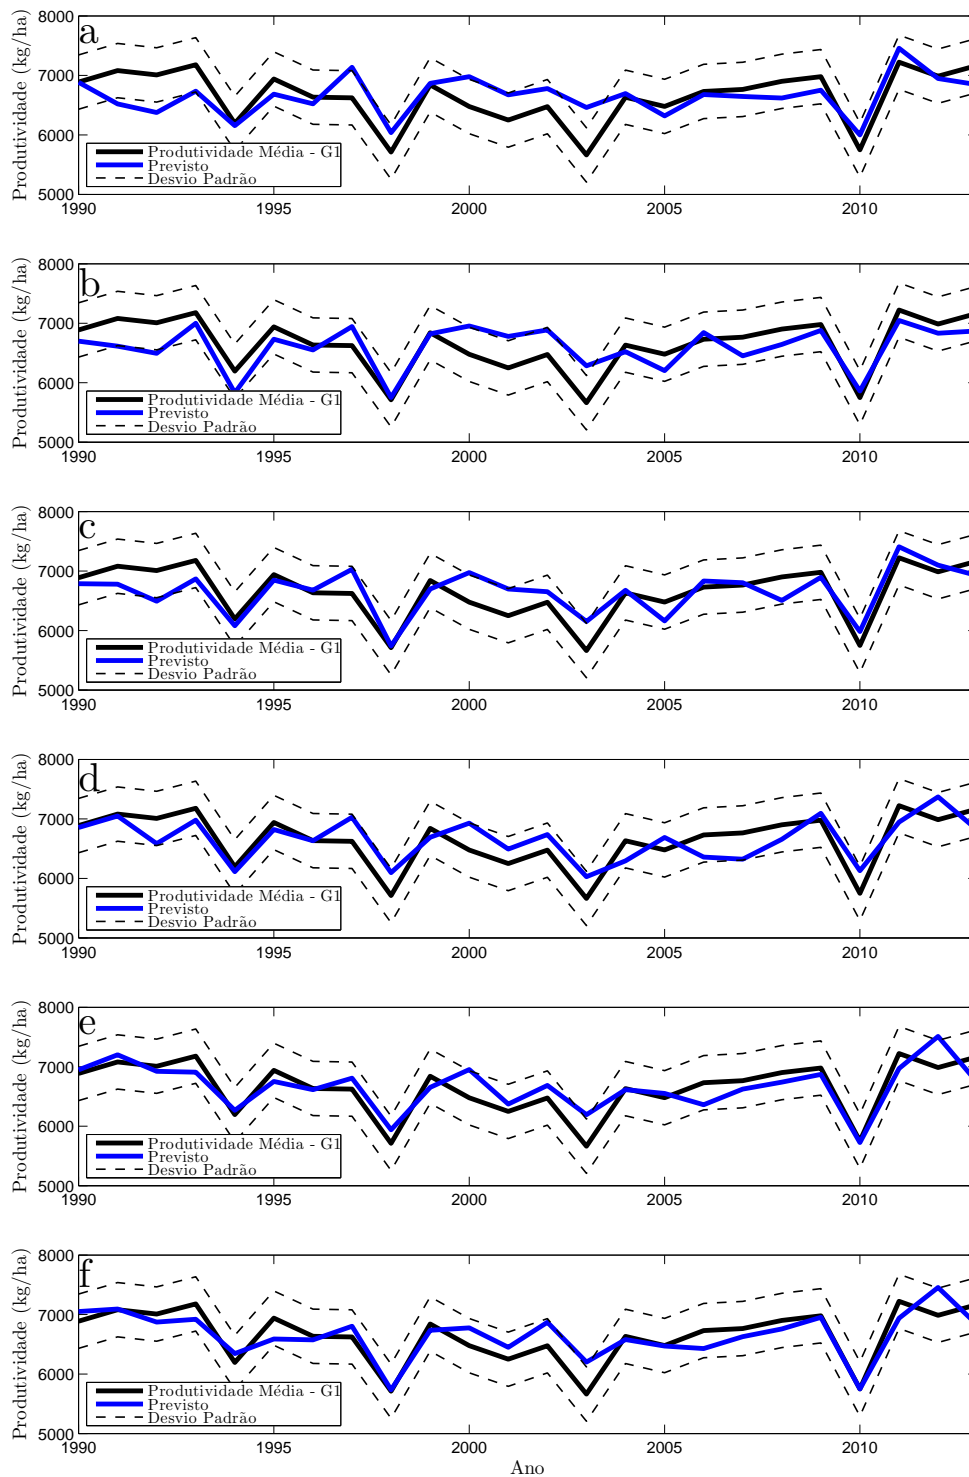


Tabela 4.12 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo do arroz referente ao Grupo 1 para as previsões dos meses de outubro a março.

	Corr.	Viés	RMSE	Taxa de Acerto
OUT	0,63	8,05	348,69	62,5%
NOV	0,73	-45,1	311,63	54,17%
DEZ	0,79	7,99	276,05	62,5%
JAN	0,75	5,71	295,53	58,33%
FEV	0,82	14,41	253,88	70,83%
MAR	0,84	9,31	244,02	79,17%

4.2.5 Previsão Estatística - G2 Arroz


4.2.5.1 *Preditores Seleccionados*

Os índices utilizados como preditores do modelo do G2 de arroz estão listados na Tabela R.1.

A lista de preditores utilizados demonstra a importância das anomalias de TSM do Oceano Pacífico no mês de setembro, próxima a 19°S/121°W, onde a correlação negativa é elevada. Esta região oceânica é o principal preditor de outubro a janeiro e também é inserida nos modelos de fevereiro e março. Anomalias positivas (negativas) de TSM na área que define este indicador estão associadas a diminuição (aumento) da produtividade de arroz no G2 em 67%(67%) dos casos (Figura 4.45).

Anomalias de TSM no Oceano Índico no mês de julho, próximas a 30°S/70°E, também exercem forte influência (correlação positiva) sobre a produtividade de arroz no G2 tendo em vista que esta região é inserida como preditora nos modelos de outubro a março.

Figura 4.45 – Relação entre anomalias de TSM no mês de setembro na região oceânica próxima a 19°S/121°W e anomalias de produtividade de arroz no Grupo 2. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) de TSM nessa região.



Fonte: Próprio autor.

4.2.5.2 Validação Cruzada

Na Figura 4.46 e na Tabela 4.13 estão contidas as séries previstas de cada mês em comparação com a série de produtividade média do grupo e as medidas de destreza dos modelos de outubro a março para o G2 do arroz. Nota-se que o modelo elaborado para este grupo apresenta um baixo Viés para todas projeções e também um baixo valor de RMSE. Também pode-se observar uma taxa de acerto na previsão por tercís superior a 60% em todos os modelos com exceção do modelo de março. Ao longo do período de estudo, o desvio padrão da série de produtividade do G2 foi de 400,78 kg/h, valor superior a todas medidas de RMSE dos modelos elaborados para este grupo.

Figura 4.46 – Comparação entre a produtividade média do arroz do Grupo 2 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.

