

**David Augusto Silva**

**Otimização da Função de Fitness para a Evolução de  
Redes Neurais com o uso de Análise Envoltória de Dados  
Aplicada à Previsão de Séries Temporais**

RECIFE-PE - JUNHO/2011

# **Otimização da Função de Fitness para a Evolução de Redes Neurais com o uso de Análise Envoltória de Dados Aplicada à Previsão de Séries Temporais**

Dissertação apresentada ao Programa de Pós-Graduação em Biometria e Estatística Aplicada como exigência parcial à obtenção do título de Mestre.

**Área de Concentração: Modelagem Estatística e Computacional**

Orientador: Prof. Dr. Tiago Alessandro Espínola Ferreira

RECIFE-PE - JUNHO/2011.

**UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO**  
**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM BIOMETRIA E ESTATÍSTICA APLICADA**

**Otimização da Função de Fitness para a Evolução de Redes Neurais com o uso de  
Análise Envoltória de Dados Aplicada à Previsão de Séries Temporais**

David Augusto Silva

Dissertação julgada adequada para obtenção do título de mestre em Biometria e Estatística Aplicada, defendida e aprovada por unanimidade em 01/07/2011 pela Comissão Examinadora.

Orientador:

---

Prof. Dr. Tiago Alessandro Espínola Ferreira  
Universidade Federal Rural de Pernambuco

Banca Examinadora:

---

Prof. Dr. Getúlio José Amorim do Amaral  
Universidade Federal de Pernambuco  
UFPE

---

Prof. Dr. Moacyr Cunha Filho  
Universidade Federal Rural de Pernambuco  
UFRPE

---

Prof. Dr. Borko D. Stosic  
Universidade Federal Rural de Pernambuco  
UFRPE

# Dedicatória

Dedico essa dissertação ao meu pai e minha mãe.

# Agradecimentos

Agradeço a Deus, em primeiro lugar, por ter me guiado e me dado paciência para enfrentar todas as dificuldades ao longo desta jornada.

A minha família, por ter me apoiado, e priorizado o meu estudo diante de todas as dificuldades que enfrentamos ao longo da vida.

Ao meu orientador Tiago por ter me dado toda a ajuda necessária e apoio durante o período do mestrado.

Agradecimento especial a Aranildo e Paulinho, porque sem eles não teria conseguido alcançar êxitos nas simulações e na dissertação.

Ao professor Gabriel, por ser sempre prestativo nas dúvidas relacionadas à estatística.

Não poderia esquecer dos meus colegas de mestrado e amigos que formei ao longo destes dois anos no estado de Pernambuco. A todos eles que de alguma forma me ajudaram diretamente nessa dissertação saibam que estou profundamente grato.

# Epígrafe

*"Ainda que o tempo, o maior e mais implacável dos carrascos, intente sobre o meu corpo físico, ele nunca terá poder sobre meu pensar, meu saber e minha vontade, pois estes são eternos. Por isto e tão somente por isto que vou tentar sempre, porque nunca é tarde para começar. "*

**Antônio Rogério de Lima Grego**

# Resumo

As técnicas de análise e previsão de séries temporais alcançaram uma posição de distinção na literatura ao longo dos anos. A utilização de recursos computacionais, combinada com técnicas estatísticas, apresenta resultados mais precisos quando comparados com os recursos separadamente. Em particular, técnicas que usam Redes Neurais Artificiais (RNA) e Computação Evolutiva (CE), apresenta uma posição de destaque na resolução de problemas de previsão na análise de séries temporais. Estas técnicas de Inteligência Artificial (AI) são inspiradas biologicamente, no qual o modelo de RNA é baseado na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência. Para o problema de previsão em séries temporais, um fator importante para o maior desempenho na previsão é encontrar um método preditivo com a melhor acurácia possível, tanto quanto possível, no qual o desempenho do método pode ser analisado através de erros de previsão. Entretanto, não existe um critério universal para identificar qual a melhor medida de desempenho a ser utilizada para a caracterização da previsão. Uma vez que as RNAs são os modelos de previsão, a CE constantemente avaliará o desempenho de previsão das RNAs, usando uma função de fitness para guiar o modelo preditivo para uma solução ótima. Desejando verificar quais critérios seriam mais eficientes no momento de escolher o melhor modelo preditivo, a Análise Envoltória de Dados (DEA) é aplicada para fornecer a melhor combinação de variáveis visando a otimização do modelo. Portanto, nesta dissertação, foi estudado o processo de otimização de Funções de Fitness através do uso da Análise Envoltória de Dados utilizando-se de técnicas híbridas de Inteligência Artificial aplicadas a área de previsão de séries temporais. O banco de dados utilizado foi obtido de séries históricas econômico- financeiras, fenômenos naturais e agronegócios obtidos em diferentes órgãos específicos de cada área. Quanto à parte operacional, utilizou-se a linguagem de programação C para implementação do sistema híbrido inteligente e o ambiente R versão 2.12 para a análise dos modelos DEA. Em geral, a perspectiva do uso da DEA para avaliar as Funções de Fitness foi satisfatório e serve como recurso adicional na área de previsão de séries temporais. Cabe ao pesquisador, avaliar os resultados sob diferentes óticas, quer seja sob a questão do custo computacional de implementar uma determinada Função que foi mais eficiente ou sob o aspecto de avaliar quais combinações não são desejadas poupando tempo e recursos.

**Palavras-chave:** Previsão de Séries Temporais, Redes Neurais Artificiais, Estratégia Evolutiva, Sistemas Híbridos Inteligentes, Otimização, Função de Fitness;

# Abstract

The techniques for Time Series Analysis and Forecasting have great presence on the literature over the years. The computational resources combined with statistical techniques are improving the predictive results, and these results have been become increasingly accurate. Computational methods base on Artificial Neural Networks (ANN) and Evolutionary Computing (EC) are presenting a new approach to solve the Time Series Analysis and Forecasting problem. These computational methods are contained in the branch of Artificial Intelligence (AI), and they are biologically inspired, where the ANN models are based on the neural structure of intelligent organism, and the EC uses the concept of nature selection of Charles Darwin. Both methods acquire experience from prior knowledge and example of the given problem. In particular, for the Time Series Forecasting Problem, the objective is to find the predictive model with highest forecast performance, where the performance measure are statistical errors. However, there is no universal criterion to identify the best performance measure. Since the ANNs are the predictive models, the EC will constantly evaluate the forecast performance of the ANNs, using a fitness functions to guide the predictive model for an optimal solution. The Data Envelopment Analysis (DEA) was employed to predictive determine the best combination of variables based on the relative efficiency of the best models. Therefore, this work to study the optimization Fitness Function process with Data Envelopment Analysis applied the Intelligence Hybrid System for time series forecasting problem. The data analyzed are composed by financial data series, agribusiness and natural phenomena. The C language program was employed for implementation of the hybrid intelligent system and the R Environment version 2.12 for analysis of DEA models. In general, the perspective of using DEA procedure to evaluate the fitness functions were satisfactory and serves as an additional resource in the branch of time series forecasting. Researchers need to compute the results under different perspectives, whether in the matter of the computational cost of implementing a particular function or which function was more efficient in the aspect of assessing which combinations are unwanted saving time and resources.

**Key-words:** Time Series Forecasting, Artificial Neural Networks, Evolution Strategies; Hybrid Intelligent Systems, Optimization, Fitness Function;



# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Introdução . . . . .	1
1.2	Motivação e Objetivos . . . . .	3
1.3	Estrutura da Dissertação . . . . .	4
<b>2</b>	<b>Revisão de Literatura</b>	<b>5</b>
2.1	Séries Temporais . . . . .	5
2.1.1	Introdução . . . . .	5
2.1.2	Decomposição Clássica . . . . .	6
2.1.3	Processo Estocástico . . . . .	7
2.1.4	Estacionariedade . . . . .	8
2.1.5	Função de Autocorrelação Amostral (FAC) . . . . .	8
2.1.6	Alguns Processos Estocásticos típicos . . . . .	8
2.1.6.1	Processo Puramente Aleatório . . . . .	8
2.1.6.2	Passeio Aleatório . . . . .	9
2.1.7	Previsão de Séries Temporais . . . . .	10
2.2	Redes Neurais Artificiais . . . . .	11
2.2.1	Introdução . . . . .	11
2.2.2	Representação de uma RNA . . . . .	11

2.2.3	Função de Ativação . . . . .	13
2.2.3.1	Função Sigmóide . . . . .	13
2.2.4	Redes Neurais Perceptron Multi-Camadas (MLP) . . . . .	14
2.2.4.1	Estrutura da rede . . . . .	14
2.2.4.2	Processo de Aprendizagem . . . . .	15
2.2.5	Redes Neurais Aplicadas ao Problema de Previsão . . . . .	15
2.3	Estratégia Evolutiva . . . . .	17
2.3.1	Introdução . . . . .	17
2.3.2	Descrição do Algoritmo . . . . .	18
2.3.3	Representação . . . . .	19
2.3.4	Mutação . . . . .	20
2.3.5	Seleção . . . . .	20
2.3.6	Estratégia Evolutiva para o Treinamento de Redes Neurais . . . . .	21
2.4	Análise Envoltória de Dados . . . . .	22
2.4.1	Introdução . . . . .	22
2.4.2	Modelos Clássicos da Análise Envoltória de Dados . . . . .	23
2.4.2.1	Modelo CCR . . . . .	23
2.4.2.2	Modelo BCC . . . . .	24
2.4.3	Propriedades dos modelos em DEA . . . . .	25
<b>3</b>	<b>Caracterização das Séries e das Medidas de Desempenho para a Previsão</b>	<b>26</b>
3.1	Caracterização das Séries . . . . .	26
3.1.1	Série das Manchas Solares (Sunspot) . . . . .	26
3.1.2	Série do Índice SP&500 . . . . .	28
3.1.3	Série de produção mensal de leite . . . . .	28
3.2	Métricas de Desempenho para a Previsão . . . . .	29
3.2.1	MSE( <i>Mean Square Error</i> ) . . . . .	29

3.2.2	MAPE( <i>Mean Absolute Percent Error</i> ) . . . . .	30
3.2.3	Estatística U de THEIL . . . . .	30
3.2.4	ARV( <i>Average Relative Variance</i> ) . . . . .	31
3.2.5	POCID( <i>Prediction of Change in Direction</i> ) . . . . .	31
<b>4</b>	<b>Materiais e Métodos</b>	<b>32</b>
4.1	Introdução . . . . .	32
4.2	Procedimentos adotado para as RNAs . . . . .	33
4.3	Procedimentos adotado para as EE . . . . .	33
4.4	Estrutura das Simulações . . . . .	35
4.5	Procedimentos para a DEA . . . . .	36
4.5.1	Definição das variáveis . . . . .	36
4.5.2	Teste de Hipóteses para escolha do modelo em DEA . . . . .	38
<b>5</b>	<b>Resultados e Discussão</b>	<b>40</b>
5.1	Comparação entre grupos de DMUs . . . . .	40
5.1.1	Caso 1: Inclusão ou não inclusão da métrica POCID . . . . .	40
5.1.2	Caso 2: Comparação dos grupos de Funções de Fitness em termos da eficiência . . . . .	43
5.2	Análise dos resultados para a série Sunspot . . . . .	44
5.2.1	Introdução . . . . .	44
5.2.2	Resultados utilizando DEA para a Série Sunspot: Caso Geral . . . . .	45
5.2.3	Resultados utilizando DEA para a Série Sunspot: Caso Específico . . . . .	49
5.3	Análise dos resultados para a série SP&500 . . . . .	54
5.3.1	Introdução . . . . .	54
5.3.2	Resultados utilizando DEA para a Série SP&500: Caso Geral . . . . .	55
5.3.3	Resultados utilizando DEA para a Série SP&500: Caso específico . . . . .	57
5.4	Análise dos resultados para a série Produção Mensal de Leite . . . . .	58

5.4.1	Introdução . . . . .	58
5.4.2	Resultados utilizando DEA para a Série de Produção de Leite: Caso Geral . . . . .	59
5.4.3	Resultados utilizando DEA para a Série Produção de Leite: Caso Específico . . . . .	62
<b>6</b>	<b>Conclusões</b>	<b>64</b>
6.1	Conclusões . . . . .	64
6.2	Trabalhos Futuros . . . . .	66
	<b>Apêndice A Estratégia Evolutiva de dois membros</b>	<b>67</b>
	<b>Apêndice B Teste para diferenças entre grupos</b>	<b>69</b>
B.1	Teste de Kolmogorov-Smirnoff para duas amostras . . . . .	69
B.2	Teste de Kruskal-Wallis . . . . .	70
	<b>Apêndice C Método Bootstrap</b>	<b>71</b>
C.1	Introdução . . . . .	71
C.2	Utilização do método <i>bootstrap</i> em DEA . . . . .	72
C.2.1	Correção de Viés . . . . .	72
	<b>Apêndice D Resultados dos Modelos DEA e Testes de Hipóteses</b>	<b>74</b>
D.1	Introdução . . . . .	74
	<b>Bibliografia</b>	<b>98</b>

# Lista de Figuras

1	(a) População americana (1790-1990). (b) Acidentes nos EUA (1973-1978)	6
2	Processo estocástico como uma família de variáveis aleatórias [9]. . . . .	7
3	Modelo não-linear de um neurônio [1]. . . . .	12
4	Função Sigmóide com o parâmetro de inclinação $a$ variável. . . . .	13
5	Arquitetura de uma rede sem realimentação (feedforward) para uma camada escondida. . . . .	14
6	Diagrama de um sistema de aprendizado supervisionado. . . . .	15
7	Superfície adaptativa com dois traços. . . . .	17
8	Pseudocódigo de uma estratégia de dois membros. . . . .	18
9	Exemplo de DEA com um recurso (input) e um produto (output) . . . . .	23
10	Projeção do sol com manchas solares usando um telescópio. . . . .	27
11	Gráfico da série anual das manchas solares (Série Normalizada entre 0 e 1). . . . .	27
12	Gráfico da série mensal do índice S&P500 . . . . .	28
13	Produção mensal de leite nos USA - (1962 a 1975) . . . . .	29
14	Procedimento da Estratégia Evolutiva utilizado nas simulações. . . . .	35
15	Fluxograma da sequência de procedimentos adotados . . . . .	37
16	Comparação entre os grupos G1 (com a métrica POCID e G2 (sem a métrica POCID) para as Séries: (a) Sunspot, (b) SP500 e (c) Série Produção de Leite. . . . .	42
17	(a) Série anual de Manchas Solares. (b) Função de Autocorrelação . . . . .	45

18	Fronteira DEA com correção de viés para a Série Sunspot (Caso geral). . .	46
19	Figura comparativa entre a série real Sunspot (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes (Caso geral). . . . .	47
20	Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série Sunspot no caso geral. . . . .	48
21	Valores previstos para Série Sunspot utilizando as DMUs menos eficientes (Caso geral). . . . .	49
22	Fronteira BCC-I para a série Sunspot (Caso específico) . . . . .	51
23	Gráfico comparativo entre a série real Sunspot (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes. ( <i>inputs</i> : MSE, ARV, THEIL) . . . . .	51
24	Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série Sunspot no caso específico ( <i>inputs</i> : MSE, ARV, THEIL). . . . .	52
25	Gráfico comparativo entre a série real Sunspot (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes. ( <i>input</i> MAPE). . . . .	53
26	Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série Sunspot no caso específico ( <i>input</i> : MAPE). . . . .	53
27	Valores previstos para Série Sunspot utilizando as DMUs menos eficientes(Caso Específico). . . . .	54
28	(a) Série do índice SP&500. (b) Função de Autocorrelação . . . . .	54
29	Gráfico comparativo entre a série real SP&500 (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes.(Caso geral). . . . .	56
30	Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série SP&500. . . . .	56
31	Valores previstos para Série Sp&500 utilizando as DMUs menos eficientes. . . . .	57
32	(a) Série de Produção Mensal de Leite. (b) Função de Autocorrelação . . . . .	59
33	Fronteira BCC-I para a série de Produção de Leite(Caso geral) . . . . .	60

34	Gráfico comparativo entre a série real Produção de Leite (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes. (Caso geral) . . . . .	61
35	Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série Sunspot no caso geral. . . . .	61
36	Valores previstos para Série Produção de Leite utilizando as DMUs menos eficientes . . . . .	62
37	Fronteira BCC-I para a série Produção de Leite(caso específico) . . . . .	63

# Lista de Tabelas

1	Funções de Fitness utilizada nos experimentos . . . . .	36
2	Teste de Hipóteses utilizando o método bootstrap . . . . .	39
3	Resultado do Teste de Hipóteses para diferenças entre grupos . . . . .	41
4	Teste de Kruskal-Wallis para diferenças entre grupos . . . . .	43
5	Resumo das medidas estatísticas para a Série Sunspot . . . . .	44
6	Eficiências e estimativas para a Série Sunspot: Caso geral. . . . .	45
7	Valores dos critérios AIC, BIC e MAPE para a oito Funções de Fitness mais eficientes na série Sunspot (caso geral). . . . .	49
8	Eficiências e estimativas para a Série Sunspot: Caso específico . . . . .	50
9	Valores dos critérios AIC, BIC e MAPE para as Funções de Fitness mais eficientes na série Sunspot no caso específico:( <i>inputs</i> : MSE, ARV, THEIL) . . . . .	52
10	Resumo das medidas estatísticas para a Série SP&500 . . . . .	55
11	Eficiências e estimativas para a Série SP&500: Caso geral . . . . .	55
12	Valores dos critérios AIC, BIC e MAPE para as Funções de Fitness mais eficientes na série SP&500 . . . . .	57
13	Eficiências e estimativas para a Série SP&500: Caso Específico . . . . .	58
14	Resumo das medidas estatísticas para a Série Produção Mensal de Leite. . . . .	59
15	Eficiências e estimativas para a Série de Produção de Leite: Caso geral . . . . .	60
16	Valores dos critérios AIC, BIC e MAPE para as Funções de Fitness mais eficientes na série Produção de Leite . . . . .	62



17	Eficiências e estimativas para a Série de Produção de Leite: Caso específico	63
18	Resultado do Teste de Tukey para as séries analisadas . . . . .	75
19	Eficiências classificadas por grupo: Série Sunspot . . . . .	79
20	Eficiências classificadas por grupo: Série SP&500 . . . . .	80
21	Eficiências classificadas por grupo: Série Produção de Leite . . . . .	81
22	Eficiências e estimativas para o caso geral . . . . .	82

# Introdução

## 1.1 Introdução

A arte de realizar previsão acerca de eventos futuros baseado em acontecimentos passados é um processo que fascina a décadas diversos pesquisadores em diversos campos da ciência. Como afirma *McCloskey* em *Art of Forecasting: From Ancient to Modern Times* [1], as pessoas sempre desejaram saber sobre o futuro, desde que sobre elas mesmas ou sobre algum acontecimento. Quando o assunto é economia e negócios, o sentimento de decisão do investidor está associado ao conhecimento técnico que o mesmo possui sobre o mercado em que está investindo. Este conhecimento pode ser auxiliado pelo prévio histórico passado do índice financeiro em questão ou sobre seu possível comportamento futuro. Quando se trata de fenômenos climáticos, o pesquisador pode ter interesse em antecipar fenômenos críticos, como por exemplo, alguma catástrofe baseado em informações recorrentes de históricos passados do clima de determinada região. Os exemplos citados podem ser caracterizados através de uma série temporal.

Uma série temporal é uma sequência discreta ou contínua de observações à respeito de um dado fenômeno ordenada sobre um índice qualquer cronológico, na maioria das vezes o tempo. Em termos práticos, na maioria dos casos, a observação de um fenômeno resulta em uma amostragem discreta de dados, preferencialmente equidistantes temporalmente. O estudo do comportamento de séries de temporais visando obter previsões acerca de determinado fenômeno evoluiu bastante com o passar dos anos. Com a utilização de recursos computacionais cada vez mais avançados, aliados as técnicas estatísticas, uma maior precisão vem sendo incorporado aos resultados, levando inclusive a um menor custo

de tempo para a geração dos mesmos.

Diversas técnicas foram incorporadas e melhoradas ao longo dos anos, mas todas com o mesmo intuito de encontrar o melhor modelo que pudesse antecipar o acontecimento de determinado fenômeno. Uma forma de checar qual modelo tem melhor resultado quanto à previsão é verificando o seu erro de previsão. Quanto menor o erro, mais o modelo estará ajustado ao fenômeno estudado.

Como mencionado no parágrafo anterior, as técnicas veêm se sofisticando ao longo dos anos visando otimizar o processo de previsão. Vários modelos estatísticos (lineares e não lineares) são propostos na literatura como o modelo linear de Box and Jenkins, mais conhecido como ARIMA (*Auto Regressive Integrated Moving Average*) [2] ou como os modelos não-lineares GARCH (*Generalized Autoregressive Conditional Heterocedastic*) [3, 4], dentre tantos outros. Uma abordagem alternativa ao problema de previsão e análise de séries temporais vem sendo desenvolvida a partir de técnicas de Inteligência Artificial, como Redes Neurais Artificiais (RNAs) [5] ou Algoritmos Evolutivos (AE) [6] cujos procedimentos simulam respectivamente o funcionamento do cérebro humano e técnicas inspiradas na Teoria da Evolução de Charles Darwin.

No entanto, as RNA's quando aplicados ao problema de previsão de séries temporais utilizam uma série de parâmetros a serem ajustados como a topologia da rede, nº de camadas, nº de neurônios por camada, função de ativação, etc. Determinar quais são os valores ótimos pode ser um difícil processo. Para ajustar todos esses parâmetros algumas técnicas híbridas baseada na combinação de RNA's com Algoritmos Evolutivos tem sido utilizadas na literatura, de forma que uma compense a deficiência da outra, como pode ser visto em [7, 8].

Segundo *Eiben e Smith* [6], o processo evolutivo baseado na seleção natural é realizado de forma que cada indivíduo da população tem as mesmas chances de serem soluções do problema. A partir de uma função de desempenho (Função de Fitness) os indivíduos são escolhidos para gerar a próxima geração até que se encontre uma solução ótima. No caso do sistema híbrido cada indivíduo da população do AE representa uma RNA onde o cromossomo é formado pelos parâmetros da rede a serem ajustados. Cada RNA apresenta um erro de previsão que é guiado pela Função de Fitness até que se encontre a solução ótima. Dessa forma, a Função de Fitness desempenha um papel importante para obtenção dos ajustes dos parâmetros no processo de busca da solução.

Para o maior desempenho na previsão de uma serie temporal é desejado um método preditivo com a melhor acurácia possível, podendo este modelo ser analisado através das medidas de erros de previsão. Na literatura estão dispostas diversas medidas de erros,

dentre as quais pode-se citar: erro quadrático médio (MSE), erro percentual médio absoluto (MAPE), entre vários outros [7]. Entretanto, mesmo com uma intensa pesquisa na área de previsão de séries temporais, não existe um critério universal para identificar qual a melhor medida de desempenho a ser utilizada para a caracterização da previsão.

Como é possível determinar a Função de Fitness (ou Função Objetivo) mais eficiente para o adequado ajuste do modelo, gerando uma melhor relação custo/precisão na previsão? Uma possível abordagem para o problema exposto é utilizar o conceito de eficiência a partir da metodologia de Análise Envoltória de Dados (DEA) de maneira que se encontre uma curva de eficiência onde as medidas de erros de previsão são minimizadas e/ou maximizadas de forma que cada função de desempenho represente uma unidade de avaliação a ser analisada. Dessa forma, essas Funções de Fitness podem ser comparadas em termos de eficiência e análises estatísticas, e com o uso de testes de hipóteses, pode-se auxiliar no aumento da acurácia dos resultados.

## 1.2 Motivação e Objetivos

Existem diversas aplicações da Análise Envoltória de Dados na avaliação da eficiência encontrados na literatura. Como pode ser visto em *Kassai* [9] existem aplicações da DEA na eficiência do faturamento de supermercados, eficiência em plataformas de petróleo, crescimento de produtividade no setor agropecuário. Também se tem utilização da DEA junto com as Redes Neurais Artificiais como técnica híbrida de avaliação de eficiência como visto no trabalho de *Wu, Yang e Liang* [10].

A motivação pelo determinado estudo parte do fato que o uso da Análise Envoltória de Dados como técnica de eficiência para otimização da Funções de Fitness é algo que pode ajudar a entender o processo de acoplamento das medidas de desempenho em relação a cada série estudada através da eficiência de cada unidade de avaliação representada pelas Funções de Fitness.

Esta dissertação tem como objetivo principal estudar o processo de otimização de Funções de Fitness através do uso da Análise Envoltória de Dados utilizando-se de técnicas híbridas de Inteligência Artificial aplicadas à área de previsão de séries temporais.

Com a coleta de dados de séries temporais, pretende-se aplicar técnicas de computação evolutiva e redes neurais artificiais para a modelagem e previsão. Uma vez que uma metodologia seja construída, é desejada a caracterização em desempenho e eficiência tanto na qualidade da previsão como a correta escolha e ajuste dos parâmetros.

Os objetivos específicos dessa dissertação podem ser enumerados como:

1. Modelar as séries temporais com técnicas não-lineares da Inteligência Artificial, em particular as Redes Neurais Artificiais do tipo MLP;
2. Estabelecer procedimento evolutivo para a busca do ajuste ótimo dos modelos preditivos eleitos através da computação evolutiva, em particular com o uso de estratégias evolutivas;
3. Determinar possíveis formas de guiar a evolução dos modelos preditivos. (determinação e análise de Funções de Fitness);
4. Analisar a eficiência da metodologia proposta com o uso das técnicas da DEA (*Data Envelopment Analysis*);

### 1.3 Estrutura da Dissertação

A presente dissertação está estruturada em cinco capítulos sendo que:

- No Capítulo 1 é apresentada uma introdução sobre a questão da otimização de Funções de Fitness na área de previsão de séries temporais, além da motivação, objetivos e estrutura da presente dissertação.
- No Capítulo 2 é apresentado uma revisão da literatura com aspectos conceituais sobre Séries Temporais, Redes Neurais Artificiais, Estratégia Evolutiva e Análise Envolvória de Dados.
- No Capítulo 3 é apresentada a descrição das séries utilizadas nesta dissertação e das métricas de desempenho de previsão.
- No Capítulo 4 é apresentado os materiais e métodos utilizados nessa dissertação.
- No Capítulo 5 é apresentado os Resultados e Discussões sobre a aplicação da DEA na otimização de Funções de Fitness.
- No Capítulo 6 é apresentada as conclusões dos procedimentos, técnicas e experimentos realizados e apresentados e a perspectiva para trabalhos futuros na área.

# Capítulo 2

## Revisão de Literatura

Nesse capítulo é apresentada uma revisão sobre as metodologias utilizadas nessa dissertação. As seções estão divididas em quatro partes: Séries Temporais, Redes Neurais Artificiais, Estratégia Evolutiva e Análise Envoltória de Dados. É descrito em cada seção uma breve introdução a respeito de cada método.


### 2.1 Séries Temporais

Neste tópico será abordada uma área de profundo interesse em diversos campos da ciência, a análise de séries temporais. O objetivo desta seção é apresentar uma introdução e definições básicas a respeito deste assunto, indicando inclusive algumas referências mais refinadas como [2, 11–13].

#### 2.1.1 Introdução

Uma série temporal é uma sequência discreta ou contínua de observações a respeito de um dado fenômeno ordenada sobre um índice qualquer cronológico, na maioria das vezes o tempo. Representa-se uma série temporal discreta como um conjunto,

$$Z_t = \{z_t \in \mathbb{R} | t = 1, 2, 3, \dots, N\}$$



**Figura 1** – (a) População americana (1790-1990). (b) Acidentes nos EUA (1973-1978)

sendo  $t$  um índice cronológico, comumente o tempo, e  $N$  o número total de observações. Tal seqüência pode ser definida em instantes de tempo discreto (enumerável) ou contínua (não-enumerável). Na Figura 1, é mostrado exemplos de séries temporais. O objetivo ao analisar uma série temporal pode ser descrição e a análise do comportamento das séries com o intuito de verificar se existe algum padrão de tendência, valores discrepantes, variação sazonal ou alterações na estrutura da mesma [14]. Pode haver o interesse em modelar os fenômenos geradores dos processos que descrevem o comportamento da série, podendo inclusive obter previsões a respeito do fenômeno estudado.

### 2.1.2 Decomposição Clássica

De acordo com *Chatfield* [13], métodos tradicionais de análise de séries temporais se preocupam em decompor a variação em uma série em tendência, variação sazonal, mudanças cíclicas e o restante em flutuações irregulares. Esta não é a melhor abordagem, porém é particularmente importante quando a variação é dominada pela tendência e/ou sazonalidade. No entanto, vale a pena notar que a decomposição não é geralmente a única suposição a ser feita. Assim, algum tipo de modelagem explícita ou implícita pode ser envolvida nestas técnicas descritivas. As variações podem ser descritas como:

1. **Tendência:** é a parte da série temporal que indica um movimento regular de crescimento ou decréscimo por um longo período de tempo. Este tipo de movimento pode apresentar padrões lineares, exponenciais ou amortecidos a depender do fenômeno estudado.
2. **Cíclica:** Não considerando os efeitos sazonais, algumas séries temporais apresen-

tam variações em um período fixo, como por exemplo, a variação diária na temperatura.

3. **Sazonal:** Muitas séries temporais apresentam variações que são em períodos anuais. Por exemplo, o índice de desemprego pode ser alto no inverno mas baixo no verão. Este tipo de variação é fácil de ser entendida e deve-se medida explicitamente e/ou removida dados gerando dados desazonalizados.
4. **Aleatória:** Este tipo de componente refere-se a variações que não ocorrem com regularidade (eventos extremos, tais como: inundações, greves, desastres) que podem alterar o comportamento da série.


Considerando uma serie temporal  $\{Z_t, t = 1, \dots, N\}$  o modelo clássico pode assumir a seguinte forma de decomposição

$$Z_t = T_t + S_t + a_t$$

onde  $T_t$  representa a tendência,  $S_t$  a componente sazonal e  $a_t$  é uma componente aleatória de média zero e variância  $\sigma_a^2$ .

### 2.1.3 Processo Estocástico

O processo gerador de uma série temporal pode ser um processo determinístico ou estocástico. Um processo estocástico é uma família de variáveis aleatórias  $Z_t; t \in T$  definidas num mesmo espaço de probabilidades. Ou seja, para cada  $t \in T$ ,  $Z_t$  é uma variável aleatória definida sobre o espaço amostral. Portanto,  $Z_t$  é uma função de dois argumentos,  $Z(t, w)$ , onde  $t \in T$  e  $w \in \Omega$ . Na Figura 2 observa-se que, para cada  $t \in T$ ,  $Z(t, w)$  é uma variável aleatória com uma distribuição de probabilidade. Por outro lado, para cada  $w \in \Omega$  fixado, obtemos uma função do tempo, ou seja, uma realização do processo [15].



**Figura 2** – Processo estocástico como uma família de variáveis aleatórias [9].



## 2.1.4 Estacionariedade

A suposição fraca de estacionariedade num processo estocástico significa que sua média e variância são constantes ao longo do tempo e o valor da covariância entre dois períodos de tempo depende somente da distância entre os dois períodos e não do tempo atual na qual a variância é calculada [16]. De maneira formal, seja  $Z_t$  uma série temporal estocástica com média, variância e covariância dada respectivamente por

$$E(Z_t) = \mu$$

$$var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$$

$$\gamma_k = E[(Z_t - \mu)(Z_{t+k} - \mu)]$$

onde  $\gamma_k$  é a covariância no lag  $k$  entre os valores de  $Z_t$  e  $Z_{t+k}$ . Se  $k = 0$ , obtêm  $\gamma_0$  que é simplesmente a variância de  $Z$ . Se  $k = 1$ ,  $\gamma_1$  é a covariância entre dois valores adjacentes de  $Z$ . Sendo uma série estacionária, independente de mudar a origem de  $Z_t$  para  $Z_{t+m}$  a média, a variância e a covariância (de vários lags) não é alterada.

## 2.1.5 Função de Autocorrelação Amostral (FAC)

A função de autocorrelação teórica (FAC) de um processo estocástico estacionário é uma ferramenta fundamental quando se deseja descrever o comportamento da série [14]. Na prática, como só se dispõe da amostra de um processo estocástico estima-se a função de autocorrelação amostral a qual é definida como,

$$r_k = \frac{c_k}{c_0} = \frac{\sum (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum (Z_t - \bar{Z})^2}$$

onde  $r_k$  é a função de autocorrelação amostral no lag  $k$ ,  $c_k$  a covariância amostral e  $c_0$  a variância amostral. O gráfico de  $r_k$  por  $k$  tem o nome de correlograma amostral e serve para indicar quando a série é estacionária ou não [2].

## 2.1.6 Alguns Processos Estocásticos típicos

### 2.1.6.1 Processo Puramente Aleatório

Um processo no tempo discreto é considerado puramente aleatório, as vezes chamado de ruído branco, se consistir de uma seqüência de variáveis mutuamente independente e

identicamente distribuídas [13]. Sendo  $u_t$  tal seqüência, sua média e variância são constantes e a sua função de autocovariância, para  $k = \pm 1, 2, \dots$ , é dada por,

$$\gamma_k = \text{cov}(Z_t, Z_{t+k}) = 0$$

Como a média e a função de autocovariância não dependem do tempo, este processo é estacionário de segunda ordem e sua função de autocorrelação é dada por

$$\rho_k = \begin{cases} 1, & \text{se } k = 0 \\ 0, & \text{se } k = \pm 1, \pm 2 \end{cases}$$

### 2.1.6.2 Passeio Aleatório

Segundo *Gujarati* [16], sendo  $u_t$  um processo puramente aleatório não correlacionado com média  $\mu$  e uma variância constante  $\sigma^2$ . Então a série  $Z_t$  é um passeio aleatório se

$$Z_t = Z_{t-1} + u_t$$

O valor de  $Z$  no tempo  $t$  é igual ao seu valor no tempo  $(t - 1)$  mais um choque aleatório. Seja  $Z_0 = 0$  no tempo  $t = 0$  então

$$Z_1 = u_1$$

$$Z_2 = Z_1 + u_2 = u_1 + u_2$$

$$Z_3 = Z_2 + u_3 = u_1 + u_2 + u_3$$

e de forma geral,

$$Z_t = \sum u_t$$

cuja esperança é  $E(Z_t) = t\mu$  e a variância é  $\text{Var}(Z_t) = t\sigma$ . Como a média e a variância dependem do tempo  $t$  este processo é considerado não estacionário. Contudo se tomarmos a primeira diferença de um passeio aleatório tem-se um processo estacionário já que,

$$Z_t - Z_{t-1} = u_t$$

O passeio aleatório tem grande representação na área de econometria e finanças como, por exemplo, o preço e títulos de ativos financeiros. Uma leitura mais aprofundada pode ser encontrada em *Spitzer* [17] e *Malkiel* [18].

## 2.1.7 Previsão de Séries Temporais

Dentre os interesses na análise de séries temporais, citado na seção 2.1, está a previsão de eventos futuros. A habilidade de executar uma boa previsão dependerá da metodologia utilizada aliada ao fenômeno estudado pelo pesquisador. Todavia, as dificuldades encontradas pelo pesquisador são que as previsões não são normalmente perfeitas, pois prever o futuro envolve muitas incertezas. Desta maneira o objetivo na hora de se realizar previsão é reduzir o erro de previsão o máximo possível para que se tenham melhores resultados diante do problema estudado. A escolha do melhor modelo ou técnica para previsão, dentre muitos fatores, depende do grau de precisão que é requerido, qual o horizonte de previsão almejado, qual o custo para produzir as previsões é tolerado e qual o tipo de dados utilizado [19]. Segundo *Chatfield* [13] os métodos para realizar previsão podem ser divididos em três partes:

1. Método Subjetivo - As previsões podem ser feitas utilizando um julgamento subjetivo ou até mesmo a intuição baseado nas experiências obtidas por quem é especialista no fenômeno estudado. Tais previsões são feitas quando os processos para a análise dos dados não são bem específicos [20].
2. Univariado - Este método compreende a maior parte dos métodos de previsão mais utilizados na literatura e se utiliza da idéia de que a previsão de uma determinada série temporal é baseada somente em seus valores passados, então,  $Z_t$  depende somente  $Z_{t-1}, Z_{t-2}, \dots$ .
3. Multivariado - Quando as previsões de uma determinada variável dependem totalmente ou em parte de outras séries para que se tenham diagnósticos sobre a mesma. Como exemplo, as previsões de venda de determinado produto pode depender de índices e ações da bolsa de valores.

Diversos modelos são encontrados na literatura como modelos lineares de médias móveis [11], alisamento exponencial [19], metodologia Box & Jenkins [2] ou modelos não-lineares como modelos ARCH (*Autoregressive Conditional Heterocedasticity*), GARCH (*General Autoregressive Conditional Heterocedasticity*) e TAR (*Threshold Autoregressive*) [21]. Para tais, outras modelagens podem ser utilizadas como alternativa aos modelos clássicos (tanto lineares como não lineares) como o caso de técnicas utilizando Redes Neurais Artificiais [22] e Computação Evolutiva [8] que serão abordados nas próximas seções.

## 2.2 Redes Neurais Artificiais

### 2.2.1 Introdução

Uma rede neural artificial (RNA) é um sistema de processamento paralelo e massivo que tem características em sistemas neurais biológicos, em especial, o cérebro humano [23]. Seu processamento baseia-se em modelos matemáticos que seguem os seguintes pressupostos:


- O processamento da informação ocorre em elementos chamados neurônios;
- Os neurônios são interligados através de conexões (sinapses);
- Cada conexão tem um peso associado, onde cada neurônio aplica uma função de ativação (geralmente não-linear) à entrada da rede para determinar a saída da rede.

As RNA's têm diversas aplicações em campos como reconhecimento de padrões e processamento de sinais [24, 25], sensoriamento remoto [26] e na análise de séries temporais [8, 27], dentre outras. Em especial, em se tratando de previsão de séries temporais, as RNA's constituem uma importante ferramenta. Tal afirmação baseia-se em suas características de aprendizagem baseadas no conhecimento adquirido através dos relacionamentos e da estrutura existente na série temporal do fenômeno estudado.

### 2.2.2 Representação de uma RNA

A forma mais comum de visualização dos neurônios de uma RNA do tipo Perceptron [5] é por meio de uma disposição de camadas. O arranjo dos neurônios dentro das camadas e o padrão de conexão entre elas é chamada de arquitetura da rede [23]. Na Figura 3 é mostrado um simples modelo de rede neural e seus elementos básicos: Segundo *Haykin* [5], neste modelo são identificados três elementos básicos:

1. Um conjunto de sinapses de entrada, onde cada entrada é ponderada por um peso. Essa ponderação é feita de maneira que um sinal  $x_j$  na entrada da sinapse  $j$  conectada ao neurônio  $k$  é multiplicado pelo peso sináptico  $w_{kj}$ . A ordem dos índices adotada na *figura 3* significa que o primeiro índice refere-se ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse à qual o peso se refere.



**Figura 3** – Modelo não-linear de um neurônio [1].

2. Um operador soma, para somar os sinais de entrada ponderados pelas respectivas sinapses do neurônio.
3. Uma função de ativação para a restrição da amplitude de saída do neurônio. Essa função, geralmente é não linear e o intervalo de amplitude da saída de um neurônio é escrito como o intervalo fechado  $(0,1)$  ou  $(-1,1)$ .

Também são incluídos nesse modelo um viés, representado por  $b_k$ , que é aplicado nesse modelo com o intuito de aumentar ou diminuir a entrada líquida da função de ativação de acordo com o sinal (positivo ou negativo) da mesma. Em termos matemáticos pode-se descrever um neurônio  $k$  através das seguintes equações:

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

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

onde,  $x_m$  é o sinal de entrada,  $w_{km}$  os pesos do neurônio  $k$ ,  $u_k$  é a saída da combinação linear a partir dos sinais de entrada,  $b_k$ , o bias,  $\varphi(\cdot)$  a função de ativação e  $y_k$  o sinal de saída do neurônio.

## 2.2.3 Função de Ativação


A função de ativação, definida por  $\varphi(\cdot)$ , pode ter diversos formatos dependendo do tipo de saída que se deseja. Segundo *Haykin* [5], destacam-se três tipos básicos de funções: Função de Limiar, Linear por Partes e Sigmóide. Esta última função será a utilizada nesta dissertação e na próxima subseção é apresentada a descrição da mesma.

### 2.2.3.1 Função Sigmóide

Este tipo de função estritamente crescente é a forma mais comum de função utilizada na construção de RNA's. Um exemplo conhecido é a função logística, definida como:

$$\varphi(v) = \frac{1}{1 + \exp(-av)}$$

onde  $a$  é o parâmetro de inclinação da função. Variando-se o parâmetro  $a$ , obtêm-se funções sigmóides com diferentes inclinações como pode ser visto na Figura 4. Uma



**Figura 4** – Função Sigmóide com o parâmetro de inclinação  $a$  variável.


função sigmóide possui um intervalo contínuo variando entre 0 e 1. Quando o valor do parâmetro de inclinação tende ao infinito a função sigmóide acaba se tornando uma função de limiar, cujo valores tendem a 0 ou a 1.

## 2.2.4 Redes Neurais Perceptron Multi-Camadas (MLP)

Dentre os modelos existentes de RNA's, as redes neurais Perceptrons Multi-Camadas (MLP) são as mais usadas quando se trata de problemas envolvendo previsão de séries temporais devido a sua praticidade e eficiência [27].

### 2.2.4.1 Estrutura da rede

As redes MLP consistem de um conjunto de unidades que constituem a camada de entrada (onde a informação é apresentada a rede), uma ou mais camadas ocultas e uma camada de saída (onde é produzida a resposta final do modelo). Os sinais são propagados para frente através da rede camada por camada [5]. Quando o fenômeno estudado se trata de previsão de séries temporais, a camada de entrada é formada pelas observações passadas da série estudada e a camada de saída formada pelo valor previsto conforme observada na Figura 5. Um ponto de fundamental importância para uma rede neural é a




**Figura 5** – Arquitetura de uma rede sem realimentação (feedforward) para uma camada escondida.

sua habilidade de aprendizado a partir do seu ambiente e de melhora do seu desempenho através da aprendizagem. Tal maneira é feita através de ajustes aplicados a seus pesos sinápticos e ao nível de viés do modelo de forma que a rede seja mais instruída a respeito do seu ambiente após cada fase do processo de aprendizagem [5].

### 2.2.4.2 Processo de Aprendizagem

Numa rede MLP, o processo de aprendizado é realizado de forma supervisionada, onde para cada padrão de entrada é observado um padrão de saída de maneira que a rede ajuste seus pesos de forma a conseguir minimizar o erro entre a saída da rede (resposta observada) e o padrão de saída (resposta desejada) [27]. Na Figura 6 é apresentado um diagrama que mostra a relação de aprendizado num ambiente supervisionado. O professor



**Figura 6** – Diagrama de um sistema de aprendizado supervisionado.

pode ser considerado como sendo o elemento que tem conhecimento sobre o ambiente em que está envolvido, sendo este ambiente representado por elementos de entrada-saída que são desconhecidos pela rede neural utilizada. À medida que é apresentado ao professor um conjunto de treinamento, este é capaz de fornecer a rede neural uma resposta desejada para o determinado vetor de treinamento. Tal resposta representa a melhor ação a ser tomada pela rede neural. Os parâmetros dessa rede são ajustados pela combinação do vetor de treinamento e pelo sinal do erro [5].

### 2.2.5 Redes Neurais Aplicadas ao Problema de Previsão

A utilização das redes neurais ao problema de previsão de séries temporais é uma aplicação que vem sendo utilizada há algumas décadas como forma alternativa aos modelos clássicos de previsão. Uma das razões da utilização das RNA's é que além de ser um modelo não-linear, podendo este estar mais relacionado a fenômenos do mundo real, as



RNAs tem a capacidade de aproximar qualquer função contínua com uma precisão desejada qualquer [28]. As redes MLP mencionadas na seção 2.2.4 são usadas no problema de previsão de séries temporais com bastante eficiência por sua capacidade de mapear arbitrariamente entradas e saídas. Quando aplicadas ao problema de previsão as variáveis de entrada (*input*) são geralmente as observações passadas da série de dados e as saídas (*output*) representam os valores futuros. Este tipo de relação funcional pode ser representado pela função,

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-p})$$

sendo  $y_t$  as observações no tempo  $t$ . Tal relação indica a dependência no tempo presente em relação aos valores passados baseado numa relação funcional não-linear. Antes que as RNAs desempenhem um bom papel como modelo para previsão de um determinado fenômeno existe a necessidade do treinamento da mesma. Tal treinamento é fator primordial para a determinação dos pesos que compõe a estrutura da rede. O conjunto de dados apresentado à rede para o treinamento geralmente é dividido em um conjunto de treinamento (50% da massa total de dados), conjunto de validação (25% da massa total de dados) e conjunto de teste (25% da massa total de dados). O processo de treinamento consiste em apresentar a rede um número fixo de observações da série a cada iteração. Supondo que se tenha  $N$  observações  $y_1, \dots, y_N$  e deseja-se obter a previsão um passo a frente, utiliza-se uma RNA com  $n$  entradas, tendo  $(N - n)$  padrões de treinamento. Os padrões apresentados a rede são dispostos da seguinte maneira,

$$y_1, y_2, \dots, y_n \rightarrow y_{n+1}$$

$$y_2, y_3, \dots, y_{n+1} \rightarrow y_{n+2}$$

$$y_{N-n}, y_{N-n+1}, \dots, y_{N-1} \rightarrow y_N$$

onde as variáveis da esquerda representa o conjunto de dados apresentados a rede (*input*) e as variáveis da direita são os horizontes de previsão (*output*). Em geral, deseja-se minimizar a função objetivo durante o processo de treinamento. Comumente é utilizado uma função baseada na medida de desempenho SSE (Sum of Square for Error) dado por,

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

em que  $a_i$  representa a saída da rede e  $y_i$  a saída desejada. A tarefa de construir e treinar uma rede neural para um determinado problema de previsão não é uma tarefa fácil devido a arquitetura de entradas, saídas e conexões entre as duas camadas não ser um processo bem definido. Existem muitas técnicas para determinar a arquitetura da rede, porém, como afirmada em *Zhang, Patuwo et al.* [22] a determinação da estrutura de uma RNA é mais uma arte do que uma ciência. A definição da estrutura da rede neural utilizada nessa


dissertação bem como o processo de construção da mesma será apresentada e discutida na seção destinada aos materiais e métodos no capítulo 4.

## 2.3 Estratégia Evolutiva

### 2.3.1 Introdução

A computação evolutiva constitui um ramo da Inteligência Artificial (IA) cuja família de algoritmos é inspirada na teoria da evolução de Darwin, baseando-se nos mecanismos encontrados na natureza, como a auto-organização e o comportamento adaptativo.

A teoria da evolução de Darwin oferece uma explicação da diversidade biológica de maneira que a seleção natural dos indivíduos desempenha um papel central no processo de evolução. A seleção natural favorece aqueles indivíduos que competem por um determinado recurso de forma mais efetiva ou que se ajusta melhor as condições do ambiente. De forma geral, como os indivíduos mais bem sucedidos tem uma maior chance de se reproduzir, sua informação genética tende a se perpetuar. Contudo, a natureza tem um procedimento que gera diversidade na população: a mutação. As mutações, quando ocorrem, dão origem a novos indivíduos que com o passar do tempo dão novas características a população [6]. Este processo é bem capturado pela noção de uma superfície adaptativa como mostrado na Figura 7.



**Figura 7** – Superfície adaptativa com dois traços.

O plano  $x-y$  retém todas as combinações possíveis de variáveis, ou traços e os valores de  $z$  mostram seus fitness. Uma dada população pode ser representada como um con-

junto de pontos desta superfície, onde cada ponto é um indivíduo realizando uma possível combinação de variáveis. A evolução é então o processo de avanços graduais da população para grandes altitudes, movidas pela variação e seleção natural. Em um determinado momento da evolução existe um número de pontos que são melhores do que todas suas soluções vizinhas. *Tais pontos são chamados de ótimo local. Se a altura deste ponto for em relação ao plano é chamada de ótimo global.* [6] Os algoritmos desenvolvidos a partir dessa idéia de evolução biológica são chamados de Algoritmos Evolucionários (AEs). Uma variedade de AEs é proposta na literatura como Algoritmos Genéticos (AG), Programação Evolutiva (PE) e Estratégia Evolutiva (EE) [6]. O princípio por trás deste tipo de algoritmo segue a idéia de que dada uma população de indivíduos, a pressão ambiental causa a seleção natural (sobrevivência do mais apto), o qual causa uma ascensão na aptidão (fitness) da população. Dada uma função característica (de qualidade) para ser maximizada, cria-se um conjunto de soluções candidatas e aplica-se a função característica como uma medida de função abstrata - quanto maior melhor.

### 2.3.2 Descrição do Algoritmo

A Estratégia Evolutiva (EE) é um algoritmo evolucionário, criado por Rechenberg and Schwefel na década de 60 [29, 30], com o objetivo principal de resolver problemas de otimização. Eles desenvolveram um esquema denominado estratégia de dois membros ou (1+1)-EE que consiste de uma população formada por um indivíduo ascendente (pai) e um descendente (filho) criado através de um processo de mutação usando uma distribuição normal com média zero e desvio padrão igual a 1. Na Figura 8 é apresentado o pseudocódigo representando uma estratégia de dois membros:

```

Inicie t = 0;
Crie o ponto inicial  $X^t = (X_1^t, X_2^t, \dots, X_n^t)$ ;
enquanto critério de parada não satisfeito faça
  Gere  $Z_i$  ( $z_i$  gerada a partir de uma Dist. Normal);
   $Y_i^t = X_i^t + Z_i$ ;
  se  $f(X_i^t) < f(Y_i^t)$  então
    senão
       $X^{t+1} = Y^t$ ;
    fim
  Faça  $t = t + 1$ ;
fim

```

**Figura 8** – Pseudocódigo de uma estratégia de dois membros.

O esboço apresentado na Figura 8 mostra que dada uma solução  $x^t$ , sendo  $t$  o número

de gerações até a condição de parada ser satisfeita e  $n$  o tamanho do vetor correspondente ao indivíduo, uma nova solução candidata  $x^{t+1}$  é criada adicionando um número aleatório  $z_i$  a cada um dos  $n$ 's componentes da solução  $x^t$ . O novo indivíduo  $x^{t+1}$  é aceito como novo membro da população mediante a condição da sua função de desempenho ser melhor que o seu antecedente, senão, permanece o mesmo indivíduo original até a próxima iteração.

Rechenberg em suas pesquisas com a estratégia de dois membros verificou a partir de dois diferentes modelos de função objetivo (modelo esférico e um modelo de passagem)<sup>1</sup> que a taxa máxima de sucesso de convergência no processo de mutação corresponde a um valor particular da probabilidade de se obter o sucesso, isto é, melhorando o valor da função objetivo. Com base nisto ele formulou uma regra de sucesso para controlar o tamanho das mudanças aleatórias, chamada de regra de sucesso 1/5 onde de tempos em tempos na busca pela solução ótima obtém-se a frequência de sucessos. Essa frequência corresponde a razão entre o número de sucessos e o número total de mutações. Se essa relação for maior que 1/5 deve-se incrementar o desvio padrão, caso contrário, deve-se decrementar o desvio padrão [31]. De maneira formal temos,

$$\left\{ \begin{array}{l} \frac{\sigma}{c}, \text{ se } p_s > 1/5 \\ \sigma.c, \text{ se } p_s < 1/5 \\ \sigma, \text{ se } p_s = 1/5 \end{array} \right.$$

onde  $p_s$  é a porcentagem de mutações com sucesso e o parâmetro  $c$  está no intervalo  $0,817 \leq c \leq 1$  [29]. Este tipo de estratégia permitiu ter uma idéia básica para facilitar a transição para a estratégia soma ( $\mu + \lambda$ ) e a estratégia vírgula ( $\mu, \lambda$ ), onde  $\mu$  representa os ascendentes (pais) e  $\lambda$  os descendentes (filhos). No caso da estratégia soma, durante a etapa de seleção os pais são levados em consideração, enquanto na estratégia virgula, só os filhos sobrevivem a medida que os pais morrem. A descrição dos procedimentos para a formalização do algoritmo  $ES - (1 + 1)$  é detalhada em *Beyer* [32] e *Schwefel* [31].

### 2.3.3 Representação

Na estratégia evolutiva o cromossomo representando o indivíduo é dividido em três partes compostas de:

1. Variáveis Objetos  $X_1, X_2, \dots, X_n$ , representando a parte do genótipo do cromossomo.

---

<sup>1</sup>Esses dois modelos podem ser lidos no catálogo de problemas apresentados no anexo A do artigo de Schwefel [31].

2. Parâmetro da estratégia, representando o fenótipo, formado pelos passos da mutação  $\sigma_1, \sigma_2, \dots, \sigma_{n\sigma}$  e pelos ângulos de rotação  $\alpha_1, \alpha_2, \dots, \alpha_{n\alpha}$ .

O ângulo de rotação que representa as interações entre o tamanho do passo usado para diferentes variáveis nem sempre é utilizado por representar um alto custo computacional de implementação e desempenho [33]. O tamanho total do cromossomo é dado por,

$$\langle X_1, X_2, \dots, X_n, \sigma_1, \sigma_2, \dots, \sigma_{n\sigma}, \alpha_1, \alpha_2, \dots, \alpha_{n\alpha} \rangle$$

### 2.3.4 Mutação

A mutação numa EE, como mencionado na seção 2.3.2, é baseada numa distribuição normal com média  $\mu$  e um desvio padrão  $\sigma$ . Na prática e nesse trabalho essa média é zero, e o processo de mutação ocorre quando se transforma o vetor formado pelo cromossomo  $(\langle X_1, X_2, \dots, X_n \rangle, (\sigma_1, \sigma_2, \dots, \sigma_{n\sigma}))$  através de um mecanismo de mutação por auto adaptação, como descrito em *Eiben e Smith* [6], *Heitkoetter e Beasley* [30], *Beyer e Schwefel* [34], dado por,

$$\sigma_i' = \sigma_i e^{\tau' \cdot N(0,1) + \tau \cdot N_i(0,1)}$$

$$x_i' = x_i + \sigma_i \cdot N_i(0, 1)$$

onde  $\tau$  e  $\tau'$  são interpretados como a taxa de aprendizagem e seus parâmetros são definidos como  $\tau = (\sqrt{2\sqrt{n}})^{-1}$  e  $\tau' = (\sqrt{2n})^{-1}$ . Uma regra é aplicada para evitar valores de mutação muito próximos de zero considerando,

$$\sigma_i' < \epsilon_0 \Rightarrow \sigma_i' = \epsilon_0$$

### 2.3.5 Seleção

Numa EE a seleção dos pais é feita sem tendência e com uma distribuição uniforme onde todo o individuo tem a mesma probabilidade de ser escolhido. Após criar  $\lambda$  descendentes a partir de  $\mu$  pais e calcular sua aptidão (fitness) decide-se qual melhor individuo. A forma da seleção pode priorizar a permanência dos pais na próxima geração junto com os filhos (estratégia  $(\mu + \lambda)$ ) ou filtrar somente a permanência dos filhos (estratégia  $(\mu, \lambda)$ ). Segundo Eiben [6], a utilização da estratégia  $(\mu, \lambda)$  é melhor por ser capaz de fugir ótimos locais no processo de busca.

### 2.3.6 Estratégia Evolutiva para o Treinamento de Redes Neurais

O procedimento de construir e treinar uma rede neural para um determinado problema não é uma tarefa fácil devido a arquitetura de entradas, saídas e conexões entre as duas camadas não ser um processo bem definido. Existe uma grande quantidade de parâmetros a serem estimados e a definição dos valores dos pesos no treinamento de uma rede pode sofrer influencia de mínimos locais a depender do método que esteja sendo usado, como por exemplo, o treinamento por retropropagação (backpropagation) [35]. Para suprir tais dificuldades, a utilização de algoritmos evolutivos tem trazidos bons resultados devido a sua capacidade de busca global. É possível utilizar os algoritmos evolutivos tanto para o ajuste dos pesos quanto para definição da arquitetura da rede. O procedimento para o treinamento da RNA funciona de maneira que, no processo evolutivo, cada individuo representa uma RNA onde o fitness ou desempenho dessa rede é medido de acordo com o erro da resposta da rede e a saída desejada. Uma rotina típica para o ajuste de pesos de uma rede neural através da evolução é apresentada a seguir e pode ser vista com detalhes em Yao [36].

1. Leia cada individuo (cromossomo) da geração atual num conjunto de pesos e construa a rede neural correspondente.
2. Calcule o erro quadrático médio entre o erro da resposta da rede e a saída desejada e defina o desempenho (*fitness*) do individuo para o qual a rede neural é construída baseada neste erro quadrático médio. (Podem ser usadas outras funções de desempenho, que não o erro quadrático médio).
3. Reproduza um determinado número de filhos para cada individuo a partir da população atual com probabilidade de acordo com o *fitness*.
4. Aplique um operador genético, como a mutação, para obter uma nova geração.

Baseado nessa metodologia utilizou-se nessa dissertação a estratégia evolutiva como algoritmo evolutivo para o treinamento das redes neurais. A dificuldade encontrada é o grande numero de parâmetros a ser ajustado o que torna o custo computacional mais elevado. Sendo a rede MLP utilizada nessa dissertação composta de uma única camada escondida com  $b$  neurônios, e os padrões de entrada representados por  $a$  e uma única saída de rede, temos uma quantidade de variáveis dado por:

$$N^{\circ}variaveis = [(1 + a + ab + 2b + 1)] / 2$$

Este valor foi dividido por dois devido a população numa estratégia evolutiva ser composta de variáveis objetos e dos parâmetros da estratégia que tem o mesmo número de elemen-

tos sem contar o ângulo de rotação, conforme visto na subseção 2.3.3.

## 2.4 Análise Envoltória de Dados


### 2.4.1 Introdução

A história da Análise Envoltória de Dados (*Data Envelopment Analysis - DEA*) começou a partir das discussões sobre como medir a eficiência da produtividade de indústrias através do trabalho de M.J.Farrel chamado de "The measurement of productive efficiency". Nesse artigo, publicado na *Journal of the Royal Society* em 1957, Farrel propõe estabelecer uma medida satisfatória de eficiência produtiva e aplica este método para a produção agrícola nos Estados Unidos [37]. Utilizando os conceitos propostos por Farrel, o modelo DEA inicial foi introduzido com a dissertação de Edward Rhodes sob a supervisão de W. W. Cooper na *H.J. Heinz III School of Public Policy and Management* [38]. O objeto do estudo da dissertação era avaliar um programa educativo para alunos carentes desenvolvido em escolas públicas dos Estados Unidos. A análise consistia em comparar o desempenho de um conjunto combinado de distritos escolares que participavam ou não do programa educativo utilizando medidas como auto-estima da criança ou o tempo gasto pela mãe em leitura com o filho. O objetivo era estimar a eficiência técnica <sup>2</sup>relativa das escolas envolvendo múltiplas variáveis de entradas e saída o que resultou na formulação do modelo CCR (*Charnes, Cooper e Rhodes*) e na publicação do primeiro artigo envolvendo DEA na *European Journal of Operations Research* em 1978 [38].

Segundo Soares [39], a Análise Envoltória de Dados é uma ferramenta matemática para medir eficiência de unidades produtivas, onde tais unidades, chamadas de DMU (*Decision Making Unit*) são capazes de tomar decisões que levem a uma maior produtividade. A produtividade pode ser entendida como a razão entre o que foi produzido e a quantidade de recursos disponível. Já a eficiência compara o que foi produzido, dado a quantidade de recursos disponíveis, com o que poderia ter sido produzido com os mesmos recursos. Na Figura 9 é mostrado um exemplo da relação entre recurso (input) versus produto (output). A curva *D* é chamada de Fronteira de Eficiência e as unidades que se encontram sobre ela são eficientes (*unidades B e C*). As unidades que se encontram abaixo da curva estão na região chamada de Conjunto Viável de Produção (*unidade A*). A unidade mais produtiva será aquela cujo coeficiente angular da reta ligada a origem é o maior possível. Observando a Figura 9 a unidade *C* além de ser eficiente é ainda a mais produtiva. A unidade

---

<sup>2</sup>A eficiência de uma firma é definida por Farrell [37] como sendo a produção máxima que se pode alcançar dado uma quantidade de recursos disponível.



**Figura 9** – Exemplo de DEA com um recurso (input) e um produto (output)

*A* é não produtiva e não eficiente. Conforme Soares [39], caso a DMU *A* deseje se tornar eficiente terá que reduzir os recursos, mantendo constantes os produtos, percorrendo o caminho até a DMU *C* (*orientação a inputs*). Ou então, aumentar os produtos até a DMU *B* mantendo constantes os recursos (*orientação a outputs*).

## 2.4.2 Modelos Clássicos da Análise Envoltória de Dados

Existem dois modelos que são considerados clássicos na Análise Envoltória de Dados: o modelo CCR (proposto por Charnes, Cooper e Rhodes [38]) e o modelo BCC (Banker, Charnes e Cooper [40]).