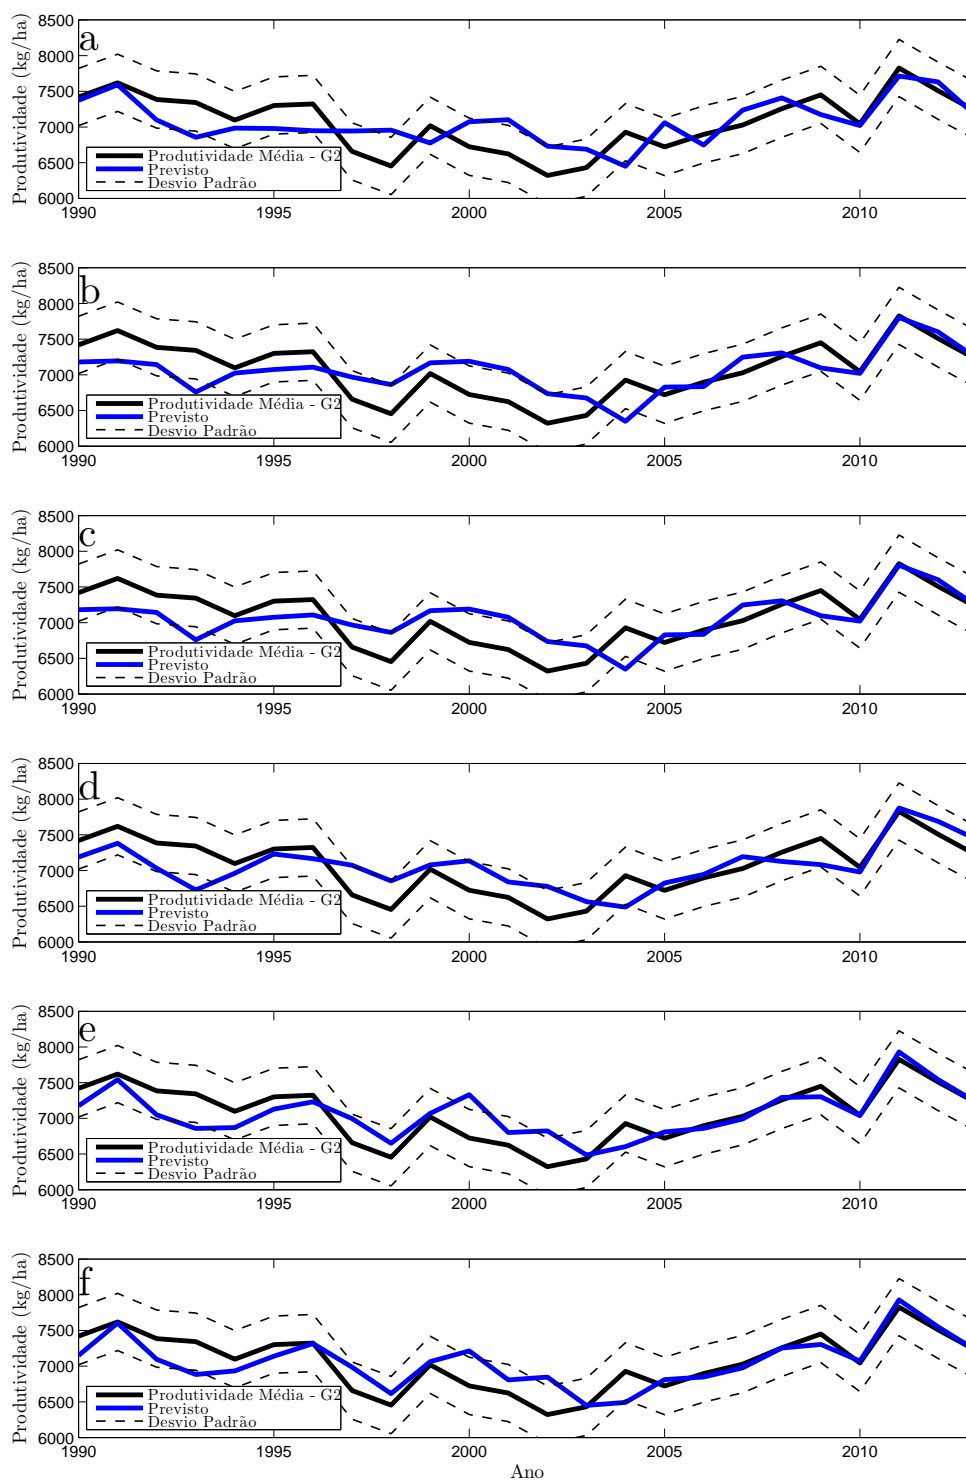


Tabela 4.13 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo do arroz referente ao Grupo 2 para as previsões dos meses de outubro a março.

	Corr.	Viés	RMSE	Taxa de Acerto
OUT	0,67	4,01	295,66	62,5%
NOV	0,64	-4,91	303,7	62,5%
DEZ	0,64	-4,91	303,7	62,5%
JAN	0,7	2,28	282,37	66,67%
FEV	0,78	0,06	246,99	70,83%
MAR	0,8	-1,86	236,54	55%


4.2.6 Previsão Estatística - G3 Arroz

4.2.6.1 *Preditores Selecionados*

A lista de preditores selecionados para diferentes defasagens encontra-se na Tabela S.1. A comparação dos índices utilizados como preditores para os diferentes modelos do G3 demonstra uma elevada alternância a medida que ocorre um avanço no tempo. Dos preditores utilizados no modelo de outubro, nenhum é retido no modelo do mês seguinte (novembro) sendo inseridas três áreas de TSM do mês de outubro como preditoras. O primeiro preditor utilizado no modelo de outubro são as anomalias de TSM no mês de agosto na faixa oceânica próxima a 27°S/159°W. Nesta região, em 64% (71%) dos casos em que foram registradas anomalias positivas de TSM houve um desvio positivo (negativo) da produtividade (Figura 4.47).

Anomalias de TSM no mês de outubro no Oceano Pacífico, próximas a 20°S/172°W, apresentam correlações positivas com a produtividade de arroz para este grupo e são inseridas como preditoras em todos os modelos a partir do mês de novembro. Também no mês de outubro, destaca-se a região oceânica próxima a 10°N/121°W no Oceano Pacífico com correlações negativas com a produtividade de arroz deste grupo.

Figura 4.47 – Relação entre anomalias de TSM no mês de agosto na região oceânica próxima a 27°S/159°W e anomalias de produtividade de arroz no Grupo 3. O percentual indica o número de vezes em que ocorreram anomalias positivas (negativas) de produtividade associadas a anomalias negativas (positivas) de TSM nessa região.



Fonte: Próprio autor.

4.2.6.2 Validação Cruzada

As medidas de destreza do modelo (Tabela 4.14) demonstram que, dentre as previsões de outubro para os grupos homogêneos de arroz, o G3 apresenta a menor taxa de acerto na previsão de tercis (60%) e a menor correlação (0,54). A previsão por tercis apresenta baixo índice de acerto para a maior parte dos modelos do G3 (outubro a janeiro). Nota-se também que o RMSE, embora menor que o desvio padrão (570,05 kg/h) é muito elevado. A análise das séries previstas (Figura 4.48) demonstra a tendência de superestimativa, sendo que o Viés mais elevado é observado no mês de dezembro. Apenas a partir de fevereiro os parâmetros de destreza do modelo apresentam melhores resultados (correlação elevada, baixo RMSE e elevada taxa de acerto) embora o Viés permaneça alto.

Dentre os modelos desenvolvidos para o arroz, o G3 (grupo de maior produtividade média) foi o que apresentou os piores resultados, sinalizando a necessidade de maiores cuidados ao se utilizar as previsões resultantes do modelo estatístico, da busca de novos índices preditores que elevem a acurácia do mesmo e do acompanhamento com modelos de desenvolvimento de cultura para auxiliar nas estimativas da produtividade.

Figura 4.48 – Comparação entre a produtividade média do arroz do Grupo 3 (linha preta sólida) e a previsão realizada (linha azul sólida) com indicadores climáticos até o mês de: a) outubro; b) novembro; c) dezembro; d) janeiro, e) fevereiro e f) março. As linhas pontilhadas delimitam o desvio padrão da série histórica do grupo.