### 2.4.2.1 Modelo CCR

O modelo CCR trabalha com retornos constantes de escala, isto é, qualquer variação nos recursos (*inputs*) produz variação proporcional nos produtos (*outputs*) [39]. Esse modelo é conhecido como modelo CRS - *Constant Returns to Scale*. Uma versão do modelo CCR cujo objetivo é minimizar os *inputs* enquanto satisfaz ao menos um dado nível de *outputs* é chamado de modelo CCR orientado a *inputs*. Uma outra versão é a orientada a *outputs* cujo objetivo é maximizar os recursos (*inputs*) sem que se altere os produtos (*outputs*). O modelo CCR orientado a *inputs* é descrito em Meza, Gomes e Fernandes [41] como,



$$\max h_o = \sum_{j=1}^m u_j y_{jo}$$

sujeito a

$$\begin{aligned} \sum_{i=1}^n v_i x_{io} &= 1 \\ \sum_{j=1}^m u_j y_{jk} - \sum_{i=1}^n v_i x_{ik} &\leq 0, k=1, \dots, s \\ u_j, v_i &\geq 0 \forall i, j \end{aligned}$$

onde  $h_o$  é a eficiência da DMU  $o$ .  $x_{ik}$  representa o *input*  $i$  da DMU  $k$  e  $y_{ik}$  representa o *output*  $j$  da DMU  $k$ .  $v_i$  representa o peso atribuído ao *input*  $i$  e  $u_j$  o peso do *output*  $j$ . Cada DMU  $k$  ( $k = 1, \dots, s$ ) é uma unidade de produção que utiliza  $n$  *inputs*  $x_{ik}$ ,  $i = 1, \dots, n$ , para produzir  $m$  *outputs*  $y_{jk}$ ,  $j = 1, \dots, m$ . Este modelo maximiza o quociente entre a combinação linear dos *outputs* e *inputs* tendo como restrição de que esse quociente não pode ser maior que 1 [41]. O objetivo é encontrar pesos  $u_j$  e  $v_i$  que maximizem a razão da DMU  $o$ , a DMU que está sendo calculada [42].

#### 2.4.2.2 Modelo BCC

O modelo BCC (*Banker, Charnes e Cooper* [43]), considera retornos variáveis de escala, por isso é também conhecido como VRS - *Variable Returns to Scale*. Este tipo de modelo considera que a relação entre *inputs* e *outputs* não são proporcionais, ou seja, aquelas DMUs que operam com baixos valores de *inputs* tenham retornos crescentes de escala e as que operam com altos valores tenham retornos decrescentes de escala [39]. Tal modelo é descrito como (conforme descrito em Angulo-Meza et al [41]),

$$\max h_o = \sum_{j=1}^p u_j y_{jo} - w$$

sujeito a

$$\begin{aligned} \sum_{i=1}^m v_i x_{io} &= 1 \\ \sum_{j=1}^s u_j y_{jk} - \sum_{i=1}^n v_i x_{ik} - w &\leq 0, k=1, \dots, n \\ u_j, v_i &\geq 0 \forall x, y \\ w &\in \mathfrak{R} \end{aligned}$$

onde  $h_o$  é a eficiência da DMU  $o$ .  $x_{ik}$  representa o *input*  $i$  da DMU  $k$  e  $y_{ik}$  representa o *output*  $j$  da DMU  $k$ .  $v_i$  representa o peso atribuído ao *input*  $i$  e  $u_j$  o peso do *output*  $j$ .  $u$  é um factor de escala que quando tem sinal positivo indica que a DMU está em região de retornos decrescentes de escala. Caso seja negativo, os retornos de escala são crescentes.

### 2.4.3 Propriedades dos modelos em DEA

Conforme descrito em Soares [39] os modelos em DEA tem algumas propriedades em comum e outras características que são individuais. Pode-se citar,

- cada DMU escolhe seu próprio conjunto de pesos.
- Todos os modelos são invariantes com a escala de medida.
- Em qualquer modelo DEA, a DMU que apresentar a melhor relação (*output*)/(*input*) será sempre eficiente;
- O modelo CCR tem como propriedade principal a proporcionalidade entre inputs e outputs na fronteira, ou seja, o aumento (decremento) na quantidade dos inputs, provocará acréscimo (redução) proporcional no valor dos outputs.
- No modelo BCC, a DMU que tiver o menor valor de um determinado input ou o menor valor de um certo output será eficiente. A esta DMU chamamos de eficiente por default ou eficiente à partida;

# Capítulo 3

## Caracterização das Séries e das Medidas de Desempenho para a Previsão

Neste capítulo é apresentada uma descrição e características das séries utilizadas neste trabalho como conjunto de teste além da motivação pelo uso das mesmas. Além disso, é apresentada as métricas de desempenho utilizadas como funções de fitness para avaliar o desempenho dos resultados obtidos.

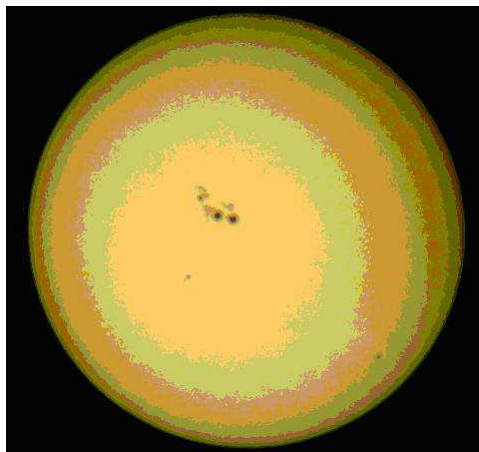
### 3.1 Caracterização das Séries

As séries utilizadas nessa dissertação são compostas por dados de séries financeiras, agrária e fenômeno natural.

#### 3.1.1 Série das Manchas Solares (Sunspot)

O corpo celeste mais proeminente em nosso sistema solar é o Sol que contém cerca de 98% da massa total do sistema solar físico total. A temperatura superficial do Sol é de 5780K, mas no núcleo a temperatura chega a milhões de graus. As características mais claras da variabilidade solar são as mudanças com o tempo no número de manchas solares (*sunspot*) vistas na parte visível do Sol [44]. A Figura 10 apresenta uma fotografia da superfície do Sol, onde as manchas solares aparecem como características mais escuras.

Prever o comportamento das atividades solares, diretamente influenciada pelas manchas




**Figura 10** – Projeção do sol com manchas solares usando um telescópio.

que se formam nesse corpo celeste, sempre foi de intenso interesse da comunidade científica [45]. O início das observações diárias das manchas solares começaram em 1746, sendo atualmente o número de manchas, utilizado para a construção da série, calculado pela contagem do número de grupos e o número de manchas individuais, seguindo a seguinte expressão,

$$R = k(10G + S)$$


onde  $S$  é o número de manchas individuais,  $G$  é o número de grupos de manchas e  $k$  um fator de qualidade, utilizado depois da comparação dos resultados das medidas de vários pontos de observações diferentes [27]. A série *sunspot* utilizada nessa dissertação consiste de dados anuais das manchas solares no período de 1700 e 1988, composto por 289 pontos. Tal série foi obtida do Centro de Dados do Índice Sunspot [46] e na Figura 11 é mostrado o gráfico onde se observa o seu comportamento não-linear.



**Figura 11** – Gráfico da série anual das manchas solares (Série Normalizada entre 0 e 1).

### 3.1.2 Série do Índice SP&500

O Índice SP&500 (*Standard & Poor 500*) é um índice ponderado de valores de mercado de 500 ativos (ações) que são negociadas nas bolsas da New York Stock Exchange (NYSE), American Stock Exchange (AMEX), e no Nasdaq National Market System. Este índice foi amplamente considerado como o melhor indicador único do grande mercado de ações nos EUA desde que o índice foi publicado pela primeira vez em 1957. O índice inclui 500 empresas líderes em setores de ponta da economia dos EUA, capturando a cobertura de 75% das ações dos EUA [47]. O ponderamento do índice, que significa multiplicar o valor do ativo pelo número de ações em circulação, faz as influências de cada companhia sobre a apresentação do índice ser diretamente proporcional ao seu valor de mercado. A série utilizada nesta dissertação consiste de observações mensais no período de janeiro de 1970 a agosto de 2003, consistindo de 369 pontos. A Figura 12 apresenta o gráfico da série S&P500.




**Figura 12** – Gráfico da série mensal do índice S&P500

### 3.1.3 Série de produção mensal de leite

O leite é rico em uma grande quantidade de nutrientes essenciais ao crescimento e a manutenção de uma vida saudável [48]. No âmbito econômico, o leite tem uma grande importância no mercado agropecuário mundial. Só em 2007, a produção mundial de leite de vaca foi de cerca de 560 bilhões de toneladas, com cerca de 70% produzidos na Europa e na América [49]. A série utilizada consiste da produção de leite mensal nos Estados Unidos, sendo composta de 168 pontos coletados mensalmente entre janeiro de 1962 e dezembro de 1975. Tais dados foram obtidos no NASS (*National Agricultural Statistics*

Service) setor que faz parte do USDA (*United States Department of Agriculture*). Consultar a referência [50] para maiores informações a respeito do banco de dados. Na Figura 13 é mostrado o gráfico de tal série. Percebe-se que esta série apresenta tendência e uma alta sazonalidade.



**Figura 13** – Produção mensal de leite nos USA - (1962 a 1975)

## 3.2 Métricas de Desempenho para a Previsão

Quando o problema em estudo se trata de previsão de séries temporais a medida natural que é utilizada como desempenho para a série estudada é a própria previsão alcançada [27]. As medidas de desempenho são baseadas a partir do erro de previsão e não existe um consenso no meio acadêmico sobre qual medida apresenta melhores resultados. Estudos utilizando diversas métricas de desempenho [8] [51] mostram que a depender do tipo de série temporal estudada, uma determinada medida pode apresentar melhores resultados na caracterização da série estudada. O erro de previsão é formulado como a diferença entre o valor atual da série e o valor previsto (ou valor de saída do modelo) e é definido pela equação,

$$e_t = (target_t - output_t)$$

Para o presente estudo foi utilizado cinco medidas de desempenho, as quais são descritas nos próximos subtópicos.

### 3.2.1 MSE(Mean Square Error)

O erro quadrático médio (MSE) é a medida de desempenho mais comumente usada pela literatura para previsão de séries temporais. Entretanto, de acordo com Collopy, Arm-

strong e Dept [52] os resultados empíricos obtidos por [52–54] demonstram que esta medida não é confiável quando se deseja comparar métodos de previsão. Sua equação é dada por,

$$MSE = \frac{1}{N} \sum_{t=1}^N (e_t)^2$$

onde  $N$  indica o número de pontos da série e  $e_t = (T_t - O_t)$  o erro de previsão no tempo  $t$ . O erro de previsão é composto pelo valor desejado ( $T_t$ ) e o valor previsto ( $O_t$ ).

### 3.2.2 MAPE(Mean Absolute Percent Error)

O erro percentual absoluto médio (MAPE) é expresso pela seguinte fórmula [55]:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{e_t}{A_t} \right|$$

onde  $A_t$  é a observação atual no tempo  $t$ ,  $F_t$  é a previsão feita para o período  $t$  e  $N$  a quantidade de pontos previstos. O MAPE é a medida de acurácia mais usada quando se deseja comparar diferentes séries temporais mas apresenta a desvantagem de ser relevante apenas para dados em escala, ou seja, dados com um zero significativo [51].

### 3.2.3 Estatística U de THEIL

A estatística U-Theil se baseia no erro médio quadratico normalizado (NMSE) dividido pelo erro de previsão de um modelo do tipo Random Walk que assume que o melhor valor de previsão para o tempo  $t + 1$  é o valor obtido no tempo  $t$  [8]. Sua equação é dada por,

$$THEIL = \frac{\sum_{t=1}^N (T_j - O_j)^2}{\sum_{t=1}^N (T_j - T_{j+1})^2}$$

para valores onde  $Theil = 1$  o preditor tem um desempenho igual a um Random Walk; se o valor for maior que 1 o desempenho é inferior; Se o valor for menor que 1 o preditor terá um desempenho menor que um modelo do tipo Random Walk. Essa estatística num modelo ideal deve tender a zero.

### 3.2.4 ARV(Average Relative Variance)

A medida de desempenho denominada ARV (*Variância Relativa Média*) é dada por,

$$ARV = \frac{\sum_{t=1}^N (O_j - T_j)^2}{\sum_{t=1}^N (O_j - \bar{T})^2}$$

onde  $O_t$  representa o valor observado enquanto que  $T_j$  representa a previsão.  $\bar{T}$  representa a média dos valores observados entre o conjunto de dados. O ARV divide a soma do quadrado do erro pela variância da série levando-se em conta a flutuação e o alisamento da série [56]. Se o  $ARV = 1$ , o modelo é equivalente a calcular a média da série e utilizar esta média como sendo a previsão. Se o  $ARV > 1$ , então o modelo é inferior a previsão pela média da série, e se o  $ARV < 1$ , então o desempenho do modelo de previsão é superior a quando comparado a previsão através da média da série. Em um modelo ideal ARV deve tender a zero [27].

### 3.2.5 POCID(Prediction of Change in Direction)

O POCID é uma medida de desempenho cuja característica é medir o percentual de acerto quanto à tendência da série e sua equação é dada por,

$$POCID = 100 \frac{\sum_{t=1}^N D_t}{N}$$

onde,

$$D_j = \begin{cases} 1, \text{ se } (T_j - T_{j-1})(O_j - O_{j-1}) > 0 \\ 0, \text{ caso contrário} \end{cases}$$

Mais a respeito das medidas de desempenho apresentadas nessa seção podem ser vistas nos artigos [8, 20, 51] e em [57–59].



# Capítulo 4

## Materiais e Métodos

### 4.1 Introdução

Esta dissertação é um estudo em otimização de Funções de Fitness utilizando-se como metodologia um sistema híbrido inteligente, combinando Rede Neurais Artificiais (RNA's) e Estratégia Evolutiva (EE) aplicada na área de previsão em séries temporais . A Estratégia Evolutiva é utilizada como forma de treinamento das RNA's onde cada indivíduo da população da EE representa uma RNA do tipo MLP [5] sendo seu cromossomo formado por todos os parâmetros da RNA a serem ajustados - pesos e conexões. Os indivíduos da população são avaliados através de uma Função de Fitness que é composta pelas medidas de desempenho em previsão apresentadas no capítulo 3. Como análise posterior aos resultados obtidos pelas simulações é utilizado a Análise Envoltória de Dados (DEA) [38] para avaliar a eficiências dessas medidas de desempenho em relação a cada série temporal utilizada.

O algoritmo para a implementação do sistema híbrido RNA + EE foi desenvolvido na linguagem de programação C. Para a análise dos dados através da DEA foi utilizado o ambiente R versão 2.12 [60] com os pacotes Benchmarking [61] e FEAR versão 1.15 [62]. As séries utilizadas nessa dissertação são provenientes de séries históricas econômicas/financeiras, fenômenos naturais e agronegócios (produção de leite) conforme foi descrito no Capítulo 3.

Neste capítulo é mostrado os procedimentos adotados para a realização das simulações e na análise das eficiências obtidas através da DEA.

## 4.2 Procedimentos adotado para as RNAs

Antes de iniciar a realização dos experimentos, foi necessário executar o procedimento de normalização dos dados. Este tipo de procedimento se dá devido a todos os dados apresentados a rede neural utilizada devem estar sob o domínio da função de ativação empregada. A função de ativação utilizada nessa dissertação é a função sigmóide logística e seu domínio está no intervalo  $[0,1]$ . Existem diversas formas de normalizar os dados, conforme mostrado em *Zhang, Patuwo et al.* [22], sendo o utilizado neste trabalho a transformação linear para o intervalo  $[0,1]$  dado pela equação,

$$X_n = \frac{X - X_{min}}{X_{max} - X_{min}}$$

onde,  $X_n$  são os valores normalizados no intervalo  $(0,1)$ ,  $X$  o valor do conjunto de dados original,  $X_{min}$  o menor valor encontrado no conjunto de dados e  $X_{max}$  o maior valor encontrado no conjunto de dados.

Após normalizar os dados, a série é dividida em três partes: conjunto de treinamento (50% da massa total de dados), conjunto de validação (25% da massa total de dados) e conjunto de teste (25 % da massa total dos dados) conforme utilizado nos trabalhos de *Ferreira* [27], *Rodrigues, Neto e Ferreira* [8] e sugerido pelo *Prechelt et al.* [63]. O conjunto de treinamento é utilizado para o treinamento do modelo da RNA e o conjunto de teste é utilizado para avaliar a habilidade de previsão do modelo. O conjunto de validação é utilizado para resolver o problema de *overfitting* e para controlar o ponto de parada no processo de treinamento [22].

A arquitetura da RNAs utilizada nos experimentos foram todas fixadas na estrutura 3-5-1 totalmente conectada, ou seja, 3 entradas, 5 neurônios na camada escondida e 1 neurônio na camada de saída. A justificativa para tal estrutura se dá pela mesma utilização dessa arquitetura nos trabalhos de *Ferreira* [27] e *Rodrigues, Neto e Ferreira* [8] onde se obteve bons resultados nos valores previstos pela RNA.

## 4.3 Procedimentos adotado para as EE

Conforme descrito no capítulo 2, seção 2.3.6 o procedimento de construir e treinar uma rede neural para um determinado problema não é uma tarefa fácil visto que a definição da arquitetura e definição dos parâmetros da RNA não são um processo bem definido. O cor-

reto ajuste desses parâmetros possibilita a melhora no desempenho da RNA. Para tanto, nessa dissertação é utilizado um sistema híbrido inteligente que combina a Estratégia Evolutiva e a RNA do tipo MLP onde é realizado um processo evolutivo onde cada indivíduo representa uma RNA com parâmetros estruturais fixos.

A estratégia evolutiva usada neste trabalho utiliza-se uma estratégia (1+1), ou Estratégia Soma com um ascendente e um descendente, onde a cada geração uma dada solução gera outra. Nessa operação é aplicada uma mutação seguindo uma distribuição normal até que o descendente substitua seu ascendente quando tiver um melhor desempenho. A rotina para o ajuste dos pesos da RNA segue o seguinte procedimento,

1. É gerada uma população aleatória inicial (no nosso caso, seguindo uma distribuição uniforme entre 0 e 1) que é composta pelos pesos da rede.
2. É calculada o erro da rede e então o indivíduo da população é avaliado através de uma função de desempenho (fitness) utilizando-se as métricas de desempenho apresentadas no capítulo 3.
3. É gerada um descendente mutacionando o indivíduo da população ao adicionar um fator aleatório sendo distribuído normalmente com média 0 e variância 1.
4. É avaliado se o descendente é melhor que seu ascendente através da função de desempenho e enquanto um critério de parada não é atingido volta-se ao passo 2.

Para todas as séries foram utilizados os mesmos parâmetros para a execução das simulações. O tamanho do indivíduo da população é formado pelos pesos da rede e dado por  $n = 57$ . O critério de mutação utilizado foi a mutação não correlacionada dada pela equação,

$$\sigma_i' = \sigma_i e^{\tau \cdot N(0,1) + \tau N_i(0,1)}$$

onde o valor para  $\sigma$  inicial é gerado aleatoriamente por uma distribuição uniforme entre 0 e 1. O valor da taxa de aprendizagem é dada por  $\tau = \left(\sqrt{2\sqrt{57}}\right)^{-1}$  e  $\tau' = \left(\sqrt{114}\right)^{-1}$  [6]. Foi utilizado o valor de  $\epsilon_0 = 0.001$  como regra de restrição para valores de mutação muito próximos de zero<sup>1</sup>. A quantidade de iterações foi de 1000000 e como critério de avaliação dos fitness utilizou-se a validação cruzada com porcentagem de queda do fitness de validação da população igual a 30%. O critério de parada foi definido como: nº de iterações

<sup>1</sup>Segundo *Eiben e Smith* [6] desvios-padrão muito próximo de zero não são interessantes, uma vez que terão um efeito insignificante sobre a média. Para tanto é estabelecido uma regra para forçar o tamanho do passo da mutação ser menor que uma fronteira, ou seja

$$\sigma' < \epsilon_0 \rightarrow \sigma' = \epsilon_0$$

sem que houvesse um novo melhor indivíduo (1% do total de iterações). O procedimento utilizado pela EE combinada com a RNA é descrita no pseudocódigo mostrado na Figura 14,

```

Inicie a = 0 // a - Número de Iterações;
Gere P(a) //População inicial ;
Filho = P(a) + Zi;
Avalia f(Filho) f(.) //Função de Fitness;
enquanto critério de parada não satisfeito faça
| se  $f(\text{Filho}) > f(P(a))$  então
| | P(a+1) =Filho;
| senão
| | P(a+1) =P(a);
| fim
| Faça a = a +1;
fim

```

**Figura 14** – Procedimento da Estratégia Evolutiva utilizado nas simulações.

## 4.4 Estrutura das Simulações

A Função de Fitness desempenha um papel importante para obtenção dos ajustes dos parâmetros no processo de busca da solução em uma RNA. Uma possível Função de Fitness pode ser dada pela equação,

$$Fitness = \frac{1}{1 + erro}$$

Nessa dissertação foram utilizadas 20 diferentes tipos de combinação de Funções de Fitness baseado nas métricas de desempenho apresentadas no Capítulo 3. A Tabela 1 apresenta essas combinações:

**Tabela 1** – Funções de Fitness utilizada nos experimentos

Funções de Fitness			
f1	$\frac{1}{1+ARV}$	f11	$\frac{POCID}{1+ARV}$
f2	$\frac{1}{1+MSE}$	f12	$\frac{POCID}{1+MAPE}$
f3	$\frac{1}{1+MAPE}$	f13	$\frac{POCID}{1+MSE}$
f4	$\frac{1}{1+THEIL}$	f14	$\frac{POCID}{1+THEIL}$
f5	$\frac{1}{1+MSE+ARV}$	f15	$\frac{POCID}{1+MSE+ARV}$
f6	$\frac{1}{1+MSE+MAPE}$	f16	$\frac{POCID}{1+MSE+MAPE}$
f7	$\frac{1}{1+MSE+THEIL}$	f17	$\frac{POCID}{1+MSE+THEIL}$
f8	$\frac{1}{1+ARV+MAPE}$	f18	$\frac{POCID}{1+ARV+MAPE}$
f9	$\frac{1}{1+ARV+THEIL}$	f19	$\frac{POCID}{1+ARV+THEIL}$
f10	$\frac{1}{1+MAPE+THEIL}$	f20	$\frac{POCID}{1+MAPE+THEIL}$

Foram realizadas 30 repetições (simulações)<sup>2</sup> para cada Função de Fitness sendo um total de 600 simulações para cada série temporal utilizada. Para cada melhor indivíduo de cada Função de Fitness são calculados as 5 medidas desempenho apresentadas no Capítulo 3.

## 4.5 Procedimentos para a DEA

### 4.5.1 Definição das variáveis

Segundo *Golany e Roll* [64] as três principais fases para a realização de um estudo de eficiência por meio da DEA são as seguintes:

- Definição e seleção das unidades de decisão (DMU, do inglês *Decision Making Unit*) que irão entrar no modelo.
- Determinação dos fatores de entrada (*inputs* e saída *outputs* que são relevantes e adequados para avaliar a eficiência da DMUs selecionadas.
- Aplicação e análise dos resultados dos modelos DEA.

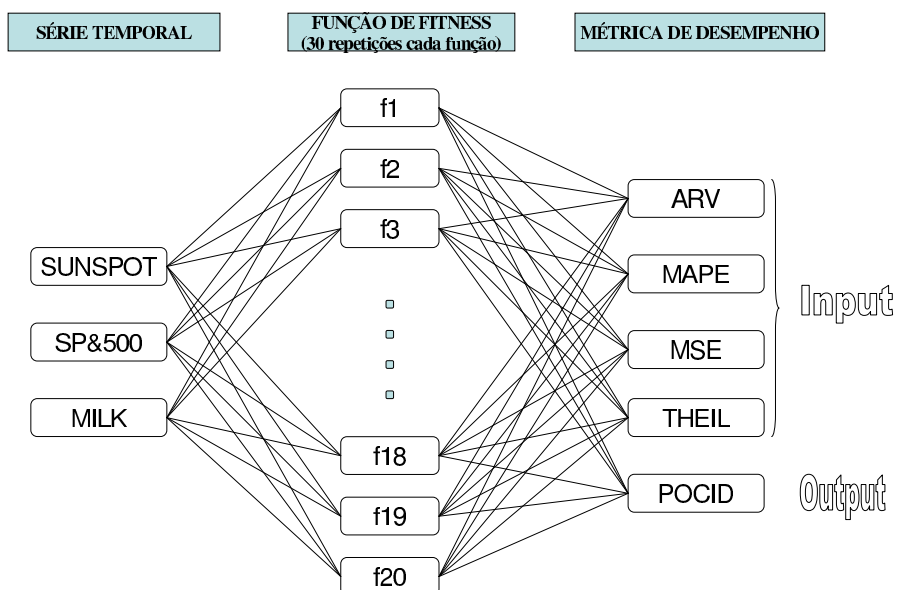
A idéia nessa dissertação é considerar as Funções de Fitness apresentadas na seção anterior como unidades de decisão que serão avaliadas quanto a sua eficiência e então

<sup>2</sup>Esse número de repetições foi realizada com o intuito de obter uma amostra que se aproximasse de uma distribuição normal.

observar as previsões em relação ao conjunto de dados original das unidades que foram mais eficientes. O número de Funções de Fitness apresentadas foram 20, sendo que, para cada uma delas é repetido 30 vezes. Como para cada repetição, existe um individuo com características diferentes foram criadas 20 grupos com 30 unidades. Portanto foram utilizadas 600 DMUs. As variáveis de entrada e saída foram definidas baseadas nas medidas de erro de previsão calculadas após os resultados dos melhores individuos de cada Função de Fitness. De maneira geral, as variáveis no modelo DEA que se deseja minimizar são consideradas *inputs* e as que se deseja maximizar são consideradas como saída, ou *outputs*. No nosso estudo as variáveis são:

- *Inputs*: ARV,MAPE,MSE,THEIL
- *Outputs*: POCID

Duas formas são observadas para as séries. O primeiro caso é minimizar as quatro variáveis de entrada (*insumos*) e maximizar a variável de saída (*produto*). O segundo caso, observa os *inputs* de forma individual para cada uma das 4 medidas de desempenho e o POCID como *output*. O modelo DEA utilizado para todas as séries temporais é o modelo DEA com retornos variáveis de escala orientado a input. O esquema apresentado na Figura 15 demonstra os procedimentos adotados nessa dissertação.



**Figura 15** – Fluxograma da sequência de procedimentos adotados

## 4.5.2 Teste de Hipóteses para escolha do modelo em DEA

Foi utilizado um teste de hipóteses para decidir qual metodologia DEA cada série utilizaria, se o modelo CRS (*Constant Return of Scale*) ou VRS (*Variable Return of Scale*) [38] baseado num teste de hipótese aplicado a DEA apresentado em Bogetoft e Otto [65]. Esse teste de hipóteses é auxiliado pela metodologia *bootstrap* que se baseia nos trabalhos de Simar e Wilson [66] e Simar e Wilson [67]. A discussão da metodologia *bootstrap* é apresentada no Apêndice C.

O intuito do teste aplicado é verificar se o conjunto de DMUs  $K$  apresenta retorno constante de escala, contra a alternativa de que apresenta retorno variáveis de escala, ou seja

$$\begin{cases} H_o : \text{Segue o modelo CRS,} \\ H_a : \text{Segue o modelo VRS.} \end{cases}$$

Se a hipótese nula é verdadeira então as eficiências calculadas para o modelo VRS são as mesmas que as calculadas para o modelo CRS. Se rejeitarmos a hipótese nula, isto significará que ao menos uma das eficiências será diferente. Um caminho apresentado por [65] é observar se a eficiência de escala  $SE^3$  dado por ,

$$SE^k = \frac{E_{CRS}^k}{E_{VRS}^k} \quad (k = 1, \dots, K)$$

é igual a 1 para todas as DMUs, significando que as DMUs seguem o modelo CRS. Para um dado conjunto de observações de  $K$  DMUs rejeita-se a hipótese nula, se ao menos uma das estimativas de  $SE$  tem um valor menor que 1. Porém, segundo [65] como a relação entre o conjunto de tecnologias<sup>4</sup> e as eficiências de escala apresenta uma relação estocástica, devemos rejeitar a hipótese se uma das estimativas de  $SE$  tem o valor significativo menor que 1, isto é, se uma das estimativas for menor que um valor crítico. Bogetoft e Otto afirma que o problema está em calcular esse valor crítico e sugere a seguinte estatística,

$$S = \frac{\sum_{k=1}^K E_{CRS}^k}{\sum_{k=1}^K E_{VRS}^k}$$

onde tem-se que  $Pr(S < c_\alpha | H_0 = \alpha)$ . O valor de  $\alpha$  utilizado foi 0.05 e  $c_\alpha$  é o valor crítico. Como não se sabe a distribuição de  $S$  sob  $H_0$ , então não se pode calcular  $c_\alpha$

<sup>3</sup> $SE$  é a razão entre a eficiência seguindo um modelo com retorno constante de escala (CRS) e um modelo com retornos variáveis de escala (VRS)

<sup>4</sup>O conjunto de tecnologia  $T$  é o conjunto de combinações de  $x$  inputs e  $y$  outputs dado que os inputs podem produzir os  $y$  outputs, ou seja

$$T = \{(x, y) \mid x \text{ produz } y\}$$

diretamente. Através do método bootstrap estima-se a distribuição de  $S$  sob  $H_0$ . O número de réplicas utilizado foi  $n_{rep} = 2000$ . Para cada série temporal com 600 DMUs é calculado as eficiências para os dois tipos de modelos a serem testados e comparados.

A Tabela 2, apresenta os resultados do teste de hipóteses para as três séries.

**Tabela 2** – Resultado do Teste de Hipóteses utilizando o método bootstrap para escolha do modelo DEA

Séries	S	$c\alpha(0,05)$	Quantis						
			1%	2%	5%	10%	15%	30%	50%
Sunspot	0,936844	0,955787	0,952733	0,954271	0,955812	0,958164	0,960107	0,964117	0,969272
SP&500	0,868312	0,715752	0,711745	0,712602	0,715745	0,725123	0,736405	0,762007	0,792499
Leite	0,783449	0,869256	0,863737	0,866898	0,869264	0,870238	0,870333	0,870651	0,874293

Como dito anteriormente, se a estimativa de  $S$  for menor que o valor crítico rejeita-se a hipótese  $H_0$ . Na Tabela 2, observa-se que somente para a série SP&500 o valor crítico está acima da estimativa  $S$ . Essa estimativa foi replicada 2000 vezes (para cada série), por meio do método *bootstrap*. Através dos quantis, existe mais de 50% probabilidade de obter um valor de  $S$  menor do que o obtido para a série SP&500 e portanto somente para essa série rejeita-se  $H_0$ . Os modelo VRS é utilizado para as séries Sunspot e de Leite, e o modelo CRS para a série SP&500.



# Capítulo 5

## Resultados e Discussão

Este capítulo apresenta os resultados oriundos das análises efetuadas nas três séries temporais apresentadas no capítulo 3. As discussões envolvem o processo de otimização das Funções de Fitness utilizando a DEA e a contribuição para o entendimento do comportamento das métricas de desempenho em relação a cada série temporal.

### 5.1 Comparação entre grupos de DMUs

As Funções de Fitness utilizadas nessa dissertação são consideradas unidades que tomam decisões (DMUs). Colocando em termos econômicos, as unidades que foram mais produtivas que outras são aquelas que conseguiram otimizar seus recursos em prol de uma maior produtividade. Dessa forma, as DMUs mais eficientes serão aquelas que obtiveram uma melhor relação entre recursos e produção.