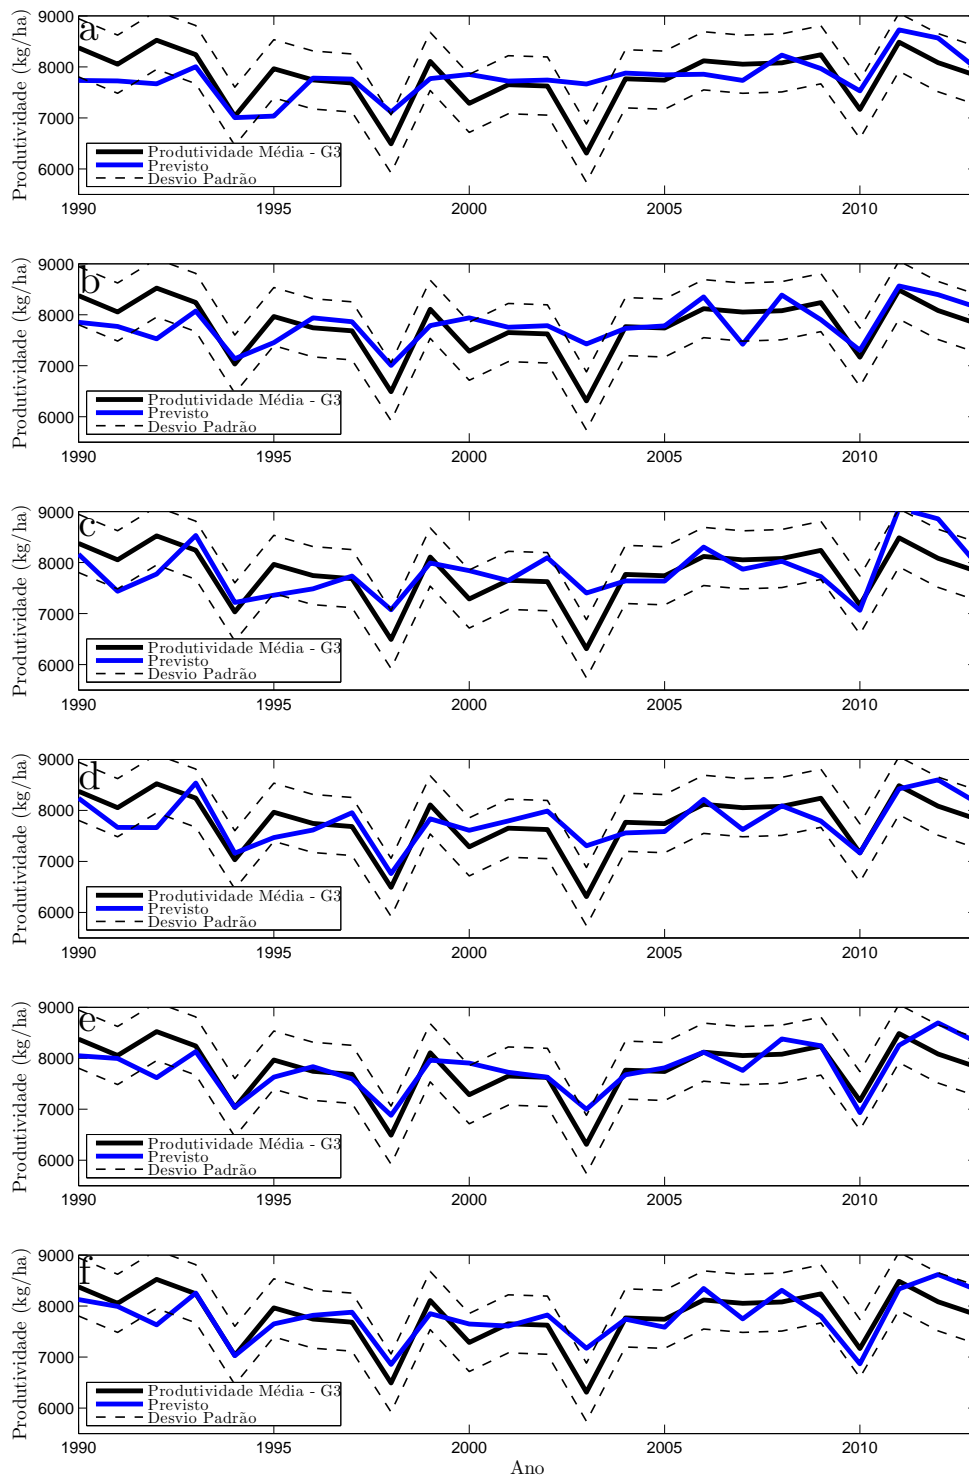


Tabela 4.14 – Parâmetros estatísticos utilizados para a estimativa da destreza do modelo do arroz referente ao Grupo 3 para as previsões dos meses de outubro a março.

	Corr.	Viés	RMSE	Taxa de Acerto
OUT	0,53	9,78	482,50	62,50%
NOV	0,62	27,21	441,79	54,17%
DEZ	0,64	52,16	454,08	54,17%
JAN	0,72	6,43	386,4	50%
FEV	0,78	21,92	354,05	70,83%
MAR	0,76	14,94	363,44	66,67%

4.2.7 Previsão das safras de arroz de 2015/2016 e 2016/2017

Na safra de 2015/2016 (Tabela 4.15) todas as rodadas do modelo (outubro a março) projetaram produtividade abaixo da média para os Grupos 1 e 3 enquanto que para o Grupo 2, as projeções de outubro a janeiro estimavam produtividade acima da média e as previsões de fevereiro e março indicavam produtividade entre a normal e acima da média. A comparação da previsão com os dados observados (Tabela 4.16) demonstra o acerto para os Grupos 1 e 3 com queda da produtividade observada em comparação com a média do período de estudo. O Grupo 2, no entanto, apresentou produtividade acima da média, fator que era indicado pelas previsões apresentadas entre outubro e janeiro.

Para a safra de 2016/2017 (Tabela 4.15), o modelo para o G1 apresentou uma variação mais próxima a média climatológica entre os meses de outubro e dezembro e também em fevereiro e março. A previsão de janeiro apresentou uma tendência extrema de produtividade acima da média e, apesar de apresentar os piores índices referentes a confiabilidade do modelo (Tabela 4.13), foi a única que conseguiu prever o aumento de produtividade (Tabela 4.16). Como visto na Figura 4.29 a ODP possui correlação negativa elevada com a produtividade do arroz, especialmente, entre dezembro e março. Tal situação recomenda uma atenção maior aos resultados do modelo de janeiro em situações que a ODP encontra-se com sinal mais intenso como na safra 2017/2017.

No Grupo 2, todas as previsões indicavam produtividade abaixo da média na safra de 2016/2017 (Tabela 4.15), mas assim como o Grupo 1 e 3 (Tabela 4.16) a produtividade foi acima da média. O modelo do Grupo 2 é altamente dependente de anomalias de TSM no Oceano Pacífico, próximas à 19°S/121°W, sendo o primeiro índice da previsão de outubro a janeiro e também sendo importante nas previsões de fevereiro e março. Esta região do oceano apresentou anomalias positivas no mês de setembro de 2016 e a sua elevada correlação negativa com a produtividade do Grupo 2 (Figura 4.35) prevaleceu sobre o segundo índice (ATSM/JUL/30°S/70°E) que apresentava ligeira anomalia positiva

indicando uma tendência de elevação da produtividade.

Por fim, para o Grupo 3, com exceção da previsão do mês de dezembro, todas as rodadas previram produtividade acima da média (Tabela 4.15) configurando-se com uma previsão certa através dos dados registrados na Fronteira Oeste e Campanha (G3) (Tabela 4.15). O modelo de dezembro é o que apresenta pior desempenho nas medidas estatísticas de destreza (Tabela 4.14) tendo o segundo maior RMSE e o Viés mais elevado.

Tabela 4.15 – Previsão estatística de produtividade de arroz para as safras 2015/2016 e 2016/2017 para os Grupos 1, 2 e 3. Os valores indicam a probabilidade da produtividade ser acima, abaixo ou dentro da normal climatológica do período de estudo.

		2015/2016			2016/2017		
		acima (%)	normal (%)	abaixo (%)	acima (%)	normal (%)	abaixo (%)
G1	OUT	3	13	84	33	39	28
	NOV	10	23	67	23	36	41
	DEZ	2	15	83	26	47	27
	JAN	1	9	90	98	1	1
	FEV	1	6	93	16	51	33
	MAR	1	3	96	15	53	32
		acima	normal	abaixo	acima	normal	abaixo
G2	OUT	56	33	11	14	39	47
	NOV	68	27	5	9	34	57
	DEZ	68	27	5	9	34	57
	JAN	50	40	10	4	25	71
	FEV	8	45	47	2	26	72
	MAR	5	42	53	2	24	74
		acima	normal	abaixo	acima	normal	abaixo
G3	OUT	4	9	87	57	24	19
	NOV	2	4	94	67	18	15
	DEZ	6	8	88	37	19	44
	JAN	2	6	92	52	29	19
	FEV	2	11	87	70	23	7
	MAR	1	4	95	77	18	5

Tabela 4.16 – Produtividade registrada nos Grupos 1, 2 e 3 nas safras de 2015/2016 e 2016/2017 e média climatológica de produtividade dos três grupos ao longo do período de estudo.

	2015/2016	2016/2017	Média
G1	6584 kg/ha	7259 kg/ha	6649 kg/ha
G2	7982 kg/ha	8460 kg/ha	7067 kg/ha
G3	7127 kg/ha	8232 kg/ha	7771 kg/ha

As previsões elaboradas pelos modelos estatísticos do arroz apresentaram bons resultados para a análise de dados que não foram utilizados na calibração do modelo. Para a safra de 2015/2016 a maior parte das previsões de tercís foi correta e conseguiu indicar a queda de produtividade para os Grupos 1 e 3 e a elevação da produtividade no Grupo 2. Na safra 2016/2017, a maior parte das estimativas para os Grupos 1 e 2 apresentou erros, enquanto o G3 teve maior taxa de acerto nas previsões. Apesar disso, os resultados demonstram o potencial desta ferramenta para estimativas de produtividade de arroz no Rio Grande do Sul.

5 CONCLUSÃO

A análise de agrupamento demonstrou uma distribuição coerente dos municípios produtores de soja e arroz no Rio Grande do Sul respeitando características regionais e se aproximando do zoneamento agroclimático proposto para as culturas. Estas regiões possuem diferentes características em termos de precipitação, radiação solar e padrões de temperatura do ar durante o desenvolvimento das culturas o que resultou em distintos padrões de correlação com os diversos índices climáticos utilizados.

A forma como é contabilizada a produtividade média em cada município resulta em limitações no momento em que são realizadas as correlações entre os índices climáticos e a produtividade o que pode acarretar na suavização do sinal dos indicadores. O valor da produtividade municipal trata-se de um valor médio que engloba diferentes cultivares e distintos períodos de semeadura. Desta forma, tomando como exemplo o período final da cultura da soja, a precipitação de determinado momento pode influenciar positivamente parte da cultura que ainda esteja em fase de desenvolvimento e ser prejudicial a outra parte que já se encaminha para o período de colheita. Assim sendo, o sinal associado a um índice climático acaba suavizado no momento em que são tomadas as correlações.