#### 5.1.1 Caso 1: Inclusão ou não inclusão da métrica POCID

No grupo de DMUs utilizadas nessa dissertação, foram mescladas diferentes métricas de desempenho onde a única diferença é inclusão da métrica POCID no numerador das Funções de Fitness, como pôde ser observado na Tabela 1. Mas, será que a inclusão dessa métrica na Função de Fitness proporcionará alguma diferença nas eficiências das DMUs? Nesta seção é utilizado um teste de hipótese para determinar se a eficiência é dependente da inclusão do POCID.

Seja G1 o grupo de Funções de Fitness sem o POCID e G2 o grupo com o POCID incluso na Função de Fitness<sup>1</sup>. Deseja-se testar a hipótese,

$$\begin{cases} H_o : G1 = G2, \\ H_a : G1 \neq G2 \end{cases}$$

Para cada série temporal foram calculadas as eficiências, baseado num modelo DEA com retorno variavel de escala, dos dois grupos G1 e G2 e então calculado o teste de Kolmogorov-Smirnov (KS) e Kruskal-Wallis [68]. Os resultados dos testes são mostrados na Tabela 3 e observa-se que somente no teste de Kruskal-Wallis (para a Série Sunspot), não se rejeitou  $H_o$  a um nível de significância  $\alpha = 0.05$ , indicando igualdade entre os dois grupos, mas no teste KS obteve um nível de rejeição aceitável.

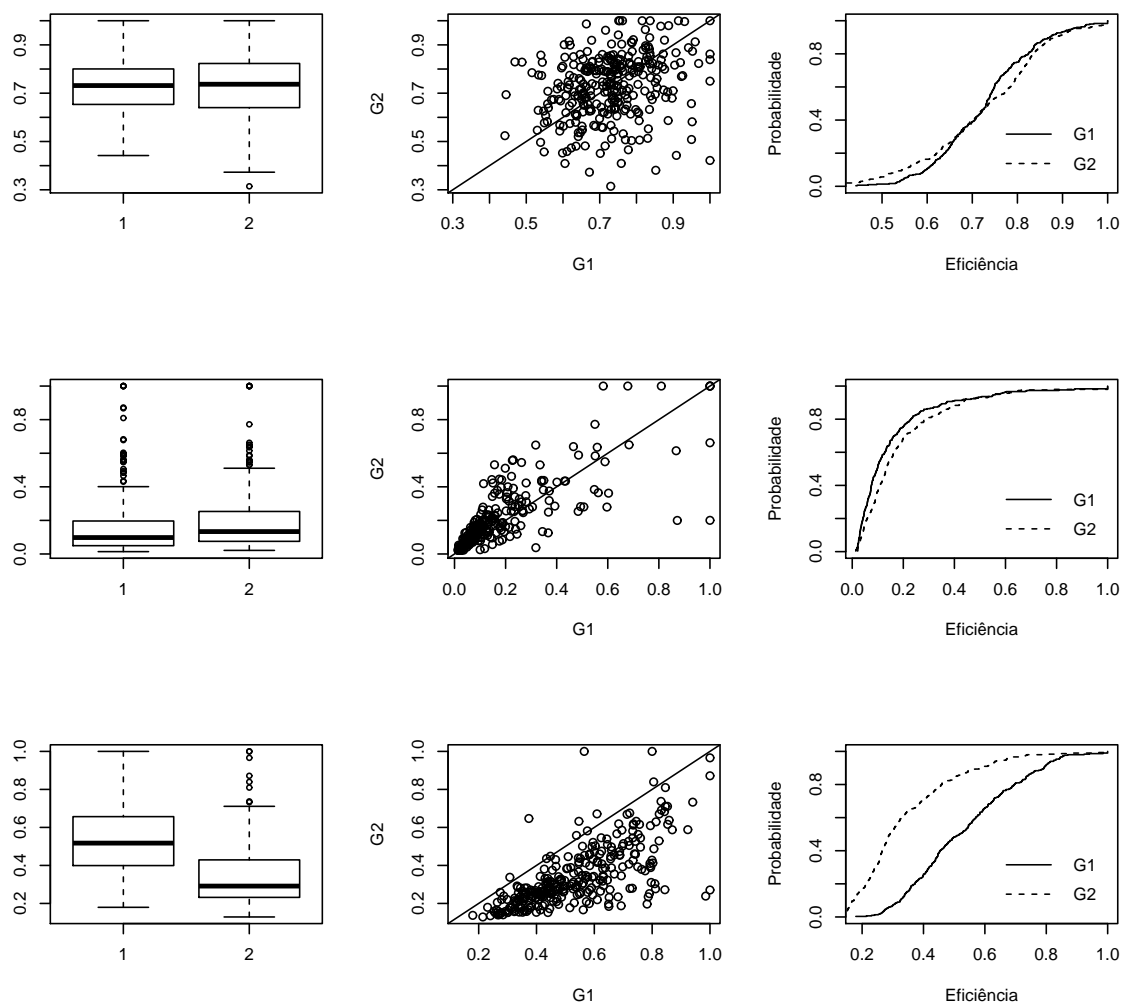
**Tabela 3** – Resultado do Teste de Hipóteses para diferenças entre grupos

Séries	Teste KS	Teste Kruskal-Wallis
	p-valor ( $\alpha = 0,05$ )	p-valor ( $\alpha = 0,05$ )
Sunspot	0,009656	0,4888
SP500	0,0001716	0,0002529
Milk	< 2,2e-16	< 2,2e-16

Através dos gráficos box-plot e da distribuição empírica das eficiências apresentada na Figura 16 pode se observar, de forma visual, se existem diferenças entre os grupos com relação a eficiência.

Na Série de Manchas Solares, primeira linha da Figura 16, as diferenças são moderadas. No gráfico de dispersão, os dados estão distribuídos de maneira proporcional em ambos os lados da linha reta, mas a concentração das eficiências está acima de 0.60. No gráfico box-plot observa-se que a mediana é bem próxima nos dois grupos e os dados estão concentrados em torno da mediana de maneira quase equalitativa. Na distribuição empírica, o nível de eficiência entre as DMUS se alterna, indicando um nível de eficiência mais baixo para o grupo G1 quando as eficiências estão abaixo de 0.7 aproximadamente. A inclusão do POCID nas Funções de Fitness, para este caso, talvez não demonstre diferenças, apesar do teste KS ter se mostrado favorável e o teste Kruskal-Wallis ter indicado que os dois grupos são iguais ao aceitar a hipótese nula. Atentar para o detalhe que a

<sup>1</sup>A variável estudada nesse teste de hipóteses são as funções de fitness apresentadas na tabela 1. O grupo G1 corresponde as funções de f1 até f10 e o grupo G2 as funções de f11 até f20



**Figura 16** – Comparação entre os grupos G1 (com a métrica POCID e G2 (sem a métrica POCID) para as Séries: (a) Sunspot, (b) SP500 e (c) Série Produção de Leite.

concentração das eficiências acima de 0.7 para as Funções de Fitness utilizadas nessa série de dados indica que elas se adequaram bem ao modelo utilizado.

Na série SP&500, segunda linha da Figura 16 percebe-se uma pequena diferença na mediana das eficiências do grupo G2 em relação ao grupo G1. Essa diferença também é observada no diagrama de dispersão onde a maioria das eficiências concentra-se acima da linha reta (apesar de estarem abaixo de 0.4), indicando que na maior parte das eficiências é sempre maior para o grupo G2. Somente no gráfico das distribuições empíricas, o nível de eficiência nas DMUs se apresenta maior no grupo G1, quando está abaixo de 0.6 e quase igual quando está acima. Como essa série apresenta uma tendência considerável em seus dados, a utilização do POCID nas Funções de Fitness pode conduzir a um melhor resultado em termos de eficiência.

Na Série de Produção de Leite, terceira linha da Figura 16 observa-se no box-plot que o grupo G1 apresenta maior mediana que o grupo G2 indicando uma maior concentração das eficiências no grupo G1 acima das eficiências do grupo G2. Isso pode ser verificado no gráfico de dispersão dos dois grupos, onde a maioria dos pontos se encontra abaixo da linha reta, indicando que a maioria das eficiências são maiores para G1. No gráfico da distribuição empírica, G1 se encontra abaixo de G2 e portanto, em termos de nível de eficiência, a proporção de DMUs onde o nível de eficiência apresenta-se mais baixo é maior no grupo G2.

### 5.1.2 Caso 2: Comparação dos grupos de Funções de Fitness em termos da eficiência

Considerando os resultados das eficiências das vinte Funções de Fitness, o interesse agora é testar se existe diferenças significativas entre essas Funções. Para tal, é realizado um teste de Kruskal-Wallis [68] que consiste de um método não-paramétrico aplicado na comparação de três ou mais grupos independentes e o resultado do experimento pode ser ordenado. Existindo diferenças, o próximo passo é aplicar um Teste de Tukey para identificar em quais grupos houveram diferenças significativas (Apêndice B). No Apêndice D encontram-se todas as tabelas com os resultados das eficiências para cada uma das Funções de Fitness de cada série temporal analisada. O teste de Kruskal-Wallis [68] foi realizado para as três séries e os resultados são apresentados na Tabela 4. Verifica-se que

**Tabela 4** – Teste de Kruskal-Wallis para diferenças entre grupos

<b>Teste de Kruskal - Wallis <math>\alpha(0.05)</math></b>		
<b>Séries</b>	$\chi^2$	<b>p-valor</b>
Sunspot	71.8901	4.449e-08
SP&500	165.3266	< 2.2e-16
Produção de Leite	257.0855	< 2.2e-16

o teste foi significativo para as três séries indicando que existe ao menos uma diferença entre o grupo de Funções de Fitness. Procedendo com o teste de Tukey ( $\alpha=(0.05)$ ) para verificar as possíveis diferenças, apresentamos na Tabela 18 do Apêndice D, os resultados para o Teste de Tukey em todas as séries utilizadas. Na coluna Diff são apresentadas as diferenças, ordenadas da maior para menor, entre todos os pares de amostras. Os valores com pares de diferenças significativas são aqueles onde o limite inferior (L. Inf.) é positivo.

Observa-se na Série Sunspot que as maiores diferenças significativas ocorrem com a Função  $F13 : POCID/(1 + MSE)$  comparada com todas os outras grupos de Funções

dessa mesma série. A maior diferença nessa série ocorreu entre as Funções  $F19 : POCID/(1+ARV+THEIL)$  e  $F13 : POCID/(1+MSE)$ . Na Série SP&500 a maior diferença foi entre a Função  $F7 : 1/(1+MSE+THEIL)$  e  $F13 : POCID/(1+MSE)$ . Cabe verificar que a Função  $F7$  foi a que mais apareceu combinando-se entre os grupos com mais diferenças significativas. Na Série de Produção de Leite, a maior diferença significativa ocorreu entre as Funções  $F7 : 1/(1+MSE+THEIL)$  e  $F12 : POCID/(1+MAPE)$ . Novamente a Função  $F7$  aparece entre as maiores diferenças entre os grupos que foram significativos para essa série. Ou seja, esses grupos foram o que mais contribuíram para as diferenças encontradas no Teste de Kruskal-Wallis ao se rejeitar  $H_0$ .

## 5.2 Análise dos resultados para a série Sunspot

### 5.2.1 Introdução

A série de manchas solares Sunspot apresenta um comportamento periódico ao longo do tempo. Na Tabela 5 é apresentado um resumo das principais medidas estatística da série.

**Tabela 5** – Resumo das medidas estatísticas para a Série Sunspot

Resumo Estatístico	
Nº de Pontos	289
Valor Mínimo	0
Valor Máximo	190.0
Média	48.62
Variância	1558.2
Desvio Padrão	39.48

O gráfico e seu correlograma são apresentados nas Figuras 17a e 17b. O correlograma é um gráfico com os  $k$  primeiros coeficientes de autocorrelação em função de  $k$ . Como essa série apresenta flutuações sazonais, seu correlograma segue a mesma característica, oscilando na mesma frequência.

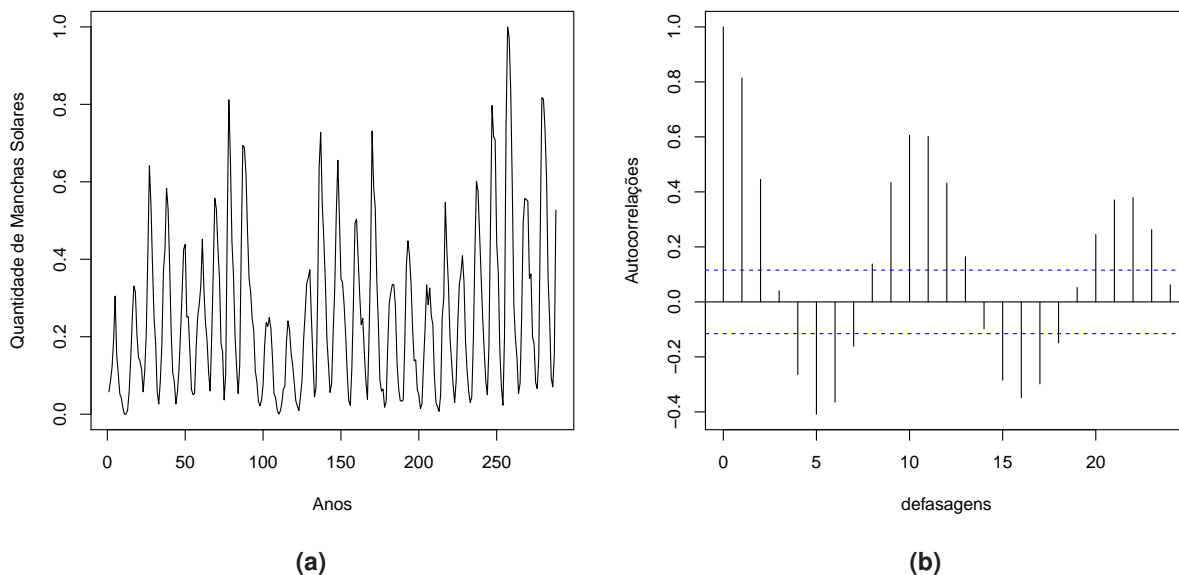


Figura 17 – (a) Série anual de Manchas Solares. (b) Função de Autocorrelação

## 5.2.2 Resultados utilizando DEA para a Série Sunspot: Caso Geral


O modelo escolhido para a série Sunspot foi o modelo com retorno variáveis de escala com orientação a *inputs*. Foram utilizadas como *inputs*, para este caso, as medidas: MSE, ARV, MAPE, THEIL e como *output* a medida *POCID*. Dos resultados obtidos com as 600 DMUs utilizadas a Tabela 6 mostra as eficiências, a estimativa da eficiência com correção de viés e o intervalo de confiança das estimativas para as 8 DMUS mais e menos eficientes.

Tabela 6 – Eficiências e estimativas para a Série Sunspot: Caso geral.

	DMUs	Eficiência	Estimativa	I.C.(95%)	
1	$POCID/(1 + MSE + ARV)_{rep2}$	1	0.964292997	0.924454438	0.990787897
2	$1/(1 + ARV)_{rep22}$	1	0.927878065	0.887960231	0.969495172
3	$POCID/(1 + THEIL)_{rep29}$	1	0.883551318	0.826265233	0.971763241
4	$POCID/(1 + MSE + THEIL)_{rep26}$	1	0.859084772	0.805924968	0.959890243
5	$1/(1 + ARV)_{rep20}$	1	0.838913508	0.755370699	0.973592387
6	$1/(1 + MSE + ARV)_{rep5}$	1	0.808728872	0.74676279	0.961221532
7	$POCID/(1 + ARV)_{rep30}$	1	0.801092717	0.730868481	0.965670961
8	$POCID/(1 + ARV + THEIL)_{rep19}$	1	0.779257217	0.649050525	0.956803247
593	$POCID/(1 + MSE)_{rep1}$	0.434990648	0.42051575	0.400135305	0.432787456
594	$POCID/(1 + ARV)_{rep11}$	0.427131386	0.409139244	0.393698707	0.424385787
595	$POCID/(1 + MSE)_{rep30}$	0.395616568	0.391742579	0.38414272	0.395430063
596	$POCID/(1 + MSE)_{rep11}$	0.395914166	0.377575004	0.354166045	0.393804995
597	$POCID/(1 + MSE)_{rep21}$	0.380865326	0.37102483	0.357403896	0.379658974
598	$POCID/(1 + MSE)_{rep14}$	0.367390426	0.35949297	0.34909149	0.36642436
599	$POCID/(1 + MSE)_{rep27}$	0.379636308	0.330928661	0.309014144	0.365634617
600	$POCID/(1 + MSE)_{rep6}$	0.309214595	0.299311654	0.284657897	0.30798849

A estimativa da correção do viés foi proposta por Simar e Wilson [66] com o objetivo de obter estimativas mais seguras para as eficiências calculadas através da aplicação do método *bootstrap* que aproxima assintoticamente a distribuição dos estimadores das eficiências. No livro do Bogetoft e Otto [65] é apresentado uma rotina do software *R* através do pacote FEAR e utilizando a função *boot.sw98* que calcula as estimativas das eficiências utilizando o método *bootstrap*.


Observa-se que houve um bom poder de discriminação, dado que, das 600 DMUs analisadas obteve-se 8 com eficiência máxima. Verifica-se que das oito DMUs mais eficientes, a métrica ARV aparece em seis Funções de Fitness, assim como, a métrica POCID que aparece 5 vezes combinada com outras métricas. No teste de Tukey realizado para série Sunspot, a Função *F13* apresentou diferenças significativas com as demais Funções, indicando então não ser uma boa combinação de Função dado que suas eficiências foram as menores de todas as 600 combinações (Apêndice D). Na Figura 18 é mostrado o gráfico contendo a fronteira DEA (linha sólida), a estimativa da fronteira com correção do viés (linha tracejada) e o intervalo de confiança superior com  $\alpha = 0.05$  (linha pontilhada). A esti-



**Figura 18** – Fronteira DEA com correção de viés para a Série Sunspot (Caso geral).

mativa foi obtida utilizando o método *bootstrap* com o número de réplicas  $n_{rep} = 2000$  para todas as 600 combinações de Funções de Fitness. Somente os pontos mais eficientes se encontram ao longo da fronteira de eficiência. Os pontos que estão abaixo se localizam na região chamada de Conjunto Viável de Produção, conforme descrito no Capítulo 2. Um dos interesses principais é verificar, se o modelo DEA conseguiu encontrar uma Função de Fitness ótima (ou a melhor dentre as apresentadas) que ao comparar os dados


originais da série com os valores previstos obtenha um bom ajuste. Tal ajuste pode ser ótimo do ponto de vista do modelo DEA, mas talvez não seja em relação ao custo computacional de implementá-las e computá-las. Na Figura 19 é apresentado os valores previstos para a Série Sunspot, baseado na oito DMUs mais eficientes. Os valores previstos



**Figura 19** – Figura comparativa entre a série real Sunspot (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes (Caso geral).

obtiveram um bom ajuste com a série real baseado na eficiência das Funções de Fitness utilizando a DEA sendo que as Funções  $POCID/(1+MSE+ARV)$ ,  $POCID/(1+ARV)$  e  $1/(1+MSE+ARV)$  se acoplaram bem ao valor real da série Sunspot. Uma forma de avaliar se os valores previstos se ajustaram bem aos valores reais é observar o gráfico dos resíduos do modelo. Caso o modelo se ajuste corretamente os resíduos se distribuem aleatoriamente ao longo da série. Se não se ajustar os resíduos podem estar considerando um padrão levando em conta o fator tendência ou um fator cíclico ou sazonal. O gráfico dos resíduos para as oito melhores eficiências é apresentado na Figura 20 e verifica-se que os resíduos estão distribuídos aleatoriamente ao longo da série.





**Figura 20** – Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série Sunspot no caso geral.

Um outro critério a ser observado é o critério AIC<sup>2</sup> (*Akaike Information Criterion*) e o critério BIC<sup>3</sup> (*Bayesian Information Criterion*) como forma de selecionar um modelo parcimonioso ou que contenha uma quantidade suficiente de parâmetros. O AIC e o BIC deverão ser os menores possíveis, sendo que ambos medem o ajuste do modelo estimado aos dados. Na Tabela 7 é apresentado o AIC e BIC das Funções mais eficientes segundo o modelo DEA além do MAPE que serve para medir a acurácia do modelo (quanto menor o MAPE melhor).

<sup>2</sup>O critério AIC proposto por Akaike [69] mede a bondade do ajuste do modelo e é definido como

$$AIC = -2\log(L) + 2k$$

onde  $k$  é número de parâmetros do modelo e  $L$  é o valor máximo da função de máxima verossimilhança do modelo estimado.

<sup>3</sup>O critério BIC foi desenvolvido por Schwarz [70] e é representado pela seguinte fórmula

$$BIC = -2\log(L) + k\ln(n)$$


onde  $n$  é o número de observações da série,  $k$  é número de parâmetros do modelo e  $L$  é o valor máximo da função de máxima verossimilhança do modelo estimado.

**Tabela 7** – Valores dos critérios AIC, BIC e MAPE para a oito Funções de Fitness mais eficientes na série Sunspot (caso geral).

	POCID/(1+MSE+ARV)rep2	1/(1+ARV)rep22	POCID/(1+THEIL)rep29	POCID/(1+MSE+THEIL)rep26
AIC	244,5806066	220,1364684	227,9044314	217,8854258
BIC	488,1838814	463,7397431	471,5077061	461,4887005
MAPE	0,302265357	0,293338746	0,356537749	0,316401036
	1/(1+ARV)rep20	1/(1+MSE+ARV)rep5	POCID/(1+ARV)rep30	POCID/(1+ARV+THEIL)rep19
AIC	260,5412006	190,3723001	230,6938001	278,7947607
BIC	504,1444754	433,9755748	474,2970748	522,3980355
MAPE	0,336966265	0,385791424	0,757623433	0,468035373

A partir dos resultados obtidos na Tabela 7 verifica-se que a Função  $1/(1 + MSE + ARV)$  obteve os menor valor dos critérios AIC e BIC apesar do seu MAPE não ser um dos menores dentre os outros. Quando observado o grafico dos seus valores previstos com a série real (Figura 19) verifica-se que este obteve um bom ajuste.

Na Figura 21 é mostrado o gráfico dos valores previstos da Série Sunspot, baseado nas duas DMUs menos eficientes. É perceptível que as DMU menos eficientes não se ajustaram a série de dados real. Seus valores estão bem próximos do eixo  $x$ . Portanto, a métrica  $POCID/(1 + MSE)$  não é uma boa escolha para a Série Sunspot.



**Figura 21** – Valores previstos para Série Sunspot utilizando as DMUs menos eficientes (Caso geral).

### 5.2.3 Resultados utilizando DEA para a Série Sunspot: Caso Específico

O segundo caso analisado, coloca as medidas de desempenho utilizado como *inputs* de forma individual e tenta verificar, por exemplo, qual Função de Fitness seria ótima para minimizar um determinado *input*. Dessa maneira, é realizada a combinação das quatro

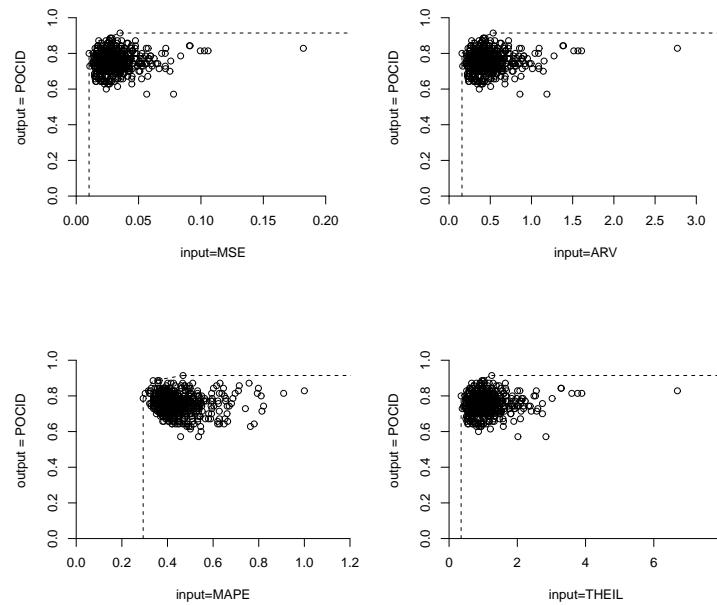
medidas usadas como *inputs* com o *output* POCID. Na Tabela 8 é apresentado a eficiência e a estimativa da eficiência, com seus intervalos de confiança, das DMUs mais e menos eficientes, para cada combinação de *inputs* com o *output* POCID .

**Tabela 8 – Eficiências e estimativas para a Série Sunspot: Caso específico**

DMUs		Eficiência	Estimativa	I.C.(95%)	
<b>Input:MSE</b>					
1°	$1/(1 + MSE + ARV)_{rep5}$	1	0.892275868	0.808491678	0.993782422
2°	$POCID/(1 + ARV)_{rep30}$	1	0.769318811	0.665936536	0.965051507
3°	$POCID/(1 + ARV + THEIL)_{rep19}$	1	0.630680462	0.54003989	0.832953366
598°	$POCID/(1 + MSE)_{rep8}$	0.115125141	0.10468723	0.094174708	0.114234989
599°	$POCID/(1 + MSE)_{rep21}$	0.111954502	0.101804072	0.091581069	0.111088882
600°	$POCID/(1 + MSE)_{rep6}$	0.073480785	0.065950778	0.058377	0.072760424
<b>Input:ARV</b>					
1°	$1/(1 + MSE + ARV)_{rep5}$	1	0.892783006	0.810864887	0.993435655
2°	$POCID/(1 + ARV)_{rep30}$	1	0.765480212	0.668163681	0.966283226
3°	$POCID/(1 + ARV + THEIL)_{rep19}$	1	0.631579769	0.545188772	0.838669972
598°	$POCID/(1 + MSE)_{rep8}$	0.115125141	0.104918261	0.094639111	0.114308402
599°	$POCID/(1 + MSE)_{rep21}$	0.111954502	0.102028741	0.092032683	0.111160274
600°	$POCID/(1 + MSE)_{rep6}$	0.073480785	0.065929495	0.058478377	0.072630601
<b>Input:MAPE</b>					
1°	$1/(1 + ARV)_{rep22}$	1	0.972459525	0.933568591	0.998169833
2°	$POCID/(1 + MSE + ARV)_{rep2}$	1	0.964620293	0.914910495	0.997220053
3°	$1/(1 + ARV)_{rep20}$	1	0.833715146	0.752888685	0.965150188
4°	$POCID/(1 + ARV + THEIL)_{rep19}$	1	0.764373265	0.635528624	0.928992246
597°	$1/(1 + THEIL)_{rep6}$	0.360386334	0.356855833	0.348956036	0.360271612
598°	$POCID/(1 + MSE + ARV)_{rep5}$	0.357232165	0.352988497	0.344753027	0.357086088
599°	$POCID/(1 + MSE)_{rep27}$	0.332457861	0.320698856	0.304171947	0.331537252
600°	$POCID/(1 + MSE)_{rep6}$	0.309214595	0.296016931	0.279071163	0.307835564
<b>Input:THEIL</b>					
1°	$1/(1 + MSE + ARV)_{rep5}$	1	0.899221205	0.813365011	0.995013688
2°	$POCID/(1 + ARV)_{rep30}$	1	0.775938462	0.666983424	0.973633632
3°	$POCID/(1 + ARV + THEIL)_{rep19}$	1	0.631322143	0.540368313	0.866343038
598°	$POCID/(1 + MSE)_{rep8}$	0.110082452	0.101260311	0.091395776	0.109425126
599°	$POCID/(1 + MSE)_{rep21}$	0.106549604	0.098010302	0.088462431	0.105913008
600°	$POCID/(1 + MSE)_{rep6}$	0.071117686	0.06451376	0.057571198	0.070405181


Ao observar a Tabela 8 verifica-se que as métricas MSE, ARV e THEIL tiveram um mesmo subconjunto de DMUs com eficiência máxima. Complementarmente em todos os *inputs*, a DMU  $POCID/(1 + MSE)$  sempre foi observada dentre as ultimas colocações no ranking de eficiência. A métrica ARV aparece em todas as Funções mais eficientes de cada *input*. Para minimizar o *input* MAPE, quatro Funções se destacaram como mais eficientes tendo sempre a presença do ARV em suas combinações.

Na Figura 22 é apresentada as fronteiras para cada uma das 4 métricas consideradas como *inputs*.




**Figura 22** – Fronteira BCC-I para a série Sunspot (Caso específico)

Como as DMUs mais eficientes para minimizar o MSE, ARV e THEIL foram iguais, na Figura 23 é mostrado os valores previstos para Série Sunspot para minimizar o *inputs* MSE, ARV e THEIL, de acordo com as DMUs consideradas mais eficientes.



**Figura 23** – Gráfico comparativo entre a série real Sunspot (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes. (*inputs*: MSE, ARV, THEIL)

Verifica-se que dentre as DMUs escolhidas com eficiência máxima, a Função  $1/(1 + MSE + ARV)$  foi a que obteve melhor ajuste dentre as outras. O gráfico dos resíduos, Figura 24, para este *input* mostra que as Funções com mais eficiência apresentaram os resíduos distribuídos aleatoriamente ao longo da série.




**Figura 24** – Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série Sunspot no caso específico (*inputs*: MSE, ARV, THEIL).

Complementando a análise dos resíduos é apresentado na Tabela 9 os valores dos critérios AIC e BIC e da medida de desempenho MAPE para o caso específico em que são considerados como *inputs* as métricas de desempenho MSE, ARV, THEIL. A Função  $1/(1 + MSE + ARV)$  apresentou menores valores do critério AIC e BIC mas não obteve o menor MAPE em relação a Função  $POCID/(1 + ARV + THEIL)_{rep19}$ .

**Tabela 9** – Valores dos critérios AIC, BIC e MAPE para as Funções de Fitness mais eficientes na série Sunspot no caso específico:(*inputs*: MSE, ARV, THEIL)


	$1/(1 + MSE + ARV)_{rep5}$	$POCID/(1 + ARV)_{rep30}$	$POCID/(1 + ARV + THEIL)_{rep19}$
AIC	190,3723001	230,6938001	219,0037288
BIC	433,9755748	474,2970748	462,6070035
MAPE	0,385791424	0,757623433	0,37158108

Na Figura 25 estão os valores previstos dos ajustes utilizando o *input* MAPE. Dentre as quatro DMUs que obtiveram eficiência máxima, duas DMUS se destacaram com um melhor acoplamento:  $1/(1 + ARV)_{rep22}$  e  $POCID/(1 + MSE + ARV)$  considerando os valores de eficiência mostrados na Tabela 8. Essas Funções tiveram valores mais bem ajustados a série real do que as outras duas. Por ser composta da combinação de somente uma métrica, a Função  $1/(1 + ARV)$  seria a mais indicada nesse caso para minimizar o MAPE.




**Figura 25** – Gráfico comparativo entre a série real Sunspot (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes. (*input* MAPE).

Na Figura 26 é apresentado os respectivos gráficos de resíduos para esse *input*. Na



**Figura 26** – Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série Sunspot no caso específico (*input*: MAPE).

Figura 27, a DMUs menos eficientes, quando observado seus valores previstos, não se ajustaram a Série Sunspot e novamente a métrica  $POCID/(1 + MSE)$  não seria indicada




**Figura 27** – Valores previstos para Série Sunspot utilizando as DMUs menos eficientes(Caso Específico).

para minimizar as Funções observando os *inputs* de maneira individual.