Outro ponto de incerteza inserido nas análises de correlação e no modelo estatístico trata-se do investimento tecnológico que é distinto dentro de um mesmo município. Apesar da remoção da tendência tecnológica baseada na regressão linear, não há a certeza que toda tendência tenha sido removida ou tenha sido removida corretamente para todos os municípios. Importante ressaltar que outros métodos de remoção da tendência tecnológica foram testados (transformação logarítmica, regressão polinomial de segunda e terceira ordem, diferenças parciais e divisão da série por períodos), mas em virtude das séries resultantes serem semelhantes (elevada correlação) optou-se pela utilização do método mais simples.

Para a soja, os índices climáticos que apresentaram correlações mais elevadas e persistentes foram, principalmente, a Oscilação Ártica, Oscilação do Atlântico Norte além de uma região no Oceano Atlântico Sul entre 20°S/30°S e 20°W/40°W. Para a cultura do arroz que, de forma geral, apresentou correlações mais elevadas e persistentes que a soja, destacaram-se, principalmente, os índices referentes as componentes oceânica (NINO) e atmosférica (IOS) do fenômeno El Niño Oscilação Sul e a Oscilação Decadal do Pacífico.

A inserção de novos preditores baseados em anomalias de Temperatura da Superfície do Mar resultou num incremento da destreza do modelo e algumas regiões oceânicas se destacaram como áreas a serem monitoradas durante os preparativos de safra e o desenvolvimento das culturas da soja e do arroz no Rio Grande do Sul. A Análise de Componentes Principais nos campos de Temperatura da Superfície do Mar poderia resultar na diminuição de indicadores necessários para a previsão estatística. Entretanto, no intuito de

fornecer uma ferramenta de mais fácil interpretação e com aplicabilidade mais abrangente optou-se por manter os campos originais da climatologia de Temperatura da Superfície do Mar.

De uma forma geral, para a soja, destaca-se o Oceano Pacífico Norte ($60^{\circ}\text{N}/30^{\circ}\text{N}$) com correlações negativas e o Oceano Pacífico Sul ($60^{\circ}\text{S}/30^{\circ}\text{S}$) com correlações positivas entre outubro e fevereiro. Para o arroz, as correlações foram mais elevadas e destacam-se as regiões equatoriais dos Oceanos Pacífico, Atlântico e Índico, ambas com correlações negativas.

Destaca-se também que muitas das ligações aqui apresentadas ainda não possuem um mecanismo físico que explique tal correlação, especialmente, nos padrões de anomalias de Temperatura da Superfície do Mar utilizados como índices previsores. Estudos futuros buscando compreender estes padrões de teleconexão poderiam também fornecer uma visão mais adequada de determinadas situações nas quais o modelo perderia destreza.

Ainda assim, a metodologia proposta se demonstrou uma ferramenta poderosa no auxílio do preparativo da soja e do arroz no Rio Grande do Sul. Os resultados apresentados mostraram que é possível prever de forma satisfatória, antes mesmo, do período de plantio a produtividade de soja e arroz no Estado baseando-se em índices climáticos já conhecidos na literatura e também com base em índices baseados em anomalias de Temperatura da Superfície do Mar.

Esta previsão pode ser atualizada mensalmente baseada na inclusão de novos índices que, na maior parte dos casos, resulta em uma elevação da destreza do modelo. A implementação de uma previsão baseada em um modelo estatístico serviria como ferramenta complementar a modelos de desenvolvimento de cultura já utilizados nos preparativos de safra no Rio Grande do Sul.

O estudo aqui apresentado trata-se de uma iniciativa inédita de previsão de produtividade no Rio Grande do Sul baseando-se em índices climáticos. Ainda, tendo em conta a forma como a previsão é elaborada atualmente (estimativas baseadas em entrevistas e expectativas de safra), a aplicação de estimativas baseadas em modelos estatísticos pode impactar significativamente na economia gaúcha.

A inserção de novos dados de produtividade para a calibragem do modelo mostra-se limitada pela atualização do banco de dados no site do IBGE dado que até a data de conclusão deste documento, dados referentes as safras de 2015/2016 e 2016/2017 ainda não constavam na base disponível.

Trabalhos futuros poderiam partir das correlações entre índices já encontradas e explorar defasagens maiores que 1 ano que forneceria uma previsão com antecedência mais elevada. Ao mesmo tempo, a elaboração de modelos estatísticos para alguns municípios de referência ao invés de grupos homogêneos poderia apresentar elevação das correlações encontradas e, conseqüentemente, uma maior destreza do modelo resultante.

Conforme visto anteriormente, a temperatura do ar e, principalmente, a precipitação são as principais variáveis meteorológicas que influenciam na variabilidade interanual da produtividade. Correlações entre os índices climáticos de maior destaque neste trabalho e séries médias de precipitação e temperatura para cada grupo homogêneo poderiam ajudar a explicar parte destas correlações.

REFERÊNCIAS BIBLIOGRÁFICAS

ALBERTO, C. M. et al. Água no solo e rendimento do trigo, soja e milho associados ao El Niño Oscilação Sul. **Pesquisa Agropecuária Brasileira**, v. 41, n. 7, p. 1067–1075, 2006.

ANA. **Levantamento da agricultura irrigada por pivôs centrais no Brasil - 2014**. Brasília, Brasil: Agência Nacional das Águas, 2016. 33 p.

ANGELL, J. K.; KORSHOVER, J. The biennial wind and temperature oscillations of the equatorial stratosphere and their possible extension to higher latitudes. **Monthly Weather Review**, v. 90, n. 4, p. 127–132, 1962.

BANNAYAN, M. et al. Association between climate indices, aridity index, and rainfed crop yield in northeast of Iran. **Field Crops Research**, v. 118, p. 105–114, 2010.

BARNETT, T. P.; PREISENDOFER, R. Origins and levels of monthly and seasonal forecast skill for united states surface air temperatures determined by canonical correlation analysis. **Monthly Weather Review**, v. 115, p. 1825–1850, 1987.

BERLATO, M. A.; FARENZENA, H.; FONTANA, D. C. Associação entre o El Niño Oscilação Sul e a produtividade do milho no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v. 40, n. 5, p. 423–432, 2005.

BERLATO, M. A.; FONTANA, D. C. Variabilidade interanual da precipitação pluvial e rendimento da soja no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v. 7, n. 1, p. 119–125, 1999.

_____. **El Niño e La Niña: impactos no clima, na vegetação e na agricultura do Rio Grande do Sul; aplicações de previsões climáticas na agricultura**. Porto Alegre: Editora UFRGS, 2003. 110 p.

BERNARDO, S. O.; MOLION, L. C. B. Variabilidade temporal e espacial na precipitação da costa leste do Nordeste no período 1992-97. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, XIII., 2004, Fortaleza, Ceará, Brasil. **Anais XII Congresso Brasileiro de Meteorologia**. Sociedade Brasileira de Meteorologia - SBMET, 2004. Disponível em: <<http://www.cbmet.com/edicoes.php?cgid=22&imageField2.x=47&imageField2.y=8>>.

CAI, R. et al. Using a climate index to measure crop yield response. **Journal of Agricultural and Applied Economics**, v. 45, p. 719–737, 4 2013.

CAPOZZOLI, C.; CARDOSO, A. de O.; FERRAZ, S. E. T. Padrões de variabilidade de vazão de rios brasileiros e associação com índices climáticos. **Revista Brasileira de Meteorologia**, v. 32, n. 2, p. 243–254, 2017.

CARDOSO, A. de O. **Relações entre a TSM nos oceanos Atlântico e Pacífico e as condições climáticas nas Regiões Sul e Sudeste do Brasil**. 2005. 192 f. Tese (Doutorado em Meteorologia) — Universidade de São Paulo, São Paulo, 2005.

CARDOSO, A. de O. et al. Use of Climate Forecasts to Soybean Yield Estimates. In: ELSHEMY, H. A. (Ed.). **Soybean Physiology and Biochemistry**. [S.l.]: InTech, 2011. p. 37–48.

CARDOSO, A. de O.; CATALDI, M. Relações de índices climáticos e vazão de rios no Brasil. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, XVII., 2012, Gramado, Rio Grande

do Sul, Brasil. **Anais eletrônicos...** Sociedade Brasileira de Meteorologia - SBMET, 2012. Disponível em: <<http://www.sbmet.org.br/cbmet2012/busca-trabalhos/index.html>>.

CARMONA, L. de C. **Efeitos associados aos fenômenos El Niño e La Niña no rendimento do arroz irrigado no Estado do Rio Grande do Sul**. 2001. 77 f. Dissertação (Mestrado em Fitotecnia) — Universidade Federal do Rio Grande do Sul, Porto Alegre, 2001.