## 5.3 Análise dos resultados para a série SP&500

### 5.3.1 Introdução

A série do índice SP&500 (*Standard & Poor 500*) é uma série que apresenta um movimento regular de crescimento ao longo de seu conjunto de dados (Figura 28a). Esta tendência de crescimento é visualizada na Figura 28b. As observações no gráfico da



**Figura 28** – (a) Série do índice SP&500. (b) Função de Autocorrelação

Função de Autocorrelação Amostral apresenta um decaimento lento para zero devido ao comportamento de tendência dos dados. Na Tabela 10 é apresentado um resumo estatístico para a Série SP&500.

**Tabela 10** – Resumo das medidas estatísticas para a Série SP&500

<b>Resumo Estatístico</b>	
Nº de Pontos	369
Valor Mínimo	74.12
Valor Máximo	3533.82
Média	866.76
Variância	1189443.09
Desvio Padrão	1090.62

### 5.3.2 Resultados utilizando DEA para a Série SP&500: Caso Geral


O modelo DEA escolhido para a Série SP&500 foi o modelo com retorno constantes de escala orientado a inputs (CCR-I), de acordo com o teste hipótese utilizando o método *bootstrap*. Ou seja, no modelo CCR, qualquer variação nos *inputs* produzirá variação proporcional nos *outputs*. Os resultados para as eficiências da Série SP&500 para o caso geral são mostrados na Tabela 11.

**Tabela 11** – Eficiências e estimativas para a Série SP&500: Caso geral

	<b>DMUs</b>	<b>Eficiência</b>	<b>Estimativa</b>	<b>I.C.(95%)</b>	
<b>1º</b>	$1/(1 + MSE + THEIL)_{rep1}$	1	0.626286331	0.56066245	0.751241256
<b>2º</b>	$1/(1 + ARV + THEIL)_{rep10}$	0.88245676	0.59917539	0.51527933	0.77299894
<b>3º</b>	$1/(1 + ARV + THEIL)_{rep1}$	0.797384579	0.564982343	0.476070223	0.747484945
<b>599º</b>	$1/(1 + MAPE)_{rep24}$	0.009926268	0.009588081	0.008834705	0.00991765
<b>600º</b>	$1/(1 + MSE)_{rep12}$	0.009476526	0.009153702	0.008434418	0.009468423


Somente a DMU  $1/(1 + MSE + THEIL)$  foi classificada com eficiência máxima, mas sua estimativa com correção de viés está abaixo de 70%. Observando os valores previstos baseado nas três métricas mais eficientes tem-se a comparação com a série real apresentada na Figura 29.





**Figura 29** – Gráfico comparativo entre a série real SP&500 (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes. (Caso geral).

A Função que mais se acoplou aos dados originais foi a DMU  $1/(1+MSE+THEIL)$ , apesar de que a Função  $1/(1+ARV+THEIL)$ , na 1º e na 10º repetição do experimento, obteve bons resultados somente destoando no final dos dados. Ao observar o gráfico dos resíduos dessas dessas Funções (Figura 30) observa-se a sua distribuição aleatória ao longo dos dados.



**Figura 30** – Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série SP&500.


Se observarmos os resultados dos critérios AIC, BIC e do MAPE na Tabela 12 verifica que a Função  $1/(1+MSE+THEIL)$  foi a que obteve os menores valores desses critérios

**Tabela 12** – Valores dos critérios AIC, BIC e MAPE para as Funções de Fitness mais eficientes na série SP&500

	$1/(1 + \text{MSE} + \text{THEIL})_{\text{rep1}}$	$1/(1 + \text{ARV} + \text{THEIL})_{\text{rep10}}$	$1/(1 + \text{ARV} + \text{THEIL})_{\text{rep1}}$
AIC	-147,3381764	-93,77052083	-78,12101968
BIC	122,4932013	176,0608569	191,7103581
MAPE	0,013912863	0,018508427	0,019345081

indicando se ajustar melhor do que as outras duas funções.

Portanto o modelo DEA, mostrou encontrar uma DMU com eficiência e que seus valores previstos se acloassem aos dados originais. Na Figura 31 são apresentados os valores previstos para as duas DMUs com menos eficiência e nota-se o não ajuste das mesmas. As DMUs menos eficientes estão muito longe dos valores reais da Série SP&500,



**Figura 31** – Valores previstos para Série Sp&500 utilizando as DMUs menos eficientes.

fator esse relacionado a baixa eficiência (menos de 1%) como visto na Tabela 11.

### 5.3.3 Resultados utilizando DEA para a Série SP&500: Caso específico

Para o caso em que cada *input* é analisado separadamente com o *output* POCID, a Tabela 13 apresenta as eficiências das três DMUs mais eficientes e as duas menos eficientes para a Série SP&500, junto com suas estimativas e intervalo de confiança. É verificado que cada *input* diferente obteve as mesmas DMUs como mais e menos eficiência, sendo diferente somente nas suas estimativas e intervalos de confiança.

O modelo DEA encontrou as mesmas DMUs com mais e menos eficiência, tanto no caso geral quanto no caso específico. Portanto, as análises são as mesmas que o caso geral e os gráficos com as eficiências são vistos na Figura 29 e 31. As diferenças ocorreram

**Tabela 13** – Eficiências e estimativas para a Série SP&500: Caso Específico


	DMUs	Eficiência	Estimativa	I.C.(95%)	
<b>Input:MSE</b>					
1°	$1/(1 + MSE + THEIL)_{rep1}$	1	0.856231561	0.676916024	0.994364164
2°	$1/(1 + ARV + THEIL)_{rep10}$	0.655823715	0.561557093	0.443945485	0.652160044
3°	$1/(1 + ARV + THEIL)_{rep1}$	0.522493338	0.447385835	0.353688255	0.519565652
599°	$1/(1 + MAPE)_{rep24}$	0.00022807	0.000195198	0.000154385	0.00022671
600°	$1/(1 + MSE)_{rep12}$	0.000216439	0.000185243	0.000146511	0.000215148
<b>Input:ARV</b>					
1°	$1/(1 + MSE + THEIL)_{rep1}$	1	0.857409656	0.680255564	0.995576159
2°	$1/(1 + ARV + THEIL)_{rep10}$	0.655823715	0.562330177	0.44613597	0.652955608
3°	$1/(1 + ARV + THEIL)_{rep1}$	0.522493338	0.448001449	0.355433248	0.520199002
599°	$1/(1 + MAPE)_{rep24}$	0.00022807	0.000195452	0.000155146	0.000227035
600°	$1/(1 + MSE)_{rep12}$	0.000216439	0.000185481	0.000147234	0.000215457
<b>Input:MAPE</b>					
1°	$1/(1 + MSE + THEIL)_{rep1}$	1	0.964764274	0.883383856	0.998967483
2°	$1/(1 + ARV + THEIL)_{rep10}$	0.88245676	0.851381903	0.779562518	0.881566893
3°	$1/(1 + ARV + THEIL)_{rep1}$	0.797384579	0.769303848	0.704408518	0.796578711
599°	$1/(1 + MAPE)_{rep24}$	0.009926268	0.009576492	0.00876871	0.009916026
600°	$1/(1 + MSE)_{rep12}$	0.009476526	0.009142596	0.008371414	0.009466746
<b>Input:THEIL</b>					
1°	$1/(1 + MSE + THEIL)_{rep1}$	1	0.859612062	0.68244185	0.994696265
2°	$1/(1 + ARV + THEIL)_{rep10}$	0.671817266	0.577504535	0.458477148	0.668257803
3°	$1/(1 + ARV + THEIL)_{rep1}$	0.534816558	0.459747786	0.364986446	0.532000762
599°	$1/(1 + MAPE)_{rep24}$	0.000231334	0.000198769	0.000157872	0.000230092
600°	$1/(1 + MSE)_{rep12}$	0.000219469	0.000188567	0.000149775	0.000218291

nas estimativas com viés corrigido que chegou no máximo a 96.47% para o caso do *input* MAPE. Novamente as Funções  $1/(1 + MAPE)$  e  $1/(1 + MSE)$  obtiveram eficiências ruins.

## 5.4 Análise dos resultados para a série Produção Mensal de Leite

### 5.4.1 Introdução

A última série temporal analisada é a série de Produção Mensal de Leite nos EUA. Esta série tem um comportamento periódico e com tendência conforme pode ser verificado no gráfico de sua série (Figura 32a) e na sua Função de Autocorrelação (Figura 32b).



**Figura 32** – (a) Série de Produção Mensal de Leite. (b) Função de Autocorrelação

É apresentado na Tabela 14, assim como nas outras séries, o resumo estatístico das principais medidas de dispersão para a série de produção mensal de leite.

**Tabela 14** – Resumo das medidas estatísticas para a Série Produção Mensal de Leite.

<b>Resumo Estatístico</b>	
Nº de Pontos	168
Valor Mínimo	553.0
Valor Máximo	969.0
Média	754.7
Variância	10445.65
Desvio Padrão	102.204

#### 5.4.2 Resultados utilizando DEA para a Série de Produção de Leite: Caso Geral

O modelo escolhido para a Série de Produção Mensal de Leite, foi o modelo DEA com retorno variável de escala orientado a *inputs* (BCC-I), assim como na Série de Manchas Solares. Para este caso, as variáveis escolhidas como *inputs* foram as métricas MSE, ARV, MAPE e THEIL. Como *output* a métrica POCID. Na Tabela 15 estão as DMUS conside-


radas mais e menos eficientes, com suas respectivas estimativas com correção de viés e seus intervalos de confiança.

**Tabela 15** – Eficiências e estimativas para a Série de Produção de Leite: Caso geral

	DMUs	Eficiência	Estimativa	I.C.(95%)	
1°	$POCID/(1 + ARV + MAPE)_{rep29}$	1	0.657641608	0.57801806	0.900830681
2°	$1/(1 + MSE + THEIL)_{rep27}$	1	0.631461972	0.54150283	0.882591367
599°	$POCID/(1 + MSE + MAPE)_{rep26}$	0.135239306	0.129376082	0.118823446	0.135056845
600°	$POCID/(1 + MAPE)_{rep1}$	0.128834435	0.127542935	0.124419324	0.128800129


As DMUs com eficiência máxima foram somente duas:  $1/(1 + MSE + THEIL)$  e  $POCID/(1 + ARV + MAPE)$ . As duas DMUs menos eficientes foram as Funções  $POCID/(1 + MSE + MAPE)$  e  $POCID/(1 + MAPE)$ . O valor real da eficiência está mais próxima do intervalo de confiança a direita, para as todas as DMUs do caso geral.

Na Figura 33 é mostrado o gráfico contendo a fronteira DEA (linha sólida), a estimativa da fronteira com correção do viés (linha tracejada) e o intervalo de confiança superior com  $\alpha = 0.05$  (linha pontilhada) para a série de produção de leite.




**Figura 33** – Fronteira BCC-I para a série de Produção de Leite(Caso geral)

Nota-se nessa Figura 33 os dois pontos na fronteira de eficiência, enquanto que os outros pontos se distribuem abaixo dela na chamada região viável de produção. A Figura 34 apresenta os valores previstos para as DMUs com mais eficiência que foram apresentadas na Tabela 15. Não houve um bom acoplamento da Função  $1/(1 + MSE + THEIL)$  no últimos pontos da série, apesar dela ter seguido o comportamento periódico da mesma. Já



**Figura 34** – Gráfico comparativo entre a série real Produção de Leite (linha sólida) e a previsão gerada pela rede neural (linha tracejada) utilizando as DMUs mais eficientes. (Caso geral)

a Função  $POCID/(1 + ARV + MAPE)$  demonstrou se ajustar bem a essa série. Seus pontos previstos tiveram bons ajustes ao longo da série real como pôde ser visto na Figura 34. Quando observado o gráfico dos resíduos na Figura 35 percebe-se que na Função  $1/(1 + MSE + THEIL)$  um padrão sistemático de tendência na distribuição dos seus resíduos indicando que o modelo deixou de considerar a tendência no seu modelo.




**Figura 35** – Gráfico dos resíduos para as Funções de Fitness mais eficientes para a Série Sunspot no caso geral.

Se verificarmos os critérios de ajuste do modelo, apresentado na Tabela 16, a Função  $POCID/(1 + ARV + MAPE)$  apresenta menores valores em todos os critérios sendo o valor de erro MAPE de cerca de 11%.

**Tabela 16** – Valores dos critérios AIC, BIC e MAPE para as Funções de Fitness mais eficientes na série Produção de Leite

	$POCID/(1 + ARV + MAPE)_{rep29}$	$1/(1 + MSE + THEIL)_{rep27}$
AIC	91,73980243	180,4844751
BIC	204,6883276	366,4151242
MAPE	0,111377155	0,119653396

O comportamento dos valores previstos das DMUs menos eficientes é apresentado na Figura 36 e verifica-se que nenhuma das duas Funções se ajustaram bem aos valores reais. Tal fato está de acordo com suas eficiências, que foram bem próximas de zero (conforme mostrado na Tabela 15).



**Figura 36** – Valores previstos para Série Produção de Leite utilizando as DMUs menos eficientes

### 5.4.3 Resultados utilizando DEA para a Série Produção de Leite: Caso Específico


Considerando o POCID como *output* e cada uma das outras métricas como *inputs* individuais, o comportamento das eficiências foram as mesmas que o caso geral. A Tabela 17 apresenta as eficiências das duas maiores e menores eficiências para a Série de Produção de Leite. Como as DMUs mais e menos eficientes foram iguais ao caso geral, os valores previstos são apresentados nas Figuras 34 e 36.

Vale frisar que as estimativas de eficiência com correção de viés estão ordenando de forma correta a qualidade de previsão gerado pela respectiva Função de Fitness, tanto nessa série de Produção de Leite quanto nas outras séries.

**Tabela 17** – Eficiências e estimativas para a Série de Produção de Leite: Caso específico

DMUs	Eficiência	Estimativa	I.C.(95%)	
<b>Input:MSE</b>				
1° $POCID/(1 + ARV + MAPE)result_{29}$	1	0.796738646	0.637271945	0.990084991
2° $1/(1 + MSE + THEIL)result_{27}$	1	0.56447499	0.509923797	0.859413388
599° $POCID/(1 + MSE + MAPE)result_{26}$	0.028397796	0.026377063	0.023018808	0.02832842
600° $POCID/(1 + MAPE)result_1$	0.023984151	0.023565805	0.022547727	0.023970365
<b>Input:ARV</b>				
1° $POCID/(1 + ARV + MAPE)result_{29}$	1	0.796998126	0.639447945	0.987343677
2° $1/(1 + MSE + THEIL)result_{27}$	1	0.56199046	0.509789599	0.826005886
599° $POCID/(1 + MSE + MAPE)result_{26}$	0.028397796	0.026363883	0.02273355	0.028317457
600° $POCID/(1 + MAPE)result_1$	0.023984151	0.023574414	0.022562246	0.02397194
<b>Input:MAPE</b>				
2° $POCID/(1 + ARV + MAPE)result_{29}$	1	0.869407939	0.749244829	0.994881954
1° $1/(1 + MSE + THEIL)result_{27}$	1	0.628692188	0.542041045	0.89829947
599° $POCID/(1 + MSE + MAPE)result_{26}$	0.135239306	0.129209732	0.117670831	0.135025329
600° $POCID/(1 + MAPE)result_1$	0.128834435	0.127512046	0.124184177	0.128800864
<b>Input:THEIL</b>				
1° $POCID/(1 + ARV + MAPE)result_{29}$	1	0.802900939	0.640511741	0.988962298
2° $1/(1 + MSE + THEIL)result_{27}$	1	0.563525798	0.509672176	0.86086609
599° $POCID/(1 + MSE + MAPE)result_{26}$	0.028794877	0.026768015	0.023349415	0.028741806
600° $POCID/(1 + MAPE)result_1$	0.024163403	0.023754443	0.022815135	0.02415409

Na Figura 37 são apresentadas as fronteiras para cada uma das 4 métricas consideradas como *inputs*.

**Figura 37** – Fronteira BCC-I para a série Produção de Leite(caso específico)



## Conclusões

Neste último capítulo apresenta-se as conclusões acerca do uso da metodologia DEA combinada com técnicas de inteligência artificial aplicadas à previsão de séries temporais. É apresentado também os possíveis trabalhos futuros que podem vir a ser executados como continuidade dos resultados expostos nessa dissertação.

### 6.1 Conclusões

O uso da DEA como técnica de otimização de Função de Fitness mostrou ser consistente quanto a ordenação das melhores Funções em relação aos resultados obtidos pelo Sistema Híbrido Inteligente, que comparado aos valores reais das séries mostraram quais se ajustaram melhor. Foram utilizadas séries com comportamento periódico, com tendência e outra com tendência e peridiocidade e em todas elas o modelo DEA apresentou resultados satisfatórios.

A inclusão ou não da métrica POCID nas Funções de Fitness somente apresentou diferenças significativas para a série de Produção de Leite, apesar do teste de hipóteses indicar que incluir essa métrica nas Funções de Fitness não influencie nas eficiências. Quando observado qual Função de Fitness foi mais eficiente para a Série de Produção de Leite, destacou-se uma Função que continha a métrica POCID. Tal fato indica que por mais que na média, a maioria das eficiências são maiores sem a inclusão do POCID, um resultado do sistema híbrido se destacou entre os demais e esse resultado continha essa métrica. Coube a DEA classificar essas DMUs e verificar quais se destacavam melhor.

Os resultados da comparação entre as Funções de Fitness foi útil para verificar quais Funções se diferenciavam entre si em termos da eficiência. Para cada série realizou-se o teste de tukey [71] e verificou-se que aquelas Funções destacadas em termos de diferenças apresentavam ótimas ou péssimas eficiências, como o ótimo resultado da Função  $1/(1 + MSE + THEIL)$  na série SP&500 e o péssimo resultado da Função  $POCID/(1 + MSE)$  na série Sunspot. Portanto uma análise prévia da comparação entre DMUs foi interessante para reforçar a análise dos resultados.

Separando as análises em dois casos foi possível observar qual foi o comportamento das DMUs quando os *inputs* analisados eram colocados sob a forma individual ou todos agrupados. Em geral, aquelas DMUs que se destacavam no caso geral também apresentavam melhores ou piores eficiências nos *inputs* individuais, exceto o caso da métrica MAPE, talvez por esta não ser bem correlacionada com a demais métricas.

O método *bootstrap* utilizado para estimar as eficiências pôde dar uma melhor noção na ordenação das DMUs mais eficientes. Das 600 DMUs utilizadas, em duas séries (Sunspot e SP&500), houve mais de uma DMU com eficiência máxima e a ordenação das eficiências através da estimativa com correção de viés ajudou a destacar quais dessas foi a melhor. Quando foi plotado os valores previstos das DMUs mais eficientes pôde se observar que o melhor ajuste era da DMU com maior eficiência segundo a estimativa com correção de viés.

É interessante frisar que em alguns casos dos resultados obtidos, a minimização de um determinado erro de previsão não se fez necessário a presença dessa métrica nas combinações de Função de Fitness ou somente a presença dessa métrica na Função de Fitness. Um exemplo é o caso do *input* MAPE na série Sunspot, da qual a melhor Função de Fitness foi a Função  $1/(1 + ARV)$ . Outro caso foi a minimização do *input* MSE que se fez necessário combinar essa métrica com outras para se obter os melhores resultados de eficiência nas series Sunspot e SP&500. No caso da métrica ARV, presente na maiores eficiências dos resultados da Série Sunspot, demonstra que esse tipo de métrica foi importante por captar as flutuações dessa série.

Em geral, a perspectiva do uso da DEA para avaliar as Funções de Fitness foi serve como recurso adicional na área de previsão de séries temporais. Cabe ao pesquisador, avaliar os resultados sob diferentes óticas, quer seja sob a questão do custo computacional de realizar simulações com uma determinada Função que foi mais eficiente ou sob o aspecto de avaliar quais combinações não são desejadas poupando tempo e recursos na hora de avaliar uma determinada série.

## 6.2 Trabalhos Futuros

A seguir é enumerado algumas sugestões para trabalhos futuros em cima do que foi trabalhado nessa dissertação:

1. Investigar com mais acurácia as estimativas das eficiências através do uso do método bootstrap.
2. Utilizar outros tipos de modelo DEA como por exemplo o modelo FDH (*Free Disposal Hull* ou Cone de Livre Disponibilidade) [72].
3. Utilizar outras combinações de métricas de desempenho além das usadas nessa dissertação.
4. Utilizar outros tipos de Sistemas Híbridos inteligentes em conjunto com a DEA como forma de avaliar as eficiências das Funções de Fitness.
5. Utilizar modelos estatísticos clássicos como ARIMA, ARCH, GARCH para comparar os resultados encontrados com os modelos utilizando sistemas híbridos e DEA.
6. Realizar um agrupamento de novas séries temporais com as características já estudada (tendência, sazonalidade e tendência com sazonalidade) para verificar se os resultados encontrados são mantidos dada a presença ou ausência destas características nas séries temporais.

## APÊNDICE A

### Estratégia Evolutiva de dois membros

Neste apêndice é mostrado o algoritmo chamado de Estratégia Evolutiva de dois membros ( *two membered ES*) conforme explicitado no trabalho de *Bäck, Hoffmeister e Schwefel* [73]. Esse algoritmo é baseado em uma população consistindo de um ascendente (pai) e um descendente (filho) criado através da soma de um número aleatório com distribuição normal. O melhor dos dois indivíduos servirá de ancestral para próxima geração. O esquema EE-(1+1), estratégia soma com um ascendente e um descendente, é descrito pela seguinte 8-tupla:

$$EE - (1 + 1) = (P^0, m, s, c_d, c_i, f, g, t)$$

em que,

$$P^0 = (x^0, \sigma^0) \in I$$

$$m : I \rightarrow I$$

$$s : I \times I \rightarrow I$$

$$c_d, c_i \in \mathbb{R}$$

$$f : \mathbb{R}^n \rightarrow \mathbb{R}$$

$$g_j : \mathbb{R}^n \rightarrow \mathbb{R}$$

$$t : I \times I \rightarrow \{0, 1\}$$

onde  $I = \mathbb{R}^n \times \mathbb{R}^n$ ,  $m$  é o operador de mutação,  $s$  é o operador de seleção,  $c_d$  e  $c_i$  são os controles do tamanho do passo da mutação,  $f$  é a função objetivo,  $g_j$  é a função de restrição  $j = \{1, \dots, q\}$  e  $t$  é o critério de parada.  $P^0$  é a população inicial de um pai que gera, através de uma mutação, um filho resultando em,

$$\begin{cases} P'^t = (a_1'^t, a_2'^t) \in I \times I \\ a_1'^t = P^t = (x^t, \sigma^t) \\ a_2'^t = m(P^t) = (x'^t, \sigma^t) \end{cases}$$

onde a operação de mutação é aplicada a todos os componentes do parâmetro  $x^t$ . A mutação no indivíduo é realizada através de uma distribuição normal de números aleatórios,

$$x'^t = x^t + N_0(\sigma^t)$$

$N_0$  é um vetor independente com distribuição Gaussiana com média 0 e desvio padrão  $\sigma_i^t = (i = 1, \dots, n)$ . O operador de seleção escolhe o indivíduo da próxima geração através de um ajuste,

$$P^{t+1} = s(P^t) = \begin{cases} a_2'^t, & \text{se} \begin{cases} f(x'^t) \leq f(x^t), \text{ e} \\ g_j(x'^t) \geq 0 \\ \forall j \in \{1, \dots, q\} \end{cases} \\ a_1'^t = P^t, & \text{c.c.} \end{cases}$$

## APÊNDICE B

### Teste para diferenças entre grupos

Neste apêndice são apresentados dois testes para diferenças entre grupos. O teste de Kolmogorov-Smirnoff e o teste de Kruskal-Wallis [68]. Cada grupo representa as eficiências de um conjunto de DMUs.

#### B.1 Teste de Kolmogorov-Smirnoff para duas amostras

O teste de Kolmogorov-Smirnov (KS) para duas amostras comprova se duas amostras foram extraídas da mesma população ou de populações que seguem a mesma distribuição. Segundo *Siegel* [68], se as duas amostras foram provenientes da mesma população é de se esperar que as distribuições acumuladas de ambas as amostras sejam próximas uma das outras, contendo apenas desvios aleatórios. Se essas distribuições são muito diferentes ou distantes em qualquer ponto, isto sugere que elas venham de populações distintas.

Seja o conjunto de DMUs  $K$  dividido em dois grupos  $K_1$  (de tamanho  $n_1$ ) e  $K_2$  (de tamanho  $n_2$ ), onde  $D = K_1 + K_2$ , sendo o interesse testar se existe diferenças significativas entre os dois grupos. Seja  $F(x)$  e  $G(x)$  as funções de distribuição desconhecidas de  $K_1$  e  $K_2$  respectivamente. E  $S_1(x)$  e  $S_2(x)$  as funções de distribuição acumulada no ponto  $x$  para os dois grupos de DMUs.

O teste de Kolmogorov-Smirnov (KS) realiza um teste de hipótese em que,

$$\begin{cases} H_o : F(x) = G(x), \\ H_a : F(x) \neq G(x) \end{cases}$$

O teste estatístico KS é definido como,

$$T_{KS} = \max [S_1(x) - S_2(x)]$$

## B.2 Teste de Kruskal-Wallis

O teste de Kruskal-Wallis investiga a diferença entre os escores de  $k$  amostras independentes de tamanho desigual. Essas diferenças podem significar diferenças efetivas entre as populações ou apenas variações casuais, esperadas entre amostras aleatórias de uma mesma população [68].

Segundo *Siegel* [68], para o cálculo do Teste de Kruskal-Wallis cada uma das  $N$  observações é substituída por um posto. Ao menor valor atribui-se o posto 1, ao seguinte o posto 2 até o maior posto  $N$ . Onde  $N$  é número total de observações independentes em cada amostra testada.

A hipótese nula testa se as amostras vem de uma mesma população contra a hipótese alternativa de que elas provém de populações diferentes. O procedimento do teste é o seguinte,

- Todas as observações são colocadas em ordem ascendente, atribuindo ao menor valor o posto 1 e ao maior valor o posto  $N$ .
- Para cada uma das amostras é feita a soma dos postos, sendo a soma dos postos dado por  $R_i$ , for  $i = 1, 2, \dots, k$ .
- O teste de Kruskal-Wallis é dado como:

$$H = \frac{12}{N(N+1)} \sum_{i=1}^k \left( \frac{R_i^2}{l_i} - 3(N+1) \right), \text{ onde } N = \sum_{i=1}^k l_i,$$

$N$  é o número de casos em todas as amostras combinadas. Se o número de empates entre os postos é alta,  $H$  é corrigido dividindo por:

$$1 - \frac{\sum (t^3 - t)}{N^3 - N}$$

onde  $t$  é o número de empates num grupo de empates.

A estatística  $H$  usada no teste tem distribuição qui-quadrado com  $gl = k - 1$ , desde que o tamanho das  $k$  amostras não seja suficientemente pequena.

# APÊNDICE C

## Metódo Bootstrap

### C.1 Introdução

O *bootstrap* é um método computacional utilizado para medir a precisão de estimativas estatísticas [74]. A idéia por trás desse método é testar amostras com reposição de um conjunto de dados e por meio disto criar um novo conjunto de dados aleatório de mesmo tamanho que o original. Com esse conjunto de dados, chamado de réplicas, pode-se calcular a estatística necessária, e repetir esse processo até formar um conjunto amostral de réplicas. O método *bootstrap* é descrito nos seguintes passos:

1. Selecione  $B$  amostras *bootstrap* independentes  $x^1, x^2, \dots, x^B$ , amostras essas que são retiradas com reposição do conjunto de dados.
2. Calcule a estimativa para cada amostra *bootstrap*

$$t(x^b), (b = 1, \dots, B)$$

3. Estime o erro usando o erro padrão amostral das  $B$  réplicas através de,

$$\hat{s}_B = \sqrt{\frac{1}{B-1} \sum_{b=1}^B (t(x^b) - \bar{t})^2}$$

$$\bar{t} = \frac{1}{B} \sum_{b=1}^B t(x^b)$$

O método *bootstrap* supõe que se a distribuição de  $x^b$  é próxima da distribuição de  $x$ , então a distribuição de  $t(x^b)$  corresponde a aproximadamente a distribuição de  $t(x)$ . O limite de  $\hat{s}_B$  quando  $B$  vai para o infinito é a convergência para o método *bootstrap*.



## C.2 Utilização do método *bootstrap* em DEA

Seja o espaço amostral de *inputs* e *outputs* de  $K$  DMUs dado pelo conjunto  $\aleph = \{(x^1, y^1), \dots, (x^K, y^K)\}$ . Usamos a amostra, para estimar o conjunto  $T$ . Esse conjunto é formado pela combinação de *inputs* e *outputs*, dado que os recursos podem produzir o produtos. Ou seja,

$$T = \{(x, y) \mid x \text{ pode produzir } y\}$$

Assumindo que o modelo segue retornos variáveis de escala, a estimativa de  $\hat{T}$  é dado por,

$$\hat{T} = \left\{ (x, y) \mid x \geq \sum_{k=1}^K \lambda^k x^k, y \geq \sum_{k=1}^K \lambda^k y^k, \lambda^k \geq 0, \sum_{k=1}^K \lambda^k = 1 \right\}$$

e a estimativa da eficiência é dado por,

$$\hat{E}^k = \min \left\{ \theta \in \mathfrak{R} \mid (\theta x^k, y^k) \in \hat{T} \right\}, (k = 1, \dots, n)$$

A amostra  $\aleph$  é considerada uma variável aleatória independente e identicamente distribuída, com distribuição de probabilidade  $P$  com suporte em  $T$ . Por fim, a distribuição de  $\hat{E}^k$  e  $\hat{T}$  depende da distribuição das amostras de  $\aleph$ .

### C.2.1 Correção de Viés

Segundo *Bogetoft e Otto* [65], a estimativa da eficiência no modelo DEA é viesada para cima. Isto porque, se não existe erros de medição, então todas as observações na amostra são definidas a partir da tecnologia  $\hat{T} \subset T$ . Então  $\hat{E}^k \geq E^k$ , porque a minimização é feita ao longo de um conjunto menor, podendo a eficiência estimada ser maior que a eficiência real. O tamanho do conjunto  $\hat{T}$  depende da amostra, e portanto,  $E^k$  é sensível a variações na fronteira obtida. O viés estimado é dado por,

$$bias^k = EV(\hat{\theta}^k) - \theta^k$$

onde  $\theta$  é a eficiência verdadeira e  $\theta^k$  é a eficiência estimada. Como não se conhece a distribuição de  $EV(\hat{\theta}^k)$ , utiliza-se o método *bootstrap* para fazê-lo. A estimativa do viés, através do método *bootstrap* é dado por,

$$bias^{k*} = \frac{1}{B} \sum_{b=1}^B (\theta^{kb} - \hat{\theta}^k) = \bar{\theta}^{k*} - \hat{\theta}^k$$

um estimador com viés corrigido de  $\theta^k$  é dado por

$$\tilde{\theta}^k = \hat{\theta}^k - \bar{\theta}^* + \hat{\theta}^k = 2\hat{\theta}^k - \bar{\theta}^{k*}$$

A precisão da estimativa pode ser determinada através da variância da estimativa *bootstrap*.

$$\sigma^2 = \frac{1}{B} \sum_{b=1}^B (\theta^{kb} - \bar{\theta}^{k*})^2$$

Mais a respeito do assunto abordado nesse Apêndice C, pode ser visto nos artigos de Simar e Wilson [66, 67] e Banker [75].

## **APÊNDICE D**

# **Resultados dos Modelos DEA e Testes de Hipóteses**

### **D.1 Introdução**

Neste apêndice é apresentado as Tabelas referentes aos resultados dos modelos DEA para cada série temporal utilizada, além dos resultados dos testes de hipóteses aplicados no Capítulo 5. O resumo do que é apresentado é mostrado a seguir:

1. Resultado do Teste de Tukey para as séries analisadas - Tabela 18
2. Eficiências classificadas por grupo: Série Sunspot - Tabela 19
3. Eficiências classificadas por grupo: Série SP&500 - Tabela 20
4. Eficiências classificadas por grupo: Série Produção de Leite - Tabela 21
5. Eficiências e estimativas para o caso geral - Tabela 22

Tabela 18 – Resultado do Teste de Tukey para as séries analisadas

Teste de Tukey														
Série Sunspot					Série SP&500					Série Produção de Leite				
Grupos	Dif.	L. Inf.	L. Sup.	p-valor	Grupos	Dif.	L. Inf.	L. Sup.	p-valor	Grupos	Dif.	L. Inf.	L. Sup.	p-valor
19-13	0.2393	0.1384	0.3402	0.0000	7-2	0.1594	0.0505	0.2682	0.0000	10-12	0.3448	0.2118	0.4777	0.0000
5-13	0.2309	0.1300	0.3318	0.0000	7-12	0.1516	0.0428	0.2605	0.0002	7-13	0.3423	0.2093	0.4753	0.0000
20-13	0.2267	0.1258	0.3276	0.0000	9-13	0.1512	0.0423	0.2600	0.0002	10-13	0.3415	0.2085	0.4744	0.0000
1-13	0.2224	0.1215	0.3233	0.0000	7-3	0.1498	0.0409	0.2586	0.0002	9-12	0.3347	0.2017	0.4676	0.0000
17-13	0.2185	0.1175	0.3194	0.0000	7-16	0.1454	0.0365	0.2542	0.0004	9-13	0.3313	0.1984	0.4643	0.0000
14-13	0.2169	0.1160	0.3179	0.0000	7-6	0.1434	0.0345	0.2523	0.0006	7-16	0.3165	0.1836	0.4495	0.0000
7-13	0.2122	0.1113	0.3132	0.0000	9-2	0.1427	0.0339	0.2516	0.0007	10-16	0.3157	0.1827	0.4487	0.0000
2-13	0.2115	0.1105	0.3124	0.0000	9-12	0.1350	0.0261	0.2438	0.0020	4-12	0.3145	0.1816	0.4475	0.0000
18-13	0.2105	0.1096	0.3114	0.0000	9-3	0.1331	0.0243	0.2420	0.0026	4-13	0.3112	0.1783	0.4442	0.0000
4-13	0.2035	0.1025	0.3044	0.0000	14-13	0.1305	0.0217	0.2394	0.0037	5-12	0.3105	0.1775	0.4435	0.0000
10-13	0.2025	0.1016	0.3034	0.0000	9-16	0.1287	0.0199	0.2376	0.0047	5-13	0.3072	0.1742	0.4402	0.0000
6-13	0.1910	0.0901	0.2920	0.0000	4-13	0.1268	0.0179	0.2357	0.0061	9-16	0.3056	0.1726	0.4386	0.0000
16-13	0.1907	0.0897	0.2916	0.0000	9-6	0.1267	0.0179	0.2356	0.0061	4-16	0.2855	0.1525	0.4185	0.0000
12-13	0.1878	0.0869	0.2887	0.0000	14-2	0.1221	0.0133	0.2310	0.0110	5-16	0.2815	0.1485	0.4144	0.0000
11-13	0.1851	0.0842	0.2860	0.0000	4-2	0.1184	0.0095	0.2272	0.0173	1-12	0.2750	0.1420	0.4080	0.0000
3-13	0.1818	0.0809	0.2827	0.0000	14-12	0.1144	0.0055	0.2232	0.0275	1-13	0.2717	0.1387	0.4047	0.0000
9-13	0.1815	0.0806	0.2824	0.0000	14-3	0.1125	0.0036	0.2214	0.0339	8-12	0.2577	0.1247	0.3907	0.0000
15-13	0.1791	0.0782	0.2800	0.0000	4-12	0.1106	0.0018	0.2195	0.0415	8-13	0.2544	0.1214	0.3874	0.0000
8-15	0.0687	-0.0322	0.1696	0.6422	10-13	0.1097	0.0008	0.2186	0.0457	1-16	0.2459	0.1129	0.3789	0.0000
8-9	0.0663	-0.0346	0.1673	0.7048	18-13	0.1093	0.0004	0.2181	0.0480	7-11	0.2320	0.0990	0.3650	0.0000
8-3	0.0660	-0.0349	0.1669	0.7127	4-3	0.1088	-0.0001	0.2176	0.0506	10-11	0.2312	0.0982	0.3642	0.0000
8-11	0.0627	-0.0382	0.1636	0.7922	19-13	0.1086	-0.0002	0.2175	0.0512	20-12	0.2294	0.0965	0.3624	0.0000
19-15	0.0602	-0.0407	0.1611	0.8436	14-16	0.1081	-0.0008	0.2170	0.0541	8-16	0.2286	0.0957	0.3616	0.0000
8-12	0.0600	-0.0409	0.1609	0.8472	8-13	0.1068	-0.0020	0.2157	0.0617	20-13	0.2261	0.0932	0.3591	0.0000
19-9	0.0578	-0.0431	0.1587	0.8850	14-6	0.1061	-0.0027	0.2150	0.0662	3-12	0.2236	0.0906	0.3566	0.0000
19-3	0.0575	-0.0434	0.1584	0.8898	4-16	0.1044	-0.0045	0.2132	0.0787	9-11	0.2211	0.0881	0.3540	0.0000
8-16	0.0572	-0.0437	0.1581	0.8946	4-6	0.1024	-0.0065	0.2113	0.0953	3-13	0.2203	0.0873	0.3533	0.0000
8-6	0.0568	-0.0441	0.1577	0.9004	10-2	0.1013	-0.0076	0.2102	0.1054	2-12	0.2147	0.0817	0.3477	0.0000
19-11	0.0541	-0.0468	0.1551	0.9337	18-2	0.1008	-0.0080	0.2097	0.1100	7-6	0.2141	0.0811	0.3471	0.0000
5-15	0.0518	-0.0491	0.1527	0.9561	19-2	0.1002	-0.0086	0.2091	0.1162	10-6	0.2133	0.0803	0.3463	0.0000
19-12	0.0514	-0.0495	0.1524	0.9587	8-2	0.0984	-0.0105	0.2073	0.1367	2-13	0.2114	0.0784	0.3443	0.0000
5-9	0.0494	-0.0515	0.1503	0.9725	17-13	0.0979	-0.0110	0.2068	0.1430	19-12	0.2072	0.0742	0.3402	0.0000
5-3	0.0491	-0.0518	0.1500	0.9742	15-13	0.0975	-0.0114	0.2063	0.1482	14-12	0.2071	0.0741	0.3401	0.0000
19-16	0.0486	-0.0523	0.1495	0.9766	7-11	0.0973	-0.0115	0.2062	0.1499	19-13	0.2039	0.0709	0.3369	0.0000
19-6	0.0482	-0.0527	0.1491	0.9785	10-12	0.0935	-0.0153	0.2024	0.2047	18-12	0.2039	0.0709	0.3369	0.0000
20-15	0.0476	-0.0533	0.1485	0.9812	18-12	0.0931	-0.0158	0.2019	0.2121	14-13	0.2038	0.0708	0.3368	0.0000
5-11	0.0457	-0.0552	0.1466	0.9879	19-12	0.0925	-0.0164	0.2013	0.2223	9-6	0.2032	0.0702	0.3361	0.0000
8-10	0.0453	-0.0556	0.1462	0.9891	10-3	0.0917	-0.0172	0.2005	0.2361	4-11	0.2010	0.0680	0.3339	0.0000
20-9	0.0452	-0.0557	0.1462	0.9893	18-3	0.0912	-0.0176	0.2001	0.2442	18-13	0.2006	0.0676	0.3336	0.0000
20-3	0.0449	-0.0560	0.1458	0.9901	8-12	0.0906	-0.0182	0.1995	0.2548	20-16	0.2004	0.0674	0.3334	0.0000
8-4	0.0444	-0.0566	0.1453	0.9915	19-3	0.0906	-0.0183	0.1995	0.2554	5-11	0.1969	0.0639	0.3299	0.0000
1-15	0.0433	-0.0576	0.1442	0.9935	17-2	0.0895	-0.0194	0.1983	0.2771	7-15	0.1951	0.0621	0.3281	0.0000
5-12	0.0430	-0.0579	0.1439	0.9941	15-2	0.0891	-0.0198	0.1979	0.2852	3-16	0.1945	0.0615	0.3275	0.0000
20-11	0.0416	-0.0593	0.1425	0.9961	8-3	0.0888	-0.0201	0.1977	0.2908	10-15	0.1943	0.0613	0.3273	0.0001
1-9	0.0409	-0.0600	0.1419	0.9968	10-16	0.0873	-0.0216	0.1962	0.3217	2-16	0.1856	0.0526	0.3186	0.0002
1-3	0.0406	-0.0603	0.1415	0.9971	7-1	0.0872	-0.0216	0.1961	0.3228	9-15	0.1842	0.0512	0.3171	0.0002
5-16	0.0402	-0.0607	0.1411	0.9974	18-16	0.0868	-0.0220	0.1957	0.3315	4-6	0.1831	0.0501	0.3160	0.0002
5-6	0.0398	-0.0611	0.1407	0.9977	19-16	0.0862	-0.0226	0.1951	0.3448	5-6	0.1790	0.0461	0.3120	0.0004
17-15	0.0394	-0.0615	0.1403	0.9980	7-5	0.0857	-0.0231	0.1946	0.3560	19-16	0.1781	0.0452	0.3111	0.0004
20-12	0.0389	-0.0620	0.1398	0.9983	10-6	0.0853	-0.0236	0.1942	0.3654	14-16	0.1780	0.0451	0.3110	0.0004
14-15	0.0379	-0.0630	0.1388	0.9988	18-6	0.0849	-0.0240	0.1937	0.3758	18-16	0.1748	0.0419	0.3078	0.0006
8-18	0.0373	-0.0636	0.1382	0.9990	20-13	0.0844	-0.0245	0.1933	0.3862	7-17	0.1741	0.0411	0.3070	0.0007
1-11	0.0373	-0.0636	0.1382	0.9990	8-16	0.0844	-0.0245	0.1933	0.3863	10-17	0.1732	0.0402	0.3062	0.0008
17-9	0.0370	-0.0639	0.1379	0.9991	19-6	0.0842	-0.0246	0.1931	0.3900	17-12	0.1715	0.0386	0.3045	0.0009

19-10	0.0368	-0.0641	0.1377	0.9992	7-20	0.0834	-0.0255	0.1923	0.4103	17-13	0.1682	0.0353	0.3012	0.0014
17-3	0.0367	-0.0642	0.1376	0.9992	8-6	0.0824	-0.0264	0.1913	0.4336	4-15	0.1641	0.0311	0.2970	0.0022
8-2	0.0364	-0.0645	0.1373	0.9993	5-13	0.0821	-0.0268	0.1909	0.4423	9-17	0.1631	0.0301	0.2961	0.0025
20-16	0.0361	-0.0649	0.1370	0.9994	17-12	0.0817	-0.0271	0.1906	0.4508	1-11	0.1614	0.0284	0.2944	0.0030
19-4	0.0358	-0.0651	0.1367	0.9995	15-12	0.0813	-0.0276	0.1902	0.4610	5-15	0.1600	0.0270	0.2930	0.0035
20-6	0.0357	-0.0652	0.1366	0.9995	9-11	0.0807	-0.0282	0.1896	0.4760	15-12	0.1505	0.0175	0.2835	0.0096
8-7	0.0356	-0.0653	0.1365	0.9995	1-13	0.0805	-0.0283	0.1894	0.4799	15-13	0.1472	0.0142	0.2802	0.0134
14-9	0.0355	-0.0654	0.1364	0.9995	17-3	0.0799	-0.0290	0.1887	0.4973	8-11	0.1441	0.0111	0.2771	0.0181
14-3	0.0352	-0.0657	0.1361	0.9996	15-3	0.0794	-0.0294	0.1883	0.5077	1-6	0.1435	0.0105	0.2765	0.0192
1-12	0.0346	-0.0663	0.1355	0.9997	20-2	0.0760	-0.0329	0.1849	0.5958	4-17	0.1430	0.0100	0.2760	0.0201
17-11	0.0333	-0.0676	0.1342	0.9998	17-16	0.0755	-0.0334	0.1843	0.6090	17-16	0.1425	0.0095	0.2755	0.0211
7-15	0.0332	-0.0678	0.1341	0.9998	15-16	0.0751	-0.0338	0.1839	0.6194	7-18	0.1417	0.0087	0.2747	0.0227
2-15	0.0324	-0.0685	0.1333	0.9999	5-2	0.0737	-0.0352	0.1825	0.6546	10-18	0.1409	0.0079	0.2739	0.0246
14-11	0.0318	-0.0691	0.1327	0.9999	17-6	0.0735	-0.0354	0.1824	0.6587	5-17	0.1390	0.0060	0.2719	0.0294
1-16	0.0318	-0.0691	0.1327	0.9999	15-6	0.0731	-0.0358	0.1819	0.6688	7-14	0.1385	0.0055	0.2715	0.0307
18-15	0.0314	-0.0695	0.1323	0.9999	1-2	0.0721	-0.0367	0.1810	0.6916	7-19	0.1384	0.0054	0.2714	0.0309
1-6	0.0314	-0.0695	0.1323	0.9999	9-1	0.0706	-0.0383	0.1795	0.7275	10-14	0.1377	0.0047	0.2706	0.0331
8-14	0.0309	-0.0700	0.1318	0.9999	11-13	0.0704	-0.0384	0.1793	0.7311	10-19	0.1376	0.0046	0.2705	0.0334
7-9	0.0308	-0.0701	0.1317	0.9999	7-15	0.0703	-0.0386	0.1792	0.7342	6-12	0.1315	-0.0015	0.2645	0.0568
17-12	0.0306	-0.0703	0.1315	0.9999	7-17	0.0699	-0.0390	0.1788	0.7435	7-2	0.1309	-0.0020	0.2639	0.0595
7-3	0.0305	-0.0704	0.1314	0.9999	9-5	0.0691	-0.0398	0.1780	0.7615	9-18	0.1308	-0.0022	0.2637	0.0603
2-9	0.0300	-0.0709	0.1309	1	20-12	0.0682	-0.0406	0.1771	0.7798	10-2	0.1301	-0.0029	0.2631	0.0637
2-3	0.0297	-0.0712	0.1306	1	9-20	0.0667	-0.0421	0.1756	0.8098	6-13	0.1282	-0.0048	0.2612	0.0745
8-17	0.0294	-0.0715	0.1303	1	20-3	0.0664	-0.0425	0.1752	0.8171	9-14	0.1275	-0.0054	0.2605	0.0785
14-12	0.0291	-0.0718	0.1300	1	5-12	0.0659	-0.0430	0.1748	0.8261	9-19	0.1275	-0.0055	0.2604	0.0790
18-9	0.0290	-0.0719	0.1299	1	1-12	0.0644	-0.0445	0.1732	0.8531	8-6	0.1262	-0.0068	0.2592	0.0871
19-18	0.0288	-0.0722	0.1297	1	5-3	0.0640	-0.0448	0.1729	0.8589	1-15	0.1245	-0.0085	0.2575	0.0996
18-3	0.0287	-0.0722	0.1296	1	1-3	0.0625	-0.0464	0.1714	0.8826	7-3	0.1220	-0.0110	0.2550	0.1198
5-10	0.0284	-0.0725	0.1293	1	11-2	0.0620	-0.0468	0.1709	0.8896	15-16	0.1214	-0.0115	0.2544	0.1251
19-2	0.0278	-0.0731	0.1287	1	20-16	0.0620	-0.0469	0.1709	0.8903	10-3	0.1212	-0.0118	0.2542	0.1274
17-16	0.0278	-0.0731	0.1287	1	7-8	0.0610	-0.0479	0.1698	0.9041	9-2	0.1200	-0.0130	0.2530	0.1390
17-6	0.0274	-0.0735	0.1283	1	14-11	0.0601	-0.0488	0.1689	0.9152	7-20	0.1162	-0.0168	0.2491	0.1808
5-4	0.0274	-0.0735	0.1283	1	20-6	0.0600	-0.0489	0.1689	0.9161	20-11	0.1159	-0.0171	0.2488	0.1845
7-11	0.0271	-0.0738	0.1280	1	5-16	0.0596	-0.0492	0.1685	0.9203	10-20	0.1153	-0.0177	0.2483	0.1910
19-7	0.0270	-0.0739	0.1279	1	7-19	0.0591	-0.0497	0.1680	0.9259	11-12	0.1136	-0.0194	0.2466	0.2136
2-11	0.0263	-0.0746	0.1272	1	7-18	0.0585	-0.0503	0.1674	0.9324	9-3	0.1111	-0.0219	0.2440	0.2496
14-16	0.0263	-0.0746	0.1272	1	1-16	0.0581	-0.0507	0.1670	0.9364	4-18	0.1107	-0.0223	0.2436	0.2558
14-6	0.0259	-0.0750	0.1268	1	7-10	0.0581	-0.0508	0.1669	0.9370	11-13	0.1103	-0.0227	0.2433	0.2614
8-1	0.0254	-0.0755	0.1263	1	5-6	0.0577	-0.0512	0.1665	0.9409	3-11	0.1100	-0.0230	0.2430	0.2661
18-11	0.0254	-0.0755	0.1263	1	4-11	0.0563	-0.0525	0.1652	0.9523	4-14	0.1074	-0.0255	0.2404	0.3078
7-12	0.0244	-0.0765	0.1253	1	1-6	0.0561	-0.0527	0.1650	0.9539	4-19	0.1073	-0.0256	0.2403	0.3093
4-15	0.0244	-0.0765	0.1253	1	11-12	0.0543	-0.0546	0.1631	0.9668	8-15	0.1072	-0.0258	0.2402	0.3116
20-10	0.0242	-0.0767	0.1251	1	9-15	0.0537	-0.0552	0.1625	0.9703	5-18	0.1066	-0.0263	0.2396	0.3217
2-12	0.0236	-0.0773	0.1245	1	9-17	0.0533	-0.0556	0.1621	0.9726	9-20	0.1052	-0.0278	0.2382	0.3470
10-15	0.0234	-0.0775	0.1243	1	11-3	0.0524	-0.0565	0.1613	0.9768	1-17	0.1034	-0.0295	0.2364	0.3798
20-4	0.0233	-0.0777	0.1242	1	14-1	0.0500	-0.0589	0.1588	0.9861	5-14	0.1034	-0.0296	0.2364	0.3803
18-12	0.0227	-0.0782	0.1236	1	14-5	0.0485	-0.0604	0.1573	0.9902	5-19	0.1033	-0.0297	0.2363	0.3820
19-14	0.0223	-0.0786	0.1232	1	11-16	0.0480	-0.0608	0.1569	0.9911	6-16	0.1024	-0.0306	0.2354	0.3992
4-9	0.0220	-0.0789	0.1229	1	4-1	0.0462	-0.0626	0.1551	0.9943	2-11	0.1011	-0.0319	0.2341	0.4255
4-3	0.0217	-0.0792	0.1226	1	14-20	0.0461	-0.0627	0.1550	0.9945	4-2	0.0999	-0.0331	0.2329	0.4497
7-16	0.0216	-0.0793	0.1225	1	11-6	0.0460	-0.0628	0.1549	0.9946	20-6	0.0980	-0.0350	0.2309	0.4888
7-6	0.0212	-0.0797	0.1221	1	4-5	0.0447	-0.0641	0.1536	0.9962	5-2	0.0958	-0.0371	0.2288	0.5326
8-20	0.0211	-0.0798	0.1220	1	9-8	0.0443	-0.0645	0.1532	0.9966	19-11	0.0936	-0.0394	0.2266	0.5794
10-9	0.0210	-0.0799	0.1219	1	9-19	0.0425	-0.0664	0.1514	0.9980	14-11	0.0935	-0.0395	0.2265	0.5813
19-17	0.0208	-0.0801	0.1217	1	4-20	0.0424	-0.0665	0.1513	0.9981	3-6	0.0921	-0.0409	0.2251	0.6109
2-16	0.0208	-0.0801	0.1217	1	9-18	0.0419	-0.0670	0.1508	0.9984	4-3	0.0910	-0.0420	0.2239	0.6342
10-3	0.0207	-0.0802	0.1216	1	9-10	0.0414	-0.0674	0.1503	0.9986	18-11	0.0903	-0.0427	0.2233	0.6478
2-6	0.0204	-0.0805	0.1213	1	7-4	0.0410	-0.0679	0.1499	0.9988	7-8	0.0879	-0.0451	0.2209	0.6958

5-18	0.0204	-0.0806	0.1213	1	10-11	0.0393	-0.0696	0.1481	0.9993	10-8	0.0871	-0.0459	0.2200	0.7120
1-10	0.0199	-0.0810	0.1208	1	18-11	0.0388	-0.0701	0.1477	0.9994	5-3	0.0869	-0.0460	0.2199	0.7143
18-16	0.0199	-0.0811	0.1208	1	19-11	0.0382	-0.0707	0.1471	0.9995	8-17	0.0862	-0.0468	0.2191	0.7291
18-6	0.0195	-0.0814	0.1204	1	7-14	0.0373	-0.0716	0.1461	0.9997	4-20	0.0851	-0.0479	0.2181	0.7486
5-2	0.0194	-0.0815	0.1203	1	8-11	0.0364	-0.0725	0.1452	0.9998	11-16	0.0845	-0.0484	0.2175	0.7590
1-4	0.0190	-0.0820	0.1199	1	14-15	0.0330	-0.0758	0.1419	0.9999	2-6	0.0832	-0.0498	0.2162	0.7824
5-7	0.0186	-0.0823	0.1195	1	14-17	0.0326	-0.0762	0.1415	1	5-20	0.0811	-0.0519	0.2141	0.8170
4-11	0.0183	-0.0826	0.1192	1	4-15	0.0293	-0.0796	0.1382	1	20-15	0.0789	-0.0540	0.2119	0.8487
10-11	0.0174	-0.0836	0.1183	1	10-1	0.0292	-0.0797	0.1380	1	9-8	0.0769	-0.0560	0.2099	0.8754
8-5	0.0170	-0.0840	0.1179	1	4-17	0.0289	-0.0800	0.1378	1	19-6	0.0757	-0.0573	0.2087	0.8903
19-1	0.0169	-0.0841	0.1178	1	18-1	0.0287	-0.0802	0.1376	1	14-6	0.0756	-0.0574	0.2086	0.8913
20-18	0.0162	-0.0847	0.1171	1	19-1	0.0281	-0.0808	0.1370	1	3-15	0.0731	-0.0599	0.2061	0.9181
17-10	0.0160	-0.0849	0.1169	1	10-5	0.0276	-0.0812	0.1365	1	18-6	0.0724	-0.0606	0.2054	0.9245
4-12	0.0156	-0.0853	0.1165	1	17-11	0.0274	-0.0814	0.1363	1	1-18	0.0711	-0.0619	0.2041	0.9357
20-2	0.0153	-0.0857	0.1162	1	18-5	0.0272	-0.0817	0.1361	1	7-1	0.0706	-0.0624	0.2036	0.9395
17-4	0.0150	-0.0859	0.1159	1	15-11	0.0270	-0.0818	0.1359	1	10-1	0.0698	-0.0632	0.2028	0.9457
10-12	0.0147	-0.0863	0.1156	1	19-5	0.0266	-0.0823	0.1354	1	1-14	0.0679	-0.0651	0.2009	0.9582
20-7	0.0145	-0.0864	0.1154	1	8-1	0.0263	-0.0826	0.1351	1	1-19	0.0678	-0.0652	0.2008	0.9588
14-10	0.0145	-0.0864	0.1154	1	10-20	0.0253	-0.0836	0.1342	1	2-15	0.0642	-0.0688	0.1972	0.9762
5-14	0.0139	-0.0870	0.1148	1	18-20	0.0249	-0.0840	0.1337	1	1-2	0.0603	-0.0727	0.1933	0.9878
14-4	0.0135	-0.0874	0.1144	1	8-5	0.0248	-0.0841	0.1336	1	9-1	0.0597	-0.0733	0.1926	0.9892
4-16	0.0128	-0.0881	0.1137	1	6-13	0.0244	-0.0845	0.1333	1	17-11	0.0580	-0.0750	0.1909	0.9923
19-20	0.0126	-0.0884	0.1135	1	9-4	0.0244	-0.0845	0.1332	1	20-17	0.0579	-0.0751	0.1909	0.9924
4-6	0.0124	-0.0885	0.1133	1	19-20	0.0242	-0.0846	0.1331	1	4-8	0.0568	-0.0761	0.1898	0.9939
5-17	0.0124	-0.0885	0.1133	1	14-8	0.0237	-0.0852	0.1326	1	19-15	0.0567	-0.0763	0.1897	0.9941
6-15	0.0120	-0.0890	0.1129	1	16-13	0.0224	-0.0864	0.1313	1	14-15	0.0566	-0.0764	0.1896	0.9942
1-18	0.0119	-0.0890	0.1128	1	8-20	0.0224	-0.0864	0.1313	1	8-18	0.0538	-0.0792	0.1868	0.9969
10-16	0.0118	-0.0891	0.1127	1	14-19	0.0219	-0.0870	0.1307	1	18-15	0.0534	-0.0796	0.1864	0.9972
16-15	0.0116	-0.0893	0.1125	1	14-18	0.0213	-0.0876	0.1301	1	5-8	0.0528	-0.0802	0.1858	0.9975
10-6	0.0114	-0.0895	0.1124	1	14-10	0.0208	-0.0880	0.1297	1	3-17	0.0520	-0.0809	0.1850	0.9980
1-2	0.0110	-0.0899	0.1119	1	9-14	0.0206	-0.0882	0.1295	1	1-3	0.0514	-0.0816	0.1844	0.9983
1-7	0.0102	-0.0907	0.1111	1	4-8	0.0200	-0.0889	0.1288	1	8-14	0.0506	-0.0824	0.1836	0.9986
20-14	0.0098	-0.0911	0.1107	1	4-19	0.0181	-0.0907	0.1270	1	8-19	0.0505	-0.0825	0.1835	0.9986
7-10	0.0098	-0.0912	0.1107	1	3-13	0.0180	-0.0908	0.1269	1	1-20	0.0455	-0.0874	0.1785	0.9997
6-9	0.0096	-0.0913	0.1105	1	4-18	0.0175	-0.0913	0.1264	1	2-17	0.0431	-0.0899	0.1761	0.9998
6-3	0.0093	-0.0916	0.1102	1	17-1	0.0173	-0.0915	0.1262	1	8-2	0.0430	-0.0899	0.1760	0.9999
16-9	0.0092	-0.0917	0.1101	1	4-10	0.0171	-0.0918	0.1259	1	17-6	0.0401	-0.0929	0.1730	0.9999
2-10	0.0090	-0.0919	0.1099	1	15-1	0.0169	-0.0919	0.1258	1	4-1	0.0396	-0.0934	0.1725	1
16-3	0.0089	-0.0920	0.1098	1	7-9	0.0166	-0.0922	0.1255	1	15-11	0.0369	-0.0961	0.1699	1
7-4	0.0088	-0.0921	0.1097	1	12-13	0.0162	-0.0927	0.1250	1	19-17	0.0357	-0.0973	0.1686	1
12-15	0.0087	-0.0922	0.1097	1	6-2	0.0160	-0.0929	0.1249	1	14-17	0.0356	-0.0974	0.1685	1
8-19	0.0086	-0.0924	0.1095	1	17-5	0.0158	-0.0930	0.1247	1	5-1	0.0355	-0.0974	0.1685	1
5-1	0.0084	-0.0925	0.1094	1	15-5	0.0154	-0.0935	0.1243	1	7-5	0.0351	-0.0979	0.1681	1
19-5	0.0084	-0.0925	0.1093	1	16-2	0.0140	-0.0949	0.1229	1	10-5	0.0342	-0.0987	0.1672	1
20-17	0.0083	-0.0927	0.1092	1	20-11	0.0140	-0.0949	0.1228	1	8-3	0.0341	-0.0988	0.1671	1
18-10	0.0080	-0.0929	0.1089	1	17-20	0.0135	-0.0954	0.1224	1	18-17	0.0323	-0.1006	0.1653	1
2-4	0.0080	-0.0929	0.1089	1	15-20	0.0131	-0.0958	0.1219	1	7-4	0.0311	-0.1019	0.1640	1
17-18	0.0079	-0.0930	0.1089	1	10-15	0.0122	-0.0966	0.1211	1	10-4	0.0302	-0.1028	0.1632	1
18-4	0.0070	-0.0939	0.1080	1	10-17	0.0118	-0.0970	0.1207	1	16-12	0.0291	-0.1039	0.1620	1
17-2	0.0070	-0.0939	0.1079	1	18-15	0.0118	-0.0971	0.1206	1	8-20	0.0283	-0.1047	0.1612	1
14-18	0.0064	-0.0945	0.1074	1	5-11	0.0116	-0.0972	0.1205	1	16-13	0.0258	-0.1072	0.1587	1
12-9	0.0064	-0.0946	0.1073	1	18-17	0.0114	-0.0975	0.1202	1	20-18	0.0256	-0.1074	0.1585	1
17-7	0.0062	-0.0947	0.1071	1	19-15	0.0112	-0.0977	0.1200	1	9-5	0.0241	-0.1088	0.1571	1
12-3	0.0060	-0.0949	0.1070	1	19-17	0.0108	-0.0981	0.1196	1	20-14	0.0223	-0.1106	0.1553	1
11-15	0.0060	-0.0949	0.1070	1	1-11	0.0101	-0.0988	0.1190	1	20-19	0.0222	-0.1107	0.1552	1
6-11	0.0059	-0.0950	0.1068	1	3-2	0.0096	-0.0992	0.1185	1	17-15	0.0211	-0.1119	0.1540	1
16-11	0.0055	-0.0954	0.1064	1	8-15	0.0093	-0.0995	0.1182	1	9-4	0.0201	-0.1129	0.1531	1
14-2	0.0055	-0.0954	0.1064	1	8-17	0.0089	-0.0999	0.1178	1	3-18	0.0197	-0.1133	0.1527	1