CARVALHO, L. M. V.; JONES, C.; AMBRIZZI, T. Opposite phases of the Antarctic Oscillation and relationships with intraseasonal to interannual activity in the tropics during the austral summer. **Journal of Climate**, v. 18, p. 702–718, 2005.

CATALDI, M. et al. Estudo da influência das anomalias da TSM do Atlântico Sul Extratropical na Região da Confluência Brasil Malvinas no regime hidrometeorológico de verão no Sul e Sudeste do Brasil. **Revista Brasileira de Meteorologia**, v. 25, n. 4, p. 513–524, 2010.

CAVALCANTI, I. F. A.; AMBRIZZI, T. Teleconexões e suas influências no Brasil. In: CAVALCANTI, I. F. de A. et al. (Ed.). **Tempo e Clima no Brasil**. [S.l.]: Oficina de Textos, 2009. p. 317–336.

CEPEA. **PIB Agro CEPEA-USP/CNA**. 2017. Disponível em: <<http://cepea.esalq.usp.br/pib/>>. Acesso em: Março 2017.

CHERENKOVA, E. A.; BARDIN, M. Y.; ZOLOTOKRYLIN, A. N. The statistics of precipitation and droughts during opposite phases of the quasi-biennial oscillation of atmospheric processes and its relation to the yield in the European part of Russia. **Russian Meteorology and Hydrology**, v. 40, n. 3, p. 160–169, 2015.

CUNHA, G. R. da et al. Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v. 9, n. 3, p. 446–459, 2001.

CUNHA, G. R. da; DALMAGO, G. A.; ESTEFANEL, V. ENSO influences on wheat crop in Brazil. **Revista Brasileira de Agrometeorologia**, v. 7, n. 1, p. 127–138, 1999.

DIAZ, A. F.; STUDZINSKI, C. D.; MECHOSO, C. R. Relationships between Precipitation Anomalies in Uruguay and Southern Brazil and Sea Surface Temperature in the Pacific and Atlantic Oceans. **Journal of Climate**, v. 11, p. 251–271, 1997.

ENFIELD, D. B. et al. How ubiquitous is the dipole relationship in tropical Atlantic sea surface temperatures? **Journal of Geophysical Research**, v. 104, n. C4, p. 7841–7848, 1999.

FARIAS, J. R. B.; NEUMAIER, N.; NEPOMUCENO, A. L. Soja. In: **Agrometeorologia dos Cultivos**. [S.l.: s.n.], 2009. p. 261–278.

FERREIRA, D. B. **Relação entre a variabilidade da precipitação e a produtividade agrícola de soja e milho nas Regiões Sul e Sudeste do Brasil**. 2006. 125 f. Dissertação (Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

FISHER, R. A.; YATES, F. **Statistical Tables for Biological, Agricultural and Medicinal Research**. 6. ed. London, England: Longman, 1974. 146 p.

FONTANA, D. C. et al. Modelo de estimativa de rendimento de soja no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v. 36, n. 3, p. 399–403, 2001.

GOMMES, R. **Crop-yield Weather Modelling. Lecture Notes and Exercises**. [S.l.]: WMO/FAO Roving Seminar, 1998. 155 p.

GONG, D.; WANG, S. Antarctic oscillation: concept and applications. **Chinese Science Bulletin**, v. 43, p. 734–738, 1998.

GRIMM, A. M.; FERRAZ, S. E. T.; GOMES, J. Precipitation Anomalies in Southern Brazil Associated with El Niño and La Niña Events. **Journal of Climatology**, v. 11, p. 2863–2880, 1998.

GRIMM, A. M.; LEITE, A. E.; SAHAI, A. K. Previsão de Precipitação Sazonal para a Bacia do Rio Paranaíba Utilizando um Modelo Linear. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, XIII., 2004, Fortaleza, Ceará, Brasil. **Anais eletrônicos...** Sociedade Brasileira de Meteorologia - SBMET, 2004. Disponível em: <<http://www.cbmet.com/index.php>>.

HASTENRATH, S. Diagnostics and prediction of anomalous river discharge in northern south america. **Journal of Climate**, v. 3, p. 1080–1096, 1990.

HEINEMANN, A. B.; STONE, L. F.; SILVA, S. C. da. Arroz. In: **Agrometeorologia dos Cultivos**. [S.l.: s.n.], 2009. p. 63–80.

HOOGENBOOM, G. Contribution of agrometeorology to the simulation of crop production and its applications. **Agricultural and Forest Meteorology**, v. 103, p. 137–157, 2000.

IBGE. **Produção Agrícola Municipal**. 2017. Disponível em: <<https://sidra.ibge.gov.br/Tabela/1612>>. Acesso em: Abril 2017.

JOLLIFFE, I. T. **Principal Component Analysis**. 2. ed. New York, New York, United States of America: Springer, 2004. 518 p.

KAYANO, M. T.; ANDREOLI, R. T. Relations of South American summer rainfall interannual variations with the Pacific Decadal Oscillation. **Journal of Climate**, v. 11, p. 2863–2880, 1998.

KAYANO, M. T.; JONES, C.; DIAS, P. L. da S. Variabilidade intrassazonal. In: CAVANCANTI, I. F. de A. et al. (Ed.). **Tempo e Clima no Brasil**. [S.l.]: Oficina de Textos, 2009. p. 337–352.

KLERING, E. V. et al. Modelo agrometeorológico-espectral para estimativa da produtividade de grãos de arroz irrigado no rio grande do sul. **Bragantia**, v. 75, n. 2, p. 247–256, 2016.

LAZZARI, M. R. Agropecuária gaúcha em 2005: estiagem, câmbio e crise. **Indicadores Econômicos FEE**, v. 33, n. 4, p. 41–50, 2006.

LIZUMI, T. et al. Impacts of el niño southern oscillation on the global yields of major crops. **Nature Communications**, v. 5, 2014.

LOBELL, D. B.; BURKE, M. B. On the use of statistical models to predict crop yield responses to climate change. **Agricultural and Forest Meteorology**, v. 150, p. 1443–1452, 2010.

LOBELL, D. B.; FIELD, C. B. Global scale climate-crop yield relationships and the impacts of recent warming. **Environmental Research Letters**, v. 2, p. 1–7, 2007.

LOPES, F. Z.; DINIZ, G. B.; MARQUES, J. R. Relação entre o Multivariate Enso Index (MEI) e a TSM das regiões dos niños com a precipitação em regiões homogêneas do Estado do Rio Grande do Sul. **Anuário do Instituto de Geociências**, v. 30, p. 11–22, 2007.

MANTUA, N. J. et al. A Pacific Interdecadal Climate Oscillation with Impacts on Salmon Production. **Bulletin of the American Meteorological Society**, v. 78, n. 6, p. 1069–1079, 1997.

MARTINEZ, C. J.; BAIGORRIA, G. A.; JONES, J. W. Use of climate indices to predict corn yields in southeast USA. **International Journal of Climatology**, v. 29, p. 1680–1691, 2009.

MELO, R. W. de. **Modelo agrometeorológico-espectral de estimativa de rendimento da soja para o estado do Rio Grande do Sul**. 2003. 71 f. Dissertação (Mestrado em Agrometeorologia) — Universidade Federal do Rio Grande do Sul, Porto Alegre, 2003.

MELO, R. W. de; FONTANA, D. C.; BERLATO, M. A. Indicadores de produção de soja no Rio Grande do Sul comparados ao zoneamento agrícola. **Pesquisa Agropecuária Brasileira**, v. 39, n. 12, p. 1167–1175, 2004.

MONTEIRO, J. E. B. de A. et al. Rice yield estimation based on weather conditions and on technological level of production systems in Brazil. **Pesquisa Agropecuária Brasileira**, v. 48, n. 2, p. 123–131, 2013.

MOTA, F. S. da. Influência dos fenômenos El Niño e La Niña sobre o rendimento do arroz irrigado na região de Pelotas (RS). **Revista Brasileira de Meteorologia**, v. 15, n. 2, p. 21–24, 2000.

NAYLOR, R. L. et al. Using El Niño/Southern Oscillation climate data to predict rice production in Indonesia. **Climate Change**, v. 50, p. 255–265, 2001.

RAO, G. V.; HADA, K. Characteristics of rainfall over Brazil annual variations and connections with the Southern Oscillation. **Theoretical and Applied Climatology**, v. 42, p. 81–91, 1990.

RAO, V. B. et al. Interannual variations of rainfall and corn yields in northeast Brazil. **Agriculture and Forest Meteorology**, v. 85, p. 63–74, 1997.

RAY, D. K. et al. Climate variation explains a third of global crop yield variability. **Nature Communications**, v. 6, p. 1–9, 2015.