1-14	0.0055	-0.0954	0.1064	1	2-13	0.0084	-0.1005	0.1173	1	15-6	0.0190	-0.1140	0.1520	1
14-7	0.0047	-0.0962	0.1056	1	6-12	0.0082	-0.1006	0.1171	1	6-11	0.0179	-0.1151	0.1509	1
20-1	0.0043	-0.0966	0.1052	1	12-2	0.0078	-0.1011	0.1166	1	1-8	0.0173	-0.1157	0.1503	1
5-20	0.0042	-0.0968	0.1051	1	6-3	0.0064	-0.1025	0.1152	1	3-14	0.0165	-0.1165	0.1494	1
1-17	0.0040	-0.0970	0.1049	1	16-12	0.0062	-0.1026	0.1151	1	3-19	0.0164	-0.1166	0.1494	1
11-9	0.0037	-0.0973	0.1046	1	16-3	0.0044	-0.1045	0.1132	1	20-2	0.0148	-0.1182	0.1477	1
11-3	0.0033	-0.0976	0.1043	1	20-1	0.0039	-0.1050	0.1127	1	7-9	0.0110	-0.1220	0.1439	1
6-12	0.0032	-0.0977	0.1041	1	14-4	0.0037	-0.1051	0.1126	1	2-18	0.0108	-0.1222	0.1438	1
16-12	0.0028	-0.0981	0.1037	1	10-8	0.0029	-0.1060	0.1118	1	10-9	0.0101	-0.1229	0.1431	1
12-11	0.0027	-0.0982	0.1036	1	18-8	0.0024	-0.1064	0.1113	1	3-2	0.0089	-0.1241	0.1419	1
3-15	0.0027	-0.0982	0.1036	1	20-5	0.0023	-0.1065	0.1112	1	2-14	0.0076	-0.1254	0.1405	1
9-15	0.0024	-0.0985	0.1033	1	6-16	0.0020	-0.1069	0.1109	1	2-19	0.0075	-0.1255	0.1405	1
7-18	0.0017	-0.0992	0.1027	1	3-12	0.0019	-0.1070	0.1107	1	20-3	0.0059	-0.1271	0.1388	1
17-14	0.0015	-0.0994	0.1024	1	19-8	0.0018	-0.1070	0.1107	1	4-5	0.0040	-0.1290	0.1370	1
4-10	0.0010	-0.0999	0.1019	1	5-1	0.0015	-0.1073	0.1104	1	19-18	0.0033	-0.1297	0.1363	1
2-18	0.0009	-0.1000	0.1019	1	10-19	0.0011	-0.1078	0.1099	1	13-12	0.0033	-0.1297	0.1363	1
7-2	0.0008	-0.1001	0.1017	1	18-19	0.0006	-0.1083	0.1095	1	14-18	0.0032	-0.1298	0.1362	1
6-16	0.0004	-0.1005	0.1013	1	10-18	0.0005	-0.1084	0.1093	1	7-10	0.0008	-0.1321	0.1338	1
3-9	0.0003	-0.1006	0.1012	1	17-15	0.0004	-0.1085	0.1093	1	7-10	0.0008	-0.1321	0.1338	1

**Tabela 19 – Eficiências classificadas por grupo: Série Sunspot**

Funções de Fitness																				
	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10	F11	F12	F13	F14	F15	F16	F17	F18	F19	F20
1	0.58893	0.54858	0.70774	0.91510	0.61817	0.71944	0.79112	0.81767	0.59352	0.69077	0.87142	0.79164	0.43499	0.78489	0.75992	0.60734	0.62637	0.79637	0.75242	0.78054
2	0.76137	0.84260	0.73840	0.75982	0.60511	0.74866	0.82299	0.72687	0.82821	0.53899	0.79417	0.75965	0.52343	0.53138	1.00000	0.77623	0.77405	0.66802	0.58609	0.87341
3	0.95331	0.64153	0.67577	0.68073	0.78664	0.72486	0.70841	0.78106	0.73913	0.74911	0.68697	0.79938	0.55000	0.71900	0.46728	0.72413	0.79635	0.82689	0.89052	0.86116
4	0.73038	0.62235	0.73330	0.58641	0.84257	0.55278	0.72156	0.77036	0.84145	0.86611	0.80233	0.59398	0.59542	0.69911	0.81833	0.73410	0.62840	0.76831	0.68245	0.61597
5	0.95248	0.64179	0.67471	0.81548	1.00000	0.74744	0.54363	0.71863	0.63849	0.68905	0.86694	0.66889	0.53158	0.75491	0.45364	0.69556	0.61500	0.78448	0.71478	0.64691
6	0.60334	0.70786	0.74720	0.46926	0.74758	0.86699	0.88747	0.80335	0.67617	0.78792	0.86577	0.58748	0.30921	0.66828	0.51414	0.63012	0.95838	0.59560	0.77507	0.54295
7	0.83286	0.72987	0.71329	0.73225	0.72953	0.66787	0.56857	0.85201	0.75165	0.66357	0.45320	0.81654	0.56880	0.71290	0.56844	0.64810	0.59727	0.78235	0.78777	0.66858
8	0.61635	0.73851	0.65003	0.89954	0.75465	0.70522	0.59610	0.73995	0.62870	0.72643	0.70301	0.66314	0.48166	0.94655	0.81969	0.67905	0.87911	0.60588	0.80403	0.81998
9	0.53252	0.86838	0.65137	0.61750	0.89313	0.75643	0.54176	0.94152	0.53975	0.74767	0.52244	0.55731	0.52332	0.49462	0.80069	0.59533	0.78794	0.71586	0.79043	0.79777
10	0.65757	0.94877	0.65419	0.73191	0.74127	0.72080	0.83542	0.91628	0.55813	0.68075	0.76024	0.78386	0.52553	0.83137	0.78066	0.58906	0.78562	0.72457	0.91254	0.65437
11	0.89679	0.76991	0.63774	0.91959	0.84112	0.73935	0.80592	0.80648	0.76537	0.75977	0.42713	0.69673	0.39590	0.97365	0.81731	0.60099	0.61016	0.77062	0.88447	0.74578
12	0.76200	0.78394	0.86644	0.73200	0.73704	0.73743	0.69145	0.61306	0.75612	0.72989	0.97943	0.68129	0.52065	0.80568	0.55311	0.66908	0.86729	0.74205	0.73886	0.96876
13	0.72652	0.69334	0.66266	0.70165	0.76982	0.73463	0.63319	0.83694	0.79999	0.57477	0.65446	0.62556	0.64537	0.60946	0.73880	0.79692	0.77319	0.85847	0.69224	0.76839
14	0.79976	0.81617	0.61879	0.85402	0.71084	0.72988	0.67905	0.73568	0.77337	0.64394	0.59683	0.70535	0.36739	0.79227	0.67704	0.78721	0.64343	0.77192	0.75635	0.82730
15	0.55883	0.80397	0.77924	0.71583	0.71064	0.64106	0.75918	0.78494	0.48838	0.65519	0.64850	0.60386	0.49304	0.66724	0.77842	0.78540	0.81124	0.80202	0.71239	0.74884
16	0.67792	0.77788	0.64769	0.60556	0.73027	0.72743	0.62468	0.82506	0.59929	0.74658	0.49069	0.77585	0.52582	0.72726	0.54843	0.68043	0.65259	0.66470	0.67345	0.47218
17	0.65979	0.80717	0.63691	0.66617	0.71451	0.67921	0.66300	0.65078	0.85568	0.54923	0.61637	0.71325	0.67646	0.88316	0.54683	0.71765	0.72581	0.85729	0.81531	0.79391
18	0.73552	0.65507	0.59450	0.65271	0.51559	0.74159	0.85989	0.62866	0.76004	0.69799	0.65049	0.79563	0.47323	0.86001	0.53397	0.81862	0.66357	0.61546	0.64855	0.81863
19	0.61258	0.70833	0.66727	0.66381	0.65149	0.78344	0.61409	0.81001	0.63209	0.82270	0.80957	0.75631	0.43739	0.77923	0.63330	0.64335	0.63283	0.79970	1.00000	0.79371
20	1.00000	0.67199	0.74247	0.79790	0.64736	0.67289	0.91419	0.74648	0.58427	0.70523	0.81141	0.56237	0.62058	0.55950	0.75726	0.60754	0.65526	0.71896	0.81419	0.55087
21	0.73410	0.98941	0.69110	0.55730	0.88294	0.60432	0.75066	0.82405	0.44502	0.83248	0.70123	0.78243	0.38086	0.77916	0.65344	0.81391	0.79797	0.77101	0.82170	0.71585
22	1.00000	0.87279	0.63456	0.66652	0.93506	0.74898	0.87369	0.64040	0.95968	0.64856	0.67096	0.72535	0.49623	0.80503	0.89512	0.69383	0.80638	0.55432	0.64840	0.68570
23	0.59873	0.53008	0.62997	0.71729	0.83858	0.69778	0.78065	0.68869	0.66359	0.72142	0.72172	0.77154	0.59997	0.61290	0.78188	0.75619	0.75398	0.94747	0.84780	0.92763
24	0.82648	0.66021	0.74476	0.77479	0.87502	0.73872	0.87618	0.85112	0.73497	0.77394	0.48328	0.76956	0.83436	0.87235	0.56312	0.63921	0.76473	0.71841	0.62183	0.85035
25	0.63536	0.56035	0.73562	0.69955	0.59130	0.64479	0.69803	0.71215	0.83584	0.79142	0.84068	0.67405	0.72711	0.56252	0.65572	0.80455	0.80104	0.79150	0.69908	0.81075
26	0.76377	0.59116	0.78041	0.80844	0.60118	0.63341	0.60778	0.82749	0.78623	0.73197	0.65047	0.66378	0.44338	0.78655	0.76172	0.81715	1.00000	0.58778	0.82347	0.59481
27	0.62905	0.68372	0.83626	0.44188	0.67489	0.54726	0.85096	0.65940	0.53354	0.70705	0.46224	0.68351	0.37963	0.48651	0.65164	0.62361	0.61330	0.74018	0.76605	0.72661
28	0.93880	0.60529	0.65569	0.78815	0.75055	0.83128	0.66759	0.72190	0.85620	0.81807	0.86544	0.72478	0.63290	0.81515	0.82392	0.78853	0.68090	0.66760	0.67540	0.88294
29	0.61079	0.75864	0.74436	0.83704	0.84548	0.65735	0.64364	0.83049	0.61759	0.80536	0.69508	0.68389	0.45873	1.00000	0.77463	0.72308	0.74412	0.61475	0.75459	0.68872
30	0.82514	0.86249	0.74957	0.84417	0.73213	0.77866	0.90510	0.72168	0.75026	0.76718	1.00000	0.76647	0.39561	0.49090	0.79269	0.82178	0.65600	0.60129	0.63641	0.71656
$\bar{x}$	0.74070	0.72974	0.70007	0.72175	0.74915	0.70933	0.73053	0.76611	0.69976	0.72077	0.70342	0.70611	0.51828	0.73523	0.69737	0.70894	0.73674	0.72879	0.75755	0.74500
$\sigma$	0.01878	0.01357	0.00427	0.01427	0.01236	0.00502	0.01312	0.00680	0.01562	0.00641	0.02379	0.00570	0.01333	0.02038	0.01840	0.00621	0.01118	0.00897	0.00903	0.01378
$\sigma^2$	0.13704	0.11648	0.06533	0.11944	0.11116	0.07083	0.11454	0.08249	0.12500	0.08008	0.15425	0.07548	0.11545	0.14276	0.13565	0.07882	0.10574	0.09470	0.09504	0.11738



**Tabela 20 – Eficiências classificadas por grupo: Série SP&500**

Funções de Fitness																				
	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10	F11	F12	F13	F14	F15	F16	F17	F18	F19	F20
1	0.11164	0.16319	0.10447	0.09164	0.03659	0.09182	1.00000	0.06712	0.79737	0.09146	0.12369	0.04244	0.05021	0.10986	0.11800	0.02809	0.09462	0.06733	0.13804	0.11025
2	0.07067	0.02950	0.08883	0.14560	0.17027	0.03318	0.07350	0.04823	0.19768	0.06150	0.06247	0.07600	0.01867	0.08109	0.36533	0.02539	0.16159	0.04253	0.08405	0.23173
3	0.03429	0.02668	0.02748	0.08765	0.34029	0.02332	0.15932	0.06998	0.11893	0.15821	0.06982	0.02296	0.16071	0.08852	0.12062	0.02438	0.06341	0.19181	0.26412	0.10599
4	0.28634	0.03282	0.15490	0.12861	0.04244	0.03049	0.08674	0.02855	0.09936	0.11034	0.08103	0.02182	0.01498	0.10741	0.04415	0.05980	0.06562	0.35498	0.06838	0.07117
5	0.30385	0.12077	0.01577	0.28048	0.03914	0.07462	0.32868	0.18874	0.07299	0.05141	0.07316	0.02989	0.01395	0.11446	0.14732	0.01528	0.14429	0.08378	0.27587	0.21128
6	0.06147	0.01692	0.09268	0.30967	0.06113	0.27412	0.53934	0.05570	0.06237	0.14819	0.04381	0.11403	0.06497	0.08062	0.31118	0.02862	0.06159	0.12329	0.17917	0.17170
7	0.07324	0.05669	0.09353	0.06423	0.21520	0.05843	0.05341	0.16094	0.03767	0.10267	0.10140	0.02402	0.08315	0.26407	0.06346	0.06019	0.04241	0.11352	0.07474	0.02802
8	0.04210	0.08932	0.03166	0.05556	0.07944	0.06726	0.24367	0.54030	0.06868	0.09367	0.04901	0.05359	0.02356	0.10788	0.08960	0.04415	0.26627	0.20688	0.10157	0.09447
9	0.25344	0.02380	0.34671	0.08577	0.07303	0.07523	0.30415	0.53160	0.09207	0.02239	0.32232	0.03638	0.02261	0.05693	0.07891	0.01810	0.16601	0.04200	0.06070	0.20811
10	0.15275	0.01576	0.11287	0.09367	0.18824	0.02739	0.06853	0.19287	0.88244	0.23755	0.10350	0.04963	0.01392	0.16250	0.16159	0.08283	0.07959	0.02816	0.27355	0.10258
11	0.10323	0.03375	0.05283	0.10613	0.12900	0.04058	0.21134	0.04943	0.06639	0.04516	0.02637	0.01886	0.01758	0.11184	0.23605	0.02734	0.08241	0.04362	0.20666	0.04390
12	0.04568	0.00948	0.03026	0.12961	0.06277	0.02218	0.16002	0.09278	0.19422	0.38351	0.12966	0.14414	0.01453	0.23986	0.02787	0.05551	0.09381	0.02516	0.08537	0.04868
13	0.04394	0.03147	0.03712	0.17701	0.04468	0.10656	0.05722	0.18481	0.11301	0.26422	0.05563	0.02362	0.01573	0.02316	0.06312	0.03310	0.19530	0.03334	0.16730	0.05182
14	0.07298	0.01971	0.03868	0.20125	0.43981	0.33679	0.26946	0.06234	0.05518	0.63861	0.12120	0.04927	0.01361	0.14041	0.02294	0.03649	0.09886	0.09671	0.03645	0.24449
15	0.05707	0.04396	0.02286	0.13223	0.08182	0.01666	0.04427	0.05793	0.20743	0.07215	0.09808	0.12552	0.08608	0.06656	0.09799	0.24163	0.06891	0.34380	0.23404	0.06491
16	0.11377	0.15598	0.11637	0.08236	0.08077	0.02399	0.23497	0.05721	0.08444	0.09673	0.07664	0.05302	0.06775	0.05392	0.05578	0.08455	0.16589	0.07405	0.10235	0.20069
17	0.04439	0.02399	0.09336	0.06607	0.44867	0.02935	0.58906	0.22218	0.34781	0.05653	0.20124	0.01982	0.01270	0.40163	0.04696	0.03079	0.07303	0.26231	0.09446	0.08618
18	0.32010	0.04237	0.02173	0.07100	0.07768	0.03045	0.29244	0.19397	0.19949	0.19132	0.17514	0.09065	0.05748	0.13041	0.05203	0.13432	0.02516	0.03789	0.19262	0.04521
19	0.14587	0.11550	0.03080	0.51184	0.03712	0.01738	0.25503	0.05685	0.08459	0.06908	0.23191	0.25706	0.01213	0.24542	0.31616	0.01289	0.11685	0.11718	0.15878	0.05332
20	0.06048	0.03793	0.02781	0.12169	0.09835	0.02844	0.06618	0.13511	0.40823	0.07365	0.15363	0.02366	0.07750	0.64036	0.27328	0.02638	0.34385	0.60202	0.15053	0.11679
21	0.08647	0.01333	0.06517	0.05116	0.05988	0.03540	0.02810	0.18110	0.15698	0.12340	0.27583	0.05781	0.01059	0.06065	0.06341	0.40620	0.08318	0.35266	0.08464	0.12058
22	0.03579	0.02782	0.01514	0.13809	0.07619	0.07790	0.16862	0.03590	0.05258	0.22213	0.04842	0.02160	0.01933	0.18344	0.11407	0.01261	0.60780	0.22401	0.51292	0.14329
23	0.06507	0.02615	0.02705	0.04373	0.03922	0.04463	0.14475	0.10996	0.12236	0.12353	0.05029	0.02084	0.07396	0.15798	0.35441	0.05061	0.05810	0.11986	0.05510	0.15306
24	0.22492	0.03974	0.00993	0.67828	0.04779	0.09252	0.09910	0.15669	0.12972	0.04237	0.13639	0.06165	0.01123	0.07386	0.07352	0.02024	0.10252	0.23471	0.07379	0.09234
25	0.03671	0.07311	0.03349	0.16777	0.24480	0.02390	0.06692	0.13403	0.27423	0.10309	0.08363	0.02755	0.07857	0.06829	0.32900	0.10060	0.14235	0.09384	0.37721	0.40247
26	0.13823	0.03058	0.01565	0.20471	0.11075	0.01222	0.06703	0.15345	0.07349	0.55045	0.12937	0.01296	0.02221	0.37726	0.08849	0.11042	0.47820	0.01668	0.08385	0.05371
27	0.08164	0.02401	0.01978	0.12110	0.07166	0.02337	0.33758	0.11785	0.27380	0.08060	0.17643	0.02624	0.07046	0.12173	0.03584	0.05335	0.05362	0.27112	0.10296	0.19903
28	0.23713	0.02359	0.01488	0.04495	0.07501	0.07995	0.25127	0.17311	0.09843	0.06299	0.04579	0.22783	0.01723	0.27840	0.22927	0.02988	0.07733	0.11596	0.08060	0.07118
29	0.34053	0.05042	0.01655	0.15040	0.14072	0.14386	0.07239	0.22436	0.02417	0.23732	0.11502	0.02285	0.01150	0.09621	0.16395	0.02673	0.16850	0.05055	0.17106	0.11849
30	0.05929	0.14072	0.06937	0.54817	0.13614	0.07679	0.04728	0.20820	0.42507	0.06385	0.03923	0.01619	0.12981	0.55777	0.14037	0.07874	0.04234	0.19463	0.05519	0.17337
$\bar{x}$	0.12344	0.05130	0.06092	0.16968	0.12495	0.06729	0.21068	0.14971	0.19404	0.15260	0.11334	0.05906	0.04289	0.17342	0.01167	0.06531	0.14078	0.15215	0.15154	0.12729
$\sigma^2$	0.00918	0.00194	0.00440	0.02386	0.01242	0.00528	0.04220	0.01484	0.04208	0.02100	0.00519	0.00363	0.00151	0.02207	0.10801	0.00635	0.01696	0.01789	0.01139	0.00661
$\sigma$	0.09583	0.04402	0.06635	0.15446	0.11147	0.07264	0.20543	0.12184	0.20513	0.14491	0.07203	0.06027	0.03890	0.14857	0.10711	0.07970	0.13023	0.13374	0.10671	0.08128

**Tabela 21 – Eficiências classificadas por grupo: Série Produção de Leite**

	Funções de Fitness																			
	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10	F11	F12	F13	F14	F15	F16	F17	F18	F19	F20
1	0.73760	0.30391	0.47957	0.50349	0.70723	0.28593	0.53039	0.38419	0.54954	0.37258	0.23677	0.12883	0.15339	0.27428	0.46064	0.13716	0.43452	0.26513	0.21439	0.34759
2	0.64528	0.48234	0.27865	0.43381	0.74161	0.48026	0.57226	0.39740	0.54729	0.37577	0.25612	0.64701	0.16695	0.58568	0.26422	0.17709	0.73285	0.55773	0.30425	0.61224
3	0.71093	0.67326	0.27002	0.33608	0.31472	0.20978	0.35931	0.55845	0.49798	0.36558	0.37920	0.16587	0.20947	0.22112	0.23783	0.23203	0.28002	0.37481	0.45550	0.31412
4	0.60065	0.34661	0.39184	0.55429	0.51892	0.37813	0.32722	0.25767	0.77330	0.58539	0.80961	0.31117	0.19918	0.34712	0.22705	0.23167	0.22494	0.47327	0.56314	0.39595
5	0.69808	0.30225	0.25472	0.76747	0.57819	0.45289	0.45688	0.32626	0.58401	0.66892	0.41051	0.15453	0.23108	0.58169	0.23903	0.21047	0.24973	0.28159	0.31149	0.32330
6	0.55678	0.29454	0.24373	0.53128	0.39404	0.23560	0.41609	0.42598	0.40217	0.41344	0.17659	0.16591	0.20542	0.32448	0.24776	0.20751	0.21151	0.50151	0.25503	0.38288
7	0.76695	0.24397	0.21295	0.61350	0.63483	0.52663	0.38785	0.40522	0.40918	0.41586	0.29153	0.27691	0.26719	0.25912	0.29925	0.21170	0.44717	0.27060	0.26092	0.25904
8	0.42166	0.39864	0.28514	0.40902	0.48998	0.38865	0.54341	0.55423	0.69953	0.45213	0.26060	0.27214	0.23468	0.43639	0.47517	0.50317	0.58812	0.20213	0.58120	0.38881
9	0.35072	0.63475	0.52267	0.50905	0.42078	0.27996	0.60076	0.41672	0.78721	0.59864	0.25965	0.19517	0.27262	0.23329	0.26757	0.45263	0.33083	0.30381	0.27067	0.24986
10	0.38721	0.53290	0.41479	0.67070	0.58819	0.28213	0.37056	0.74453	0.69089	0.50536	0.39266	0.15124	0.15367	0.35466	0.29383	0.22496	0.40657	0.34223	0.41609	0.27111
11	0.31794	0.32764	0.78565	0.45867	0.50891	0.31494	0.28143	0.49647	0.56252	0.73907	0.34517	0.14096	0.16362	0.67063	0.25679	0.15201	0.39874	0.28237	0.28085	0.36623
12	0.40585	0.35617	0.47901	0.58159	0.37012	0.24696	0.87395	0.35215	0.67693	0.47845	0.21318	0.19678	0.18950	0.66879	0.24474	0.14589	0.87162	0.42267	0.25106	0.60915
13	0.37870	0.30083	0.60238	0.64725	0.53706	0.27233	0.79472	0.64905	0.75708	0.40676	0.25826	0.17731	0.14946	0.71090	0.27675	0.16351	0.51002	0.23373	0.71066	0.40959
14	0.74357	0.33746	0.64481	0.27487	0.30990	0.31196	0.45120	0.31896	0.58295	0.50878	0.34231	0.16639	0.21490	0.50496	0.42117	0.14011	0.61620	0.83740	0.40798	0.28125
15	0.43105	0.41595	0.37799	0.46945	0.42767	0.25243	0.85950	0.68244	0.68216	0.79939	0.41260	0.18450	0.20321	0.38249	0.26429	0.21838	0.27074	0.33612	0.52685	0.46073
16	0.78740	0.45006	0.31649	0.52029	0.58203	0.62823	0.51983	0.40968	0.39972	0.51674	0.31409	0.19674	0.17329	0.61599	0.33935	0.17964	0.48717	0.51491	0.35855	0.32090
17	0.56518	0.50343	0.68075	0.62283	0.26694	0.30960	0.38379	0.43465	0.35693	0.50825	0.31062	0.33771	0.21961	0.49608	0.28645	0.15766	0.38545	0.28656	0.28576	0.47379
18	0.46200	0.34729	0.72834	0.44307	0.73998	0.33953	0.61108	0.31406	0.30080	0.68381	0.52916	0.15239	0.24519	0.30675	0.45308	0.25657	0.30069	0.54497	0.45864	0.31711
19	0.31520	0.61378	0.75569	0.36012	0.30464	0.31895	0.39742	0.24350	0.59350	0.54288	0.32291	0.14971	0.30091	0.41800	0.42788	0.15802	0.25965	0.67561	0.34622	0.28824
20	0.36809	0.54222	0.25258	0.37252	0.74956	0.22392	0.52503	0.55113	0.49210	0.63983	0.31510	0.24722	0.16186	0.33109	0.83955	0.56638	0.34586	0.22008	0.73690	0.58744
21	0.31827	0.49378	0.26093	0.70087	0.43814	0.56703	0.43009	0.42349	0.33448	0.53893	0.27880	0.18761	0.25829	0.49739	0.54536	0.25211	0.32896	0.46008	0.68295	0.96609
22	0.40808	0.48678	0.73205	0.50725	0.31538	0.24694	0.66990	0.47422	0.43034	0.92248	0.26038	0.17244	0.23853	0.31253	0.52923	0.23297	0.39269	0.63216	0.50103	0.25667
23	0.30204	0.33102	0.19948	0.66395	0.56334	0.33398	0.64991	0.65224	0.52044	0.68445	0.39513	0.23480	0.15696	0.43044	0.29161	0.17614	0.23888	0.27404	0.33123	0.29280
24	0.45880	0.33071	0.44347	0.43701	0.41602	0.32842	0.75017	0.41387	0.62244	0.55122	0.29107	0.17764	0.15785	0.33931	0.24595	0.21757	0.41313	0.30608	0.62934	0.69088
25	0.45923	0.53679	0.34773	0.45130	0.68767	0.37151	0.39023	0.67234	0.28902	0.46360	0.24945	0.20631	0.20945	0.43955	0.41826	0.67124	0.26251	0.44620	0.42620	0.45592
26	0.43067	0.44365	0.33378	0.53124	0.50428	0.29018	0.93083	0.40846	0.63708	0.77455	0.26870	0.15211	0.34190	0.52116	0.31046	0.13524	0.26394	0.33814	0.22418	0.49937
27	0.33270	0.43328	0.38480	0.70709	0.58067	0.56162	1.00000	0.57609	0.38211	0.46279	0.27105	0.18798	0.27881	0.29580	0.22240	0.24369	0.32301	0.30406	0.28249	0.61878
28	0.25559	0.34577	0.72219	0.79408	0.74399	0.29350	0.46036	0.34107	0.46172	0.80943	0.30690	0.17964	0.18389	0.25466	0.38877	0.17845	0.31654	0.43278	0.39618	0.52648
29	0.44762	0.23875	0.33361	0.40462	0.64001	0.30520	0.61145	0.69337	0.49131	0.33720	0.22813	0.15982	0.19482	0.27366	0.54401	0.15816	0.25149	1.00000	0.61874	0.53915
30	0.44538	0.65133	0.23129	0.41932	0.50050	0.16709	0.47222	0.41305	0.78447	0.48047	0.28122	0.18286	0.22306	0.38498	0.45608	0.13943	0.26263	0.25563	0.38719	0.63752
$\bar{x}$	0.48364	0.42333	0.43224	0.52320	0.51918	0.34014	0.55426	0.46636	0.54331	0.55342	0.32225	0.20866	0.21196	0.41577	0.35915	0.23772	0.38021	0.41255	0.41586	0.43810
$\sigma^2$	0.02489	0.01510	0.03551	0.01713	0.02149	0.01294	0.03595	0.01873	0.02188	0.02260	0.01368	0.00937	0.00234	0.01988	0.01901	0.01762	0.02436	0.03480	0.02374	0.02744
$\sigma$	0.15778	0.12287	0.18844	0.13088	0.14660	0.11376	0.18960	0.13686	0.14791	0.15034	0.11697	0.09680	0.04841	0.14101	0.13787	0.13276	0.15609	0.18655	0.15408	0.16564