REBOITA, M. S. et al. Regimes de precipitação na América do Sul: uma revisão bibliográfica. **Revista Brasileira de Meteorologia**, v. 25, n. 2, p. 185–204, 2010.

ROGERS, J. C. Atmospheric circulation changes associated with the warming over the northern North Atlantic in the 1920s. **Journal of Climate**, v. 24, n. 12, p. 1303–1310, 1985.

SANTOS, E. B.; DINIZ, G. B. Oceanic indices and their relations with the monthly precipitation in Rio Grande do Sul state, Brazil. **Revista Brasileira de Geofísica**, v. 32, p. 371–381, 2014.

SCHLESINGER, M. E.; RAMANKUTTY, N. An oscillation in the global climate system of period 65–70 years. **Nature**, v. 367, n. 6465, p. 723–726, 1994.

SENTELHAS, P. C. et al. The soybean yield gap in Brazil - magnitude, causes and possible solution for sustainable production. **Journal of Agricultural Science**, v. 153, p. 1–18, 2015.

SERVAIN, J. Simple climatic indices for the tropical Atlantic ocean and some applications. **Journal of Geophysical Research**, v. 96, n. C8, p. 15137–15146, 1991.

SILVA, M. R. da et al. Modelagem numérica para previsão de safra de arroz irrigado no Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v. 51, n. 7, p. 791–800, 2016.

SILVESTRI, G. E.; VERA, C. S. Antarctic oscillation signal on precipitation anomalies over southeastern south america. **Geophysical Research Letters**, v. 30, n. 21, p. CLM – 3 – 1, 1994.

SOSBAI. **Arroz Irrigado: recomendações técnicas da pesquisa para o Sul do Brasil**. [S.l.]: Sociedade Sul-Brasileira de Arroz Irrigado, 2014. 192 p.

SOUZA, E. B. de; AMBRIZZI, T. ENSO impacts on the South American rainfall during 1980s: Hadley and Walker circulation. **Atmosfera**, v. 15, p. 105–120, 2002.

STRECK, N. A. et al. Associação da variabilidade da precipitação pluvial em Santa Maria com a Oscilação Decadal do Pacífico. **Pesquisa Agropecuária Brasileira**, v. 44, n. 12, p. 1553–1561, 2009.

SUN, L. et al. Climate variability and corn yields in Semiarid Ceará, Brazil. **Journal of Applied Meteorology and Climatology**, v. 46, p. 226–240, 2007.

TEDESCHI, R. G.; CAVALCANTI, I. F. A.; GRIMM, A. M. Influences of two types of ENSO on South American precipitation. **International Journal of Climatology**, v. 33, n. 3, p. 1382–1400, 2013.

THOMAS, A. L.; COSTA, J. A. Influência do déficit hídrico sobre o desenvolvimento e rendimento da soja. **Pesquisa Agropecuária Brasileira**, v. 29, n. 9, p. 389–396, 1994.

THOMPSON, D. W. J.; WALLACE, J. M. The arctic oscillation signature in the wintertime geopotential height and temperature fields. **Geophysical Research Letters**, v. 25, p. 1297–1300, 1998.

TRENBERTH, E. K. Signal versus noise in the southern oscillation. **Monthly Weather Review**, v. 112, n. 2, p. 326–332, 1984.

_____. The definition of el niño. **Bulletin of American Meteorological Society**, v. 28, n. 12, p. 2771–2777, 1997.

VASCONSELLOS, F. C. **A Oscilação Antártica - mecanismos físicos e a relação com características atmosféricas sobre a América do Sul/oceanos adjacentes**. 2012. 195 f. Tese (Doutorado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012.

WALLACE, J. M.; FULU, T.; ZHAO, Z. Teleconnections in the geopotential heigth field during the north hemisphere winter. **Monthly Weather Review**, v. 109, n. 4, p. 784–812, 1981.

WARD, J. H. Hierarchical grouping to optimize an objective function. **Journal of the American Statistical Association**, v. 58, n. 301, p. 236–244, 1963.

WENJIAO, S.; FULU, T.; ZHAO, Z. A review on statistical modelos for identifying climate contributions to crop yields. **Journal of Geographical Sciences**, v. 23, p. 567–576, 2013.

WILKS, D. S. **Statistical Methods in the Atmospheric Sciences**. 2. ed. San Diego, California, United States of America: Academic Press, Elsevier, 2006. 630 p.

WMO. **Guide to Agricultural Meteorological Practices**. [S.l.]: World Meteorological Organization, 2012. 799 p.


ZANON, A. J.; STRECK, N. A.; GRASSINI, P. Climate and management factors influence soybean yield potential in a subtropical environment. **Agronomy Journal**, v. 108, p. 1447–1454, 2016.

ANEXO A – EL NIÑO OSCILAÇÃO SUL - ENOS

O fenômeno acoplado El Niño Oscilação Sul é a principal fonte da variabilidade climática interanual. A sua componente oceânica na região do Niño 3.4 é medida através de anomalias de TSM no Oceano Pacífico Equatorial e os dados disponíveis são resultado de uma média móvel de 3 meses de anomalias na região entre 5°N-5°S e 120°W-170°W. Episódios de EN (LN) são definidos quando a anomalia é maior ou igual (menor ou igual) a 0.5°C e permanece por, pelo menos, 5 meses consecutivos. Os dados estão disponíveis em: <http://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ensoyears.shtml>.

Já a componente atmosférica é definida como a diferença de pressão ao nível do mar normalizada entre Tahiti (aproximadamente 17°S/149°W) na Polinésia Francesa e Darwin (aproximadamente 12°S/130°E) no norte da Austrália. Os dados estão disponíveis em: <<http://www.cpc.ncep.noaa.gov/data/indices/soi>>.

Figura A.1 – Variação das anomalias de TSM na região do Niño 3.4 (superior) e o Índice de Oscilação Sul (inferior) durante o período de estudo. A linha preta sólida indica a tendência linear da série.




ANEXO B – OSCILAÇÃO DO ATLÂNTICO NORTE - NAO

A Oscilação do Atlântico Norte está relacionada a um centro de baixa pressão próximo a Islândia e a uma alta pressão situada próxima a região dos Açores. Em sua fase positiva (negativa), há uma intensificação (desintensificação) da alta dos Açores e da baixa da Islândia que resulta em uma intensificação (desintensificação) do gradiente de pressão sobre o Oceano Atlântico Norte e, conseqüentemente, invernos mais quentes e úmidos (frios) na Europa e leste dos Estados Unidos. Na América do Sul, a intensificação (desintensificação) da alta dos Açores induz a intensificação (desintensificação) dos ventos alísios de nordeste e intensifica (desintensifica) o transporte de umidade para o interior do continente.

Os índices mensais referentes a NAO podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/nao.data>>.

Figura B.1 – Variação do índice mensal referente a NAO durante o período de estudo. A linha preta sólida indica a tendência linear da série.



Fonte: Próprio autor.


ANEXO C – PADRÃO DO PACÍFICO / AMÉRICA DO NORTE - PNA

O padrão de teleconexão Pacífico / América do Norte é um dos principais modos de variabilidade de baixa frequência nas regiões extratropicais do Hemisfério Norte. A sua fase positiva é caracterizada por anomalias positivas de geopotencial nas proximidades do Havaí e na região das Montanhas Rochosas acompanhadas de anomalias negativas sobre o sul do Alaska e sudeste dos Estados Unidos. Fases positivas da PNA estão associadas a anomalias positivas de precipitação sobre altas latitudes do Pacífico Norte.

O PNA é fortemente influenciada pelo ENOS. Fases positivas da PNA tendem a estar associadas a episódios de El Niño enquanto fases negativas, geralmente, estão associadas a episódios de La Niña.

Os índices mensais referentes ao PNA podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/pna.data>>.

Figura C.1 – Variação do índice mensal referente a PNA durante o período de estudo. A linha preta sólida indica a tendência linear da série.



Fonte: Próprio autor.


ANEXO D – OSCILAÇÃO MULTIDECADAL DO ATLÂNTICO - AMO

A Oscilação Multidecadal do Atlântico é uma série contínua com mudanças de longa duração na TSM do Atlântico Norte com fases quentes e frias que podem durar entre 20 e 40 anos e diferenças de, aproximadamente, 0,556°C entre os extremos.

Na América do Sul, a AMO possui correlação negativa com o total de chuva na Amazônia ocidental e na sua fase negativa nota-se o aquecimento anômalo do Oceano Atlântico Sul e um aumento na atividade da Zona de Convergência Intertropical (ZCAS).

Os índices mensais referentes a AMO podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/amon.us.data>>.

Figura D.1 – Variação do índice mensal referente a AMO durante o período de estudo. A linha preta sólida indica a tendência linear da série.




Fonte: Próprio autor.

ANEXO E – ANOMALIA DE TSM NO ATLÂNTICO TROPICAL SUL - TSA

As anomalias de TSM referentes a TSA são calculadas na região compreendida entre a Linha do Equador e 20°S e entre 30°E/10°W, próxima ao Golfo da Guiné. Há um padrão dipolo com periodicidade de 8-12 anos para o inverno/primavera Hemisfério Norte e 2-3 anos para o verão/outono no Hemisfério Norte.

Os índices mensais referentes a TSA podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/tsa.data>>.

Figura E.1 – Variação do índice mensal referente a TSA durante o período de estudo. A linha preta sólida indica a tendência linear da série.




Fonte: Próprio autor.

ANEXO F – ANOMALIA DE TSM NO ATLÂNTICO TROPICAL NORTE - TNA

As anomalias de TSM referentes a TNA são calculadas na região compreendida entre 5,5°N/23,5°N e 15°W/57.5°W. Apresenta um padrão dipolar com periodicidade de 8-12 anos para o inverno/primavera boreal e 2-3 anos para o verão/outono boreal.

Os índices mensais referentes a TNA podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/tna.data>>.

Figura F.1 – Variação do índice mensal referente a TNA durante o período de estudo. A linha preta sólida indica a tendência linear da série.




Fonte: Próprio autor.

ANEXO G – OSCILAÇÃO DECADAL DO PACÍFICO - ODP

Caracterizada por anomalias de TSM ao norte de 20°N no Oceano Pacífico. Possui uma variabilidade interdecadal com oscilações no período aproximado de 50 anos. Em sua fase quente, são observadas anomalias de TSM anormalmente frias na região central do Pacífico Norte e o afundamento da baixa pressão das Aleutas juntamente com águas mais quentes na costa oeste das Américas.

Os índices mensais referentes a ODP podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/pdo.data>>.

Figura G.1 – Variação do índice mensal referente a ODP durante o período de estudo. A linha preta sólida indica a tendência linear da série.




Fonte: Próprio autor.

ANEXO H – OSCILAÇÃO QUASE BIENAL - QBO

Caracterizada por uma oscilação quase periódica da componente zonal do vento na estratosfera tropical (ventos de leste e oeste) com um período médio de 28-29 meses. A fase positiva (negativa) é caracterizada por ventos de oeste (leste).

Os índices mensais referentes a QBO podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/qbo.data>>.

Figura H.1 – Variação do índice mensal referente a QBO durante o período de estudo. A linha preta sólida indica a tendência linear da série.



Fonte: Próprio autor.


ANEXO I – MODO MERIDIONAL DO ATLÂNTICO - AMM

O AMM é a principal fonte da variabilidade oceano-atmosfera no Oceano Atlântico e possui uma variabilidade entre interanual a decadal. Em sua fase positiva (negativa), são observadas anomalias positivas (negativas) de TSM no Atlântico Norte, a Zona de Convergência Intertropical fica deslocada mais para o norte (sul) e há uma condição de precipitação abaixo (acima) da média no Nordeste.

O cálculo do índice referente ao AMM é definido através da aplicação da Análise de Covariância Máxima do campo de TSM e das componentes zonal e meridional do vento (10m) na região compreendida entre 21 °S/32 °N e 15 °E/74 °W.

Os índices mensais referentes a AMM podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/timeseries/monthly/AMM/ammsst.data>>.

Figura I.1 – Variação do índice mensal referente ao AMM durante o período de estudo. A linha preta sólida indica a tendência linear da série.



Fonte: Próprio autor.


ANEXO J – OSCILAÇÃO ÁRTICA - AO

O padrão da AO é definido através do primeiro modo resultante da análise de Funções Ortogonais Empíricas no campo de anomalia de altura geopotencial em 1000 hPa entre 20°N/90°N. Os índices diários e mensais são construídos projetando as anomalias de altura diárias e mensais de 1000 hPa no modo resultante da Função Ortogonal Empírica. As séries são então normalizadas pelo desvio padrão do índice mensal.

Em sua fase positiva ocorre o fortalecimento do vórtice polar que transporta ar quente e úmido do Atlântico rumo ao leste da Europa e da Sibéria. Em sua fase negativa, há o avanço de ar mais frio para o sul e invernos mais intensos em pontos da América do Norte, Europa e Ásia.

Os índices mensais referentes a AO podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/ao.data>>.

Figura J.1 – Variação do índice mensal referente ao AO durante o período de estudo. A linha preta sólida indica a tendência linear da série.



Fonte: Próprio autor.


ANEXO K – OSCILAÇÃO ANTÁRTICA - OAA

Para o cálculo do índice da OAA, de forma semelhante a AO, é aplicada a técnica das Funções Ortogonais Empíricas nos campos de anomalia de altura geopotencial em 700 hPa entre 20°S/90°S. Valores positivos (negativos) do índice da OAA estão associados a anomalias positivas (negativas) de altura geopotencial em latitudes médias e anomalias negativas (positivas) em altas latitudes.

Em situações em que o índice da OAA está positivo (negativo) há uma redução (intensificação) das condições frontogenéticas no sudeste da América do Sul e anomalias negativas (positivas) de precipitação sobre o Sul do Brasil.

Os índices mensais referentes a OAA podem ser encontrados em: <<https://www.esrl.noaa.gov/psd/data/correlation/aao.data>>.

Figura K.1 – Variação do índice mensal referente a OAA durante o período de estudo. A linha preta sólida indica a tendência linear da série.



Fonte: Próprio autor.

ANEXO L – MUNICÍPIOS HOMOGÊNEOS DE PRODUTIVIDADE DE SOJA

Tabela L.1 – Municípios com produtividade homogênea de soja.

Grupo 1	Grupo 2	Grupo 3
Campinas do Sul	Ajuricaba	Boa Vista do Buricá
Carazinho	Alpestre	Bossoroca
Casca	Anta Gorda	Campina das Missões
Chapada	Aratiba	Cerro Largo
Ciríaco	Augusto Pestana	Crissiumal
Colorado	Braga	Guarani das Missões
Condor	Caibaté	Porto Lucena
Cruz Alta	Caiçara	Roque Gonzales
Cruzeiro do Sul	Campo Novo	Santo Antônio das Missões
Erechim	Cândido Godói	Santo Cristo
Esmeralda	Catuípe	São Borja
Espumoso	Chiapetta	São Nicolau
Gaurama	Constantina	São Paulo das Missões
Getúlio Vargas	Encruzilhada do Sul	
Ibiaçá	Ervai Grande	
Jacutinga	Frederico Westphalen	
Júlio de Castilhos	Giruá	
Machadinho	Humaitá	
Marau	Ijuí	
Maximiliano de Almeida	Independência	
Não-Me-Toque	Iraí	
Nonoai	Itaqui	
Panambi	Itatiba do Sul	
Passo Fundo	Jaguari	
Pejuçara	Mata	
Ronda Alta	Rodeio Bonito	
Santa Bárbara do Sul	Rondinha	
Santo Augusto	Santa Rosa	
Sarandi	Santiago	
Serafina Corrêa	Santo Ângelo	
Sertão	São Gabriel	
Soledade	São Luiz Gonzaga	
Tupanciretã	São Martinho	
Viadutos	São Vicente do Sul	
Victor Graeff	Seberi	
	Tenente Portela	
	Três de Maio	
	Três Passos	
	Vicente Dutra	

ANEXO M – PREDITORES - SOJA G1

Tabela M.1 – Lista de preditores utilizados para o Grupo 1 de soja para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.

	OUT	NOV	DEZ	JAN	FEV	MAR
1°	ATSM/SET/50°S/72°E	ATSM/SET/50°S/72°E	ATSM/SET/50°S/72°E	ATSM/SET/50°S/72°E	ATSM/SET/50°S/72°E	ATSM/SET/50°S/72°E
2°	ATSM/JUL/39°S/130°E	ATSM/OUT/59°S/77°W	ATSM/NOV/42°S/165°W	ATSM/NOV/42°S/165°W	ATSM/JAN/47°N/157°W	ATSM/FEV/45°S/55°W
3°	ATSM/MAI/52°N/178°W	ATSM/JUL/39°S/130°E	ATSM/OUT/59°S/77°W	ATSM/OUT/59°S/77°W	ATSM/JAN/40°N/154°W	ATSM/JAN/47°N/157°W
4°	ATSM/MAI/60°S/163°W	ATSM/OUT/39°S/169°W	ATSM/NOV/38°S/123°W	ATSM/NOV/38°S/123°W	ATSM/OUT/59°S/77°W	ATSM/JAN/40°N/154°W
5°		ATSM/OUT/39°S/121°W	ATSM/JUL/39°S/130°E	ATSM/DEZ/43°S/129°E	ATSM/NOV/38°S/123°W	ATSM/OUT/59°S/77°W
6°		ATSM/MAI/52°N/178°W	ATSM/MAI/52°N/178°W	ATSM/DEZ/47°S/122°W	ATSM/JAN/34°N/63°W	ATSM/NOV/38°S/123°W
7°		ATSM/AGO/23°N/143°W		ATSM/MAI/52°N/178°W		ATSM/JAN/34°N/63°W
8°		ATSM/SET/33°S/67°E		ATSM/AGO/23°N/143°W		
9°		AO/OUT				

ANEXO N – PREDITORES - SOJA G2

Tabela N.1 – Lista de preditores utilizados para o Grupo 2 de soja para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.

	OUT	NOV	DEZ	JAN	FEV	MAR
1°	ATSM/SET/48°S/146°E	ATSM/SET/48°S/146°E	ATSM/NOV/41°N/166°W	ATSM/NOV/41°N/166°W	ATSM/NOV/41°N/166°W	ATSM/FEV/46°S/54°W
2°	ATSM/MAI/52°N/178°W	ATSM/MAI/52°N/178°W	ATSM/NOV/38°S/123°W	ATSM/NOV/38°S/123°W	ATSM/NOV/38°S/123°W	ATSM/NOV/41°N/166°W
3°	ATSM/AGO/22°N/142°W	AO/OUT	ATSM/SET/48°S/146°E	ATSM/DEZ/46°S/132°W	ATSM/DEZ/46°S/132°W	ATSM/FEV/28°S/41°W
4°	ATSM/MAI/60°S/162°W	ATSM/OUT/39°S/121°W	ATSM/MAI/52°N/178°W	ATSM/SET/48°S/146°E	ATSM/JAN/34°N/62°W	ATSM/NOV/38°S/123°W
5°	ATSM/SET/50°S/106°E	ATSM/OUT/39°S/121°W	AO/OUT	ATSM/MAI/52°N/178°W	ATSM/SET/48°S/146°E	
6°	ATSM/SET/55°N/172°W	ATSM/AGO/22°N/142°W	ATSM/AGO/22°N/142°W	AO/OUT	ATSM/MAI/52°N/178°W	
7°	ATSM/SET/27°N/28°W	NAO/OUT	ATSM/NOV/47°S/115°W			
8°	AO/AGO	ATSM/MAI/60°S/162°W	ATSM/MAI/60°S/162°W			
9°	PNA/AGO		NAO/OUT			

ANEXO O – PREDITORES - SOJA G3

Tabela O.1 – Lista de preditores utilizados para o Grupo 3 de soja para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.

	OUT	NOV	DEZ	JAN	FEV	MAR
1°	ATSM/SET/48°S/146°E	ATSM/OUT/37°N/170°W	ATSM/NOV/39°S/124°W	ATSM/DEZ/46°S/122°W	ATSM/DEZ/46°S/122°W	ATSM/DEZ/46°S/122°W
2°	ATSM/MAI/27°N/146°E	ATSM/SET/48°S/146°E	ATSM/NOV/40°N/168°W	ATSM/NOV/40°N/168°W	ATSM/JAN/34°N/63°W	ATSM/FEV/28°S/41°W
3°	ATSM/MAI/52°N/179°E	AO/OUT	ATSM/SET/48°S/146°E	ATSM/SET/48°S/146°E	ATSM/NOV/40°N/168°W	ATSM/JAN/34°N/63°W
4°	ATSM/MAI/44°S/151°W	ATSM/OUT/45°N/139°W	AO/OUT	ATSM/DEZ/32°S/167°W	ATSM/SET/48°S/146°E	ATSM/NOV/40°N/168°W
5°	ATSM/SET/0°/27°W	ATSM/MAI/27°N/146°E	ATSM/OUT/45°N/139°W	AO/OUT	OAA/JAN	ATSM/FEV/46°S/54°W
6°	ATSM/JUL/39°S/129°E	ATSM/MAI/52°N/179°E		ATSM/OUT/45°N/139°W		ATSM/SET/48°S/146°E
7°	ATSM/AGO/44°S/18°W	ATSM/MAI/44°S/151°W		ATSM/MAI/27°N/146°E		
8°		ATSM/SET/0°/27°W				
9°		ATSM/JUL/39°S/129°E				

ANEXO P – MUNICÍPIOS HOMOGÊNEOS DE PRODUTIVIDADE DE ARROZ

Tabela P.1 – Municípios com produtividade homogênea de arroz.

Grupo 1	Grupo 2	Grupo 3
Barra do Ribeiro	Arroio Grande	Agudo
Caçapava do Sul	Cidreira	Alegrete
Cacequi	Cristal	Bagé
Cachoeira do Sul	Eldorado do Sul	Dom Pedrito
Camaquã	Guaíba	Dona Francisca
Candelária	Jaguarão	Itacurubi
Cerro Brando	Pedro Osório	Itaqui
Formigueiro	Santa Vitória do Palmar	Paraíso do Sul
Mostardas	Torres	Quaraí
Nova Esperança do Sul		Rio Grande
Osório		Rosário do Sul
Palmares do Sul		Santana do Livramento
Restinga Seca		Santo Antônio das Missões
Rio Pardo		São Borja
Rolante		São Gabriel
Santa Cruz do Sul		Uruguaiana
São Francisco de Assis		Venâncio Aires
São Lourenço do Sul		
São Sepé		
São Vicente do Sul		
Tavares		

ANEXO Q – PREDITORES - ARROZ - G1

Tabela Q.1 – Lista de preditores utilizados para o Grupo 1 de arroz para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.

	OUT	NOV	DEZ	JAN	FEV	MAR
1°	ATSM1/SET	ATSM1/SET	ATSM1/SET	ODP/DEZ	ATSM1/JAN	ATSM1/JAN
2°	QBO/ABR	QBO/ABR	QBO/ABR	TSA/DEZ	ODP/JAN	ODP/FEV
3°	NIÑO/SET	NIÑO/OUT	NIÑO/OUT	ATSM1/DEZ	TSA/DEZ	TSA/DEZ
4°	ATSM2/JUN	TSA/OUT	TSA/OUT	PNA/DEZ		
5°	ODP/SET	ATSM2/JUN	ATSM2/JUN			
6°	IOS/AGO		ODP/SET			
7°	AMM/SET		IOS/AGO			
8°	AO/JUL		PNA/NOV			
9°			AMM/SET			

ANEXO R – PREDITORES - ARROZ - G2

Tabela R.1 – Lista de preditores utilizados para o Grupo 2 de arroz para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.

	OUT	NOV	DEZ	JAN	FEV	MAR
1°	ATSM/SET/19°S/121°W	ATSM/SET/19°S/121°W	ATSM/SET/19°S/121°W	ATSM/SET/19°S/121°W	ATSM/JAN/47°S/10°E	ATSM/FEV/43°N/179°W
2°	ATSM/JUL/30°S/70°E	ATSM/JUL/30°S/70°E	ATSM/SET/19°S/121°W	ATSM/SET/19°S/121°W	ATSM/JAN/42°N/176°E	ATSM/JAN/47°S/10°E
3°	IOS/MAI			ATSM/DEZ/43°N/178°W	ATSM/SET/19°S/121°W	ATSM/SET/19°S/121°W
4°	OAA/ABR				ATSM/JUL/30°S/70°E	ATSM/JUL/30°S/70°E
5°					ODP/JAN	ODP/JAN
6°					ATSM/OUT/17°S/85°W	ATSM/OUT/17°S/85°W
7°						
8°						
9°						

ANEXO S – PREDITORES - ARROZ - G3

Tabela S.1 – Lista de preditores utilizados para o Grupo 3 de arroz para diferentes defasagens. A organização de 1° a 9° refere-se a ordem na qual os preditores foram inseridos.

	OUT	NOV	DEZ	JAN	FEV	MAR
1°	ATSM/AGO/27°S/159°W	ATSM/OUT/20°S/172°W	ATSM/OUT/20°S/172°W	ATSM/DEZ/19°S/15°W	ATSM/JAN/16°S/23°W	ATSM/JAN/16°S/23°W
2°	ATSM1/ABR	ATSM/OUT/10°N/121°W	ATSM/NOV/19°S/11°W	ATSM/OUT/20°S/172°W	ATSM/OUT/20°S/172°W	ATSM/OUT/20°S/172°W
3°	NINO/SET	ATSM/OUT/0°/90°W	ATSM/OUT/10°N/121°W	ATSM/OUT/10°N/121°W	ATSM/JAN/32°N/153°W	
4°	IOS/AGO		ATSM/OUT/0°/90°W	TSA/DEZ		
5°	ODP/AGO		ATSM/NOV/42°S/22°W	ATSM/OUT/0°/90°W		
6°	QBO/ABR		ATSM1/ABR	ATSM/NOV/42°S/22°W		
7°	AMM/SET					
8°						
9°						