**Tabela 22 – Eficiências e estimativas para o caso geral**

	Série Sunspot					Série SP&500					Série Produção de Leite				
	(DMUs)	Eficiência	Estimativa <sup>a</sup>	I.C. <sup>b</sup>		(DMUs)	Eficiência	Estimativa <sup>a</sup>	I.C. <sup>b</sup>		(DMUs)	Eficiência	Estimativa <sup>a</sup>	I.C. <sup>b</sup>	
				L.Inf.	L.Sup.				L.Inf.	L.Sup.				L.Inf.	L.Sup.
1	F1rep22	1	0.9279	0.888	0.9695	F7rep1	1	0.6263	0.5607	0.7512	F7rep27	1	0.6315	0.5415	0.8826
2	F1rep20	1	0.8389	0.7554	0.9736	F9rep10	0.8825	0.5992	0.5153	0.773	F18rep29	1	0.6576	0.578	0.9008
3	F5rep5	1	0.8087	0.7468	0.9612	F9rep1	0.7974	0.565	0.4761	0.7475	F20rep21	0.9661	0.7858	0.7011	0.9232
4	F11rep30	1	0.8011	0.7309	0.9657	F17rep22	0.6886	0.4944	0.4125	0.6779	F7rep26	0.9308	0.7464	0.6638	0.8826
5	F14rep29	1	0.8836	0.8263	0.9718	F4rep24	0.6783	0.4796	0.4047	0.6366	F10rep22	0.9225	0.7249	0.6501	0.8733
6	F15rep2	1	0.9643	0.9245	0.9908	F14rep20	0.6404	0.4707	0.3905	0.6137	F7rep12	0.874	0.7212	0.6404	0.8443
7	F17rep26	1	0.8591	0.8059	0.9599	F10rep14	0.6386	0.4628	0.3865	0.6057	F17rep12	0.8717	0.7545	0.6659	0.8587
8	F19rep19	1	0.7793	0.6491	0.9568	F18rep20	0.602	0.47	0.3662	0.5868	F7rep15	0.8595	0.7777	0.6903	0.8548
9	F2rep21	0.9894	0.8763	0.8189	0.9653	F7rep17	0.5891	0.4392	0.3637	0.571	F15rep20	0.8396	0.8092	0.7546	0.8381
10	F11rep12	0.9794	0.8349	0.7559	0.9591	F14rep30	0.5578	0.4461	0.2973	0.5465	F18rep14	0.8375	0.5973	0.5046	0.781
11	F14rep11	0.9737	0.8845	0.829	0.9493	F10rep26	0.5504	0.4129	0.3409	0.5339	F11rep4	0.8097	0.6723	0.5971	0.7849
12	F20rep12	0.9688	0.8431	0.7822	0.9399	F4rep30	0.5482	0.3786	0.3227	0.4957	F10rep28	0.8095	0.6833	0.6023	0.7927
13	F10rep22	0.9597	0.9213	0.8784	0.9542	F8rep8	0.5403	0.3789	0.3199	0.4987	F10rep15	0.7994	0.7716	0.7227	0.798
14	F17rep6	0.9584	0.8685	0.8141	0.939	F7rep6	0.5393	0.3835	0.3216	0.5081	F7rep13	0.7947	0.7359	0.6653	0.7906
15	F1rep3	0.9534	0.8463	0.7898	0.9228	F8rep9	0.5316	0.3766	0.3169	0.4974	F4rep28	0.7941	0.714	0.6363	0.7881
16	F1rep5	0.9526	0.8873	0.8358	0.937	F19rep22	0.5129	0.3736	0.3082	0.4891	F1rep16	0.7874	0.6854	0.6043	0.778
17	F2rep10	0.9488	0.7991	0.7186	0.9286	F4rep19	0.5118	0.377	0.3134	0.4918	F10rep9	0.7872	0.7099	0.6323	0.7817
18	F18rep23	0.9475	0.9087	0.8653	0.9396	F17rep26	0.4782	0.3389	0.2841	0.4481	F3rep11	0.7857	0.7226	0.6517	0.781
19	F14rep8	0.9466	0.8398	0.7774	0.9306	F5rep17	0.4487	0.352	0.2888	0.4378	F10rep30	0.7845	0.7522	0.698	0.7828
20	F8rep9	0.9415	0.9047	0.8718	0.9302	F5rep14	0.4398	0.3384	0.2786	0.4273	F10rep26	0.7746	0.6939	0.6152	0.7696
21	F1rep28	0.9389	0.907	0.8706	0.9311	F9rep30	0.4251	0.2988	0.2513	0.3934	F10rep4	0.7733	0.6385	0.5666	0.7467
22	F5rep22	0.9351	0.8215	0.7591	0.9093	F9rep20	0.4082	0.314	0.2192	0.3973	F4rep5	0.7675	0.7495	0.7155	0.7668
23	F20rep23	0.9276	0.8937	0.863	0.9223	F16rep21	0.4062	0.313	0.2119	0.3959	F1rep7	0.767	0.6479	0.5715	0.7541
24	F4rep11	0.9196	0.8907	0.8566	0.9152	F20rep25	0.4025	0.2977	0.2349	0.3892	F10rep13	0.7571	0.7101	0.6468	0.7547
25	F8rep10	0.9163	0.8682	0.8159	0.9093	F14rep17	0.4016	0.3213	0.21	0.3942	F3rep19	0.7557	0.6821	0.6077	0.7512
26	F4rep1	0.9152	0.8095	0.7553	0.888	F10rep12	0.3835	0.2979	0.2047	0.3738	F7rep24	0.7502	0.6852	0.6144	0.7463
27	F7rep20	0.9142	0.8828	0.8509	0.9068	F14rep26	0.3773	0.2689	0.2241	0.3556	F5rep20	0.7496	0.6962	0.6312	0.7464
28	F19rep10	0.9126	0.7934	0.7392	0.8757	F19rep25	0.3772	0.2785	0.2066	0.3642	F8rep10	0.7445	0.6942	0.6315	0.7411
29	F7rep30	0.9051	0.8237	0.7728	0.8919	F15rep3	0.3653	0.3077	0.2089	0.3627	F5rep28	0.744	0.6838	0.616	0.7398
30	F4rep8	0.8996	0.8463	0.804	0.8849	F18rep4	0.355	0.2715	0.1853	0.3453	F1rep14	0.7436	0.6131	0.5451	0.7172
31	F1rep11	0.8969	0.8786	0.855	0.8951	F15rep24	0.3544	0.2924	0.1959	0.3503	F5rep2	0.7416	0.7292	0.7048	0.7413
32	F15rep22	0.8952	0.8784	0.8547	0.8937	F18rep21	0.3527	0.2633	0.1825	0.3423	F5rep18	0.74	0.6693	0.601	0.7336
33	F5rep9	0.8932	0.8347	0.7824	0.8838	F9rep17	0.3478	0.2832	0.1882	0.3433	F10rep11	0.7391	0.6911	0.6284	0.7364
34	F19rep3	0.8906	0.7887	0.7298	0.8657	F3rep9	0.3467	0.3003	0.2517	0.3434	F1rep1	0.7376	0.6406	0.5653	0.7297

35	<i>F7rep6</i>	0.8875	0.8611	0.8263	0.8837	<i>F17rep20</i>	0.3439	0.2673	0.1802	0.3365	<i>F19rep20</i>	0.7369	0.6313	0.5569	0.7282
36	<i>F19rep11</i>	0.8845	0.8605	0.8305	0.8806	<i>F18rep15</i>	0.3438	0.2704	0.1812	0.3372	<i>F17rep2</i>	0.7329	0.6558	0.587	0.725
37	<i>F14rep17</i>	0.8832	0.8389	0.7985	0.8712	<i>F1rep29</i>	0.3405	0.285	0.2367	0.3355	<i>F3rep22</i>	0.7321	0.7106	0.6701	0.7312
38	<i>F5rep21</i>	0.883	0.8492	0.8161	0.8759	<i>F5rep3</i>	0.3403	0.3034	0.2556	0.3386	<i>F3rep18</i>	0.7284	0.6229	0.55	0.7158
39	<i>F20rep28</i>	0.883	0.8364	0.7992	0.871	<i>F7rep27</i>	0.3376	0.2673	0.1832	0.3309	<i>F3rep28</i>	0.7222	0.6848	0.6283	0.7202
40	<i>F17rep8</i>	0.8791	0.8532	0.8191	0.8756	<i>F6rep14</i>	0.3368	0.2746	0.2233	0.3303	<i>F1rep3</i>	0.7109	0.68	0.6357	0.7089
41	<i>F7rep24</i>	0.8762	0.8371	0.8025	0.8637	<i>F15rep26</i>	0.329	0.2505	0.1704	0.32	<i>F14rep13</i>	0.7109	0.6012	0.5296	0.6974
42	<i>F5rep24</i>	0.875	0.84	0.801	0.867	<i>F7rep5</i>	0.3287	0.2785	0.1939	0.326	<i>F19rep13</i>	0.7107	0.5767	0.5158	0.6824
43	<i>F7rep22</i>	0.8737	0.8235	0.7833	0.8596	<i>F11rep9</i>	0.3223	0.2758	0.1915	0.3207	<i>F5rep1</i>	0.7073	0.5788	0.5129	0.6812
44	<i>F20rep2</i>	0.8734	0.8386	0.8044	0.8661	<i>F1rep18</i>	0.3201	0.2544	0.2082	0.3131	<i>F4rep27</i>	0.7071	0.6653	0.6059	0.7049
45	<i>F2rep22</i>	0.8728	0.8471	0.8223	0.8671	<i>F15rep20</i>	0.3162	0.2657	0.1779	0.3139	<i>F4rep21</i>	0.7009	0.6566	0.6028	0.6963
46	<i>F14rep24</i>	0.8724	0.8588	0.8403	0.8717	<i>F15rep7</i>	0.3112	0.2728	0.1965	0.3104	<i>F10rep8</i>	0.6995	0.6743	0.6287	0.6983
47	<i>F11rep1</i>	0.8715	0.8546	0.8315	0.8699	<i>F4rep6</i>	0.3097	0.264	0.2157	0.306	<i>F1rep5</i>	0.6981	0.6747	0.633	0.697
48	<i>F2rep9</i>	0.8684	0.7668	0.7148	0.8406	<i>F7rep9</i>	0.3042	0.2401	0.1639	0.2977	<i>F8rep29</i>	0.6934	0.6798	0.6525	0.693
49	<i>F17rep12</i>	0.8673	0.8254	0.7753	0.8617	<i>F1rep5</i>	0.3038	0.258	0.2151	0.2997	<i>F10rep10</i>	0.6909	0.6514	0.5998	0.6881
50	<i>F6rep6</i>	0.867	0.8535	0.833	0.8662	<i>F7rep18</i>	0.2924	0.2287	0.157	0.2861	<i>F20rep24</i>	0.6909	0.6387	0.5831	0.6862
51	<i>F11rep5</i>	0.867	0.8414	0.8127	0.8624	<i>F1rep4</i>	0.2863	0.2583	0.2216	0.285	<i>F5rep25</i>	0.6877	0.6682	0.6312	0.687
52	<i>F3rep12</i>	0.8665	0.8428	0.8126	0.8629	<i>F4rep5</i>	0.2805	0.2335	0.1911	0.276	<i>F10rep23</i>	0.6845	0.6547	0.6062	0.6829
53	<i>F10rep4</i>	0.8662	0.8247	0.7924	0.8577	<i>F14rep28</i>	0.2784	0.2438	0.1732	0.2777	<i>F10rep18</i>	0.6839	0.6483	0.5934	0.6822
54	<i>F11rep6</i>	0.8658	0.8296	0.8007	0.8584	<i>F19rep5</i>	0.2759	0.2188	0.1484	0.2716	<i>F19rep21</i>	0.683	0.6625	0.6253	0.682
55	<i>F11rep28</i>	0.8655	0.8555	0.8374	0.865	<i>F11rep21</i>	0.2758	0.215	0.1468	0.2699	<i>F8rep15</i>	0.6825	0.6526	0.6058	0.6807
56	<i>F2rep30</i>	0.8625	0.809	0.7634	0.8498	<i>F9rep25</i>	0.2742	0.2132	0.1458	0.2678	<i>F10rep15</i>	0.6822	0.6547	0.6081	0.6809
57	<i>F20rep3</i>	0.8612	0.8445	0.8218	0.8588	<i>F6rep6</i>	0.2741	0.2242	0.1825	0.269	<i>F3rep17</i>	0.6808	0.6257	0.5597	0.6775
58	<i>F14rep18</i>	0.8601	0.8401	0.8154	0.8571	<i>F9rep27</i>	0.2738	0.2426	0.1817	0.2731	<i>F10rep12</i>	0.677	0.6456	0.6028	0.6746
59	<i>F7rep18</i>	0.8599	0.8497	0.8317	0.8593	<i>F19rep10</i>	0.2735	0.2133	0.1449	0.2678	<i>F18rep19</i>	0.6756	0.6188	0.5532	0.672
60	<i>F18rep13</i>	0.8585	0.834	0.8031	0.855	<i>F15rep21</i>	0.2733	0.2437	0.1836	0.2727	<i>F2rep3</i>	0.6733	0.6568	0.6273	0.6724
61	<i>F18rep17</i>	0.8573	0.8393	0.8189	0.8562	<i>F18rep27</i>	0.2711	0.2235	0.1536	0.2682	<i>F8rep25</i>	0.6724	0.6088	0.5436	0.6682
62	<i>F10rep28</i>	0.8562	0.8403	0.8182	0.8542	<i>F7rep14</i>	0.2695	0.2205	0.1549	0.2659	<i>F16rep25</i>	0.6713	0.572	0.5016	0.6605
63	<i>F10rep17</i>	0.8557	0.8374	0.8127	0.8533	<i>F17rep8</i>	0.2663	0.2141	0.1442	0.2624	<i>F4rep10</i>	0.6707	0.6213	0.5664	0.6663
64	<i>F4rep14</i>	0.854	0.8343	0.8106	0.8507	<i>F10rep13</i>	0.2642	0.2135	0.1468	0.2603	<i>F14rep11</i>	0.6706	0.6137	0.5474	0.6673
65	<i>F8rep7</i>	0.8521	0.7575	0.7094	0.8343	<i>F19rep3</i>	0.2641	0.2428	0.1901	0.3045	<i>F7rep22</i>	0.6699	0.6476	0.6132	0.6684
66	<i>F8rep24</i>	0.8511	0.845	0.8309	0.8509	<i>F14rep7</i>	0.2641	0.2376	0.1784	0.2638	<i>F10rep5</i>	0.6689	0.6159	0.5523	0.6657
67	<i>F7rep27</i>	0.851	0.7978	0.7526	0.8413	<i>F18rep17</i>	0.2623	0.2273	0.1614	0.2616	<i>F14rep12</i>	0.6688	0.6039	0.5388	0.6643
68	<i>F20rep24</i>	0.8504	0.8161	0.788	0.8434	<i>F12rep19</i>	0.2571	0.2139	0.146	0.2543	<i>F4rep23</i>	0.664	0.5994	0.5316	0.66
69	<i>F19rep23</i>	0.8478	0.8297	0.8058	0.8456	<i>F7rep19</i>	0.255	0.2109	0.1458	0.252	<i>F8rep23</i>	0.6523	0.6308	0.5912	0.6513
70	<i>F5rep29</i>	0.8455	0.73	0.6789	0.8106	<i>F1rep9</i>	0.2534	0.2209	0.1858	0.2515	<i>F2rep30</i>	0.6513	0.4547	0.3999	0.5917
71	<i>F4rep30</i>	0.8442	0.8185	0.7857	0.8409	<i>F7rep28</i>	0.2513	0.1994	0.1375	0.2462	<i>F7rep23</i>	0.6499	0.6258	0.589	0.6483
72	<i>F2rep2</i>	0.8426	0.8167	0.7862	0.8368	<i>F14rep19</i>	0.2454	0.204	0.1423	0.2428	<i>F8rep13</i>	0.6491	0.634	0.6087	0.6482
73	<i>F5rep4</i>	0.8426	0.8172	0.791	0.8394	<i>F5rep25</i>	0.2448	0.2009	0.1634	0.2406	<i>F4rep13</i>	0.6472	0.6335	0.6071	0.6467

74	<i>F10rep4</i>	0.8415	0.817	0.7885	0.8379	<i>F20rep14</i>	0.2445	0.2064	0.1455	0.2428	<i>F12rep2</i>	0.647	0.6247	0.5841	0.646
75	<i>F5rep11</i>	0.8412	0.7895	0.7491	0.8296	<i>F7rep8</i>	0.2437	0.2167	0.1678	0.243	<i>F1rep2</i>	0.6453	0.6259	0.5901	0.6445
76	<i>F11rep25</i>	0.8407	0.7937	0.7527	0.8297	<i>F16rep15</i>	0.2416	0.2092	0.1524	0.2408	<i>F3rep14</i>	0.6448	0.6295	0.5997	0.6442
77	<i>F5rep23</i>	0.8386	0.8095	0.7746	0.8339	<i>F14rep12</i>	0.2399	0.1969	0.1355	0.2371	<i>F5rep29</i>	0.64	0.5858	0.52	0.6364
78	<i>F4rep29</i>	0.8371	0.7374	0.6823	0.8241	<i>F10rep10</i>	0.2376	0.2125	0.1602	0.237	<i>F10rep20</i>	0.6398	0.6212	0.5898	0.6387
79	<i>F8rep13</i>	0.837	0.8077	0.7834	0.8296	<i>F10rep29</i>	0.2373	0.1881	0.1288	0.2327	<i>F20rep30</i>	0.6376	0.6208	0.59	0.6367
80	<i>F3rep27</i>	0.8363	0.8305	0.8166	0.8362	<i>F1rep28</i>	0.2371	0.2044	0.171	0.2345	<i>F10rep26</i>	0.6371	0.5454	0.481	0.6295
81	<i>F10rep25</i>	0.8358	0.7925	0.7484	0.8256	<i>F15rep12</i>	0.2361	0.2	0.138	0.2347	<i>F5rep7</i>	0.6348	0.5759	0.5201	0.6291
82	<i>F7rep10</i>	0.8354	0.8236	0.8046	0.8348	<i>F7rep16</i>	0.235	0.2125	0.1706	0.2345	<i>F2rep9</i>	0.6348	0.6183	0.5858	0.6342
83	<i>F13rep24</i>	0.8344	0.788	0.7393	0.8268	<i>F18rep24</i>	0.2347	0.1965	0.1372	0.2327	<i>F18rep22</i>	0.6322	0.6027	0.5627	0.6296
84	<i>F1rep7</i>	0.8329	0.8015	0.7725	0.8248	<i>F19rep15</i>	0.234	0.1964	0.1378	0.2322	<i>F19rep24</i>	0.6294	0.5983	0.5498	0.6278
85	<i>F10rep21</i>	0.8325	0.8087	0.784	0.8296	<i>F11rep19</i>	0.2319	0.2119	0.1699	0.2323	<i>F6rep16</i>	0.6283	0.6107	0.584	0.6271
86	<i>F14rep10</i>	0.8314	0.8045	0.7777	0.8282	<i>F20rep2</i>	0.2317	0.1925	0.1337	0.2293	<i>F4rep17</i>	0.6229	0.6074	0.5817	0.6219
87	<i>F6rep28</i>	0.8313	0.8117	0.787	0.8282	<i>F15rep29</i>	0.2293	0.2006	0.1482	0.2287	<i>F10rep24</i>	0.6225	0.5935	0.5489	0.6207
88	<i>F8rep29</i>	0.8305	0.803	0.764	0.8263	<i>F12rep28</i>	0.2278	0.1949	0.1403	0.2267	<i>F20rep27</i>	0.6188	0.5719	0.5199	0.6148
89	<i>F10rep2</i>	0.8282	0.8053	0.7804	0.825	<i>F1rep24</i>	0.2249	0.1988	0.1683	0.2237	<i>F19rep29</i>	0.6188	0.5827	0.5325	0.6168
90	<i>F8rep26</i>	0.8275	0.7943	0.7564	0.821	<i>F8rep29</i>	0.2244	0.1977	0.1477	0.2237	<i>F17rep14</i>	0.6162	0.5839	0.5418	0.6132
91	<i>F20rep14</i>	0.8273	0.7867	0.756	0.8167	<i>F18rep22</i>	0.224	0.2026	0.1546	0.2299	<i>F14rep16</i>	0.616	0.5905	0.5549	0.6143
92	<i>F18rep3</i>	0.8269	0.8154	0.7979	0.8264	<i>F8rep17</i>	0.2222	0.1835	0.1299	0.2196	<i>F2rep19</i>	0.6138	0.5755	0.5252	0.6116
93	<i>F1rep24</i>	0.8265	0.781	0.7327	0.8195	<i>F10rep22</i>	0.2221	0.1882	0.1348	0.2205	<i>F4rep7</i>	0.6135	0.5858	0.5425	0.6119
94	<i>F1rep30</i>	0.8252	0.7878	0.7587	0.8153	<i>F5rep7</i>	0.2152	0.1942	0.1652	0.2143	<i>F20rep2</i>	0.6123	0.5975	0.5683	0.6118
95	<i>F8rep16</i>	0.8251	0.7822	0.7516	0.8135	<i>F7rep11</i>	0.2113	0.1808	0.1334	0.2098	<i>F7rep29</i>	0.6115	0.5831	0.5393	0.6097
96	<i>F8rep21</i>	0.8241	0.7822	0.7418	0.8164	<i>F20rep5</i>	0.2113	0.1952	0.1536	0.2526	<i>F7rep18</i>	0.6111	0.5833	0.5384	0.6097
97	<i>F15rep28</i>	0.8239	0.8064	0.7868	0.8228	<i>F8rep30</i>	0.2082	0.1899	0.1562	0.2081	<i>F20rep12</i>	0.6092	0.5874	0.5519	0.6078
98	<i>F19rep26</i>	0.8235	0.7844	0.7365	0.8188	<i>F20rep9</i>	0.2081	0.1852	0.1385	0.2079	<i>F3rep13</i>	0.6024	0.5738	0.5354	0.5997
99	<i>F7rep2</i>	0.823	0.7353	0.6757	0.8133	<i>F9rep15</i>	0.2074	0.1969	0.1648	0.3022	<i>F7rep9</i>	0.6008	0.569	0.5214	0.5991
100	<i>F10rep19</i>	0.8227	0.8158	0.8009	0.8224	<i>F18rep8</i>	0.2069	0.1809	0.1329	0.2064	<i>F1rep4</i>	0.6007	0.5887	0.5647	0.6003
101	<i>F16rep30</i>	0.8218	0.7994	0.7757	0.82	<i>F19rep11</i>	0.2067	0.1845	0.1376	0.2065	<i>F10rep9</i>	0.5987	0.5672	0.5211	0.5969
102	<i>F19rep21</i>	0.8218	0.7455	0.6955	0.8069	<i>F4rep26</i>	0.2047	0.1885	0.1632	0.2042	<i>F10rep19</i>	0.5935	0.5761	0.5468	0.5925
103	<i>F20rep8</i>	0.82	0.8068	0.7871	0.8191	<i>F4rep14</i>	0.2013	0.1871	0.164	0.2009	<i>F5rep10</i>	0.5882	0.5711	0.5423	0.5872
104	<i>F15rep8</i>	0.8197	0.8012	0.7789	0.8179	<i>F11rep17</i>	0.2012	0.1739	0.1276	0.2004	<i>F17rep8</i>	0.5881	0.5532	0.5045	0.5863
105	<i>F16rep18</i>	0.8187	0.7887	0.7542	0.8114	<i>F20rep16</i>	0.2007	0.195	0.1626	0.464	<i>F20rep20</i>	0.5875	0.5522	0.5035	0.5856
106	<i>F20rep18</i>	0.8187	0.7978	0.7726	0.8149	<i>F9rep18</i>	0.1995	0.1699	0.1241	0.198	<i>F14rep2</i>	0.5857	0.5736	0.5504	0.5852
107	<i>F15rep4</i>	0.8184	0.7815	0.7514	0.8116	<i>F20rep27</i>	0.199	0.1714	0.1243	0.1982	<i>F10rep4</i>	0.5854	0.5739	0.5512	0.585
108	<i>F10rep28</i>	0.8181	0.804	0.7829	0.817	<i>F9rep2</i>	0.1977	0.1759	0.1346	0.1972	<i>F10rep5</i>	0.584	0.567	0.5405	0.5827
109	<i>F8rep1</i>	0.8177	0.786	0.7575	0.812	<i>F17rep13</i>	0.1953	0.1843	0.1515	0.2931	<i>F10rep14</i>	0.583	0.5618	0.5251	0.5819
110	<i>F15rep11</i>	0.8173	0.7643	0.7233	0.7995	<i>F18rep30</i>	0.1946	0.1716	0.1277	0.1942	<i>F5rep16</i>	0.582	0.5534	0.5086	0.5806
111	<i>F16rep26</i>	0.8172	0.8095	0.7945	0.8169	<i>F9rep12</i>	0.1942	0.1648	0.118	0.1928	<i>F14rep5</i>	0.5817	0.5702	0.5466	0.5814
112	<i>F12rep7</i>	0.8166	0.7787	0.7481	0.8094	<i>F8rep18</i>	0.194	0.1819	0.1516	0.2409	<i>F4rep12</i>	0.5816	0.5588	0.5259	0.5801

113	<i>F2rep14</i>	0.8162	0.7443	0.6978	0.8	<i>F8rep10</i>	0.1929	0.1714	0.1343	0.1924	<i>F19rep8</i>	0.5812	0.5667	0.5432	0.5803
114	<i>F4rep5</i>	0.8155	0.7317	0.6814	0.8036	<i>F19rep18</i>	0.1926	0.1612	0.1135	0.1908	<i>F5rep27</i>	0.5807	0.5513	0.5053	0.5792
115	<i>F19rep17</i>	0.8153	0.8045	0.7864	0.8147	<i>F18rep3</i>	0.1918	0.1677	0.1234	0.1914	<i>F5rep5</i>	0.5782	0.5682	0.5488	0.5779
116	<i>F14rep28</i>	0.8152	0.8045	0.787	0.8148	<i>F10rep18</i>	0.1913	0.1612	0.1148	0.1896	<i>F8rep27</i>	0.5761	0.5654	0.5442	0.5758
117	<i>F19rep20</i>	0.8142	0.7947	0.7721	0.8121	<i>F8rep5</i>	0.1887	0.1763	0.1468	0.2254	<i>F7rep2</i>	0.5723	0.4572	0.392	0.5497
118	<i>F16rep21</i>	0.8139	0.7653	0.7177	0.8068	<i>F5rep10</i>	0.1882	0.1692	0.1433	0.1874	<i>F6rep21</i>	0.5671	0.5495	0.5177	0.5663
119	<i>F11rep20</i>	0.8114	0.7706	0.7243	0.8057	<i>F8rep13</i>	0.1848	0.1742	0.1462	0.2453	<i>F16rep20</i>	0.5664	0.4015	0.347	0.532
120	<i>F17rep15</i>	0.8113	0.7738	0.7411	0.8035	<i>F14rep22</i>	0.1834	0.1634	0.1246	0.1831	<i>F1rep17</i>	0.5652	0.5517	0.5294	0.5644
121	<i>F20rep25</i>	0.8108	0.8015	0.784	0.8103	<i>F8rep21</i>	0.1811	0.1577	0.1187	0.1804	<i>F5rep23</i>	0.5633	0.5077	0.4574	0.5575
122	<i>F8rep19</i>	0.81	0.8001	0.7819	0.8095	<i>F19rep6</i>	0.1792	0.1732	0.1442	0.3762	<i>F19rep4</i>	0.5632	0.5531	0.5343	0.5629
123	<i>F11rep19</i>	0.8096	0.785	0.7547	0.806	<i>F4rep13</i>	0.177	0.1533	0.1275	0.1756	<i>F10rep11</i>	0.5625	0.5105	0.4614	0.5571
124	<i>F4rep26</i>	0.8085	0.7902	0.7703	0.8073	<i>F11rep27</i>	0.1764	0.1555	0.1184	0.176	<i>F6rep27</i>	0.5616	0.5526	0.5349	0.5614
125	<i>F2rep17</i>	0.8072	0.7921	0.7712	0.8063	<i>F11rep18</i>	0.1751	0.1622	0.133	0.1974	<i>F8rep3</i>	0.5585	0.549	0.5317	0.558
126	<i>F8rep11</i>	0.8065	0.8005	0.787	0.8063	<i>F20rep30</i>	0.1734	0.1561	0.1193	0.1733	<i>F18rep2</i>	0.5578	0.5333	0.4993	0.5557
127	<i>F17rep22</i>	0.8064	0.7205	0.6708	0.7814	<i>F8rep28</i>	0.1731	0.161	0.1342	0.2012	<i>F1rep6</i>	0.5568	0.5263	0.4806	0.5551
128	<i>F7rep11</i>	0.8059	0.7888	0.7671	0.8041	<i>F20rep6</i>	0.1717	0.1577	0.1258	0.2011	<i>F4rep4</i>	0.5543	0.5255	0.4812	0.5528
129	<i>F14rep12</i>	0.8057	0.7141	0.6615	0.7882	<i>F19rep29</i>	0.1711	0.1639	0.1359	0.3163	<i>F8rep8</i>	0.5542	0.5458	0.5292	0.554
130	<i>F10rep29</i>	0.8054	0.7964	0.7813	0.805	<i>F5rep2</i>	0.1703	0.159	0.1395	0.17	<i>F10rep24</i>	0.5512	0.5283	0.4902	0.5501
131	<i>F14rep22</i>	0.8051	0.7955	0.7793	0.8046	<i>F7rep22</i>	0.1686	0.1633	0.1401	0.35	<i>F8rep20</i>	0.5511	0.5417	0.5243	0.5507
132	<i>F16rep25</i>	0.8046	0.7974	0.7826	0.8043	<i>F17rep29</i>	0.1685	0.1706	0.1427	2.4502	<i>F10rep1</i>	0.5495	0.5415	0.5258	0.5492
133	<i>F19rep8</i>	0.8041	0.785	0.7645	0.8027	<i>F4rep25</i>	0.1678	0.1463	0.1219	0.1666	<i>F10rep2</i>	0.5473	0.4875	0.4332	0.5408
134	<i>F2rep15</i>	0.804	0.7875	0.763	0.8017	<i>F19rep13</i>	0.1673	0.1564	0.128	0.2296	<i>F15rep21</i>	0.5454	0.5263	0.4968	0.5441
135	<i>F8rep6</i>	0.8034	0.7702	0.7474	0.7909	<i>F17rep9</i>	0.166	0.1458	0.1082	0.1656	<i>F18rep18</i>	0.545	0.5097	0.4628	0.543
136	<i>F11rep4</i>	0.8024	0.7713	0.7365	0.7976	<i>F17rep16</i>	0.1659	0.154	0.1243	0.2102	<i>F15rep29</i>	0.544	0.517	0.481	0.5418
137	<i>F18rep15</i>	0.8021	0.7744	0.7508	0.7945	<i>F15rep30</i>	0.164	0.1515	0.1237	0.191	<i>F7rep8</i>	0.5434	0.5169	0.4765	0.5419
138	<i>F17rep25</i>	0.8011	0.758	0.7117	0.7944	<i>F2rep1</i>	0.1632	0.145	0.123	0.1623	<i>F10rep19</i>	0.5429	0.5272	0.5008	0.542
139	<i>F15rep9</i>	0.8007	0.72	0.67	0.7885	<i>F14rep10</i>	0.1625	0.1613	0.1366	0.6163	<i>F2rep20</i>	0.5422	0.532	0.5116	0.542
140	<i>F10rep13</i>	0.8	0.7584	0.7246	0.7912	<i>F15rep11</i>	0.1616	0.148	0.1194	0.1738	<i>F20rep29</i>	0.5392	0.5292	0.5101	0.5389
141	<i>F1rep14</i>	0.7998	0.7661	0.7281	0.7927	<i>F17rep2</i>	0.1616	0.1519	0.125	0.2351	<i>F10rep21</i>	0.5389	0.4556	0.406	0.5245
142	<i>F18rep19</i>	0.7997	0.7935	0.7797	0.7995	<i>F8rep7</i>	0.1609	0.1512	0.1266	0.2066	<i>F5rep13</i>	0.5371	0.5182	0.4836	0.5362
143	<i>F12rep3</i>	0.7994	0.7786	0.7502	0.7966	<i>F13rep3</i>	0.1607	0.1485	0.1215	0.1786	<i>F2rep25</i>	0.5368	0.5221	0.4947	0.5362
144	<i>F17rep21</i>	0.798	0.7146	0.6664	0.7755	<i>F7rep12</i>	0.16	0.1528	0.1299	0.252	<i>F2rep10</i>	0.5329	0.5221	0.5031	0.5323
145	<i>F4rep20</i>	0.798	0.7766	0.7536	0.7934	<i>F7rep3</i>	0.1593	0.1416	0.1109	0.1589	<i>F4rep6</i>	0.5313	0.5197	0.4964	0.5309
146	<i>F20rep9</i>	0.7978	0.7879	0.7717	0.7973	<i>F19rep19</i>	0.1588	0.1433	0.1113	0.1627	<i>F4rep26</i>	0.5313	0.515	0.4896	0.5302
147	<i>F16rep13</i>	0.7969	0.7658	0.7379	0.7919	<i>F10rep3</i>	0.1582	0.1581	0.1342	0.8113	<i>F7rep1</i>	0.5304	0.5098	0.4788	0.529
148	<i>F18rep1</i>	0.7964	0.7866	0.7705	0.7959	<i>F14rep23</i>	0.158	0.1513	0.1266	0.2705	<i>F15rep22</i>	0.5292	0.3827	0.3212	0.5029
149	<i>F17rep3</i>	0.7964	0.7527	0.7192	0.7843	<i>F9rep21</i>	0.157	0.1354	0.1008	0.1562	<i>F11rep18</i>	0.5292	0.4677	0.4154	0.5217
150	<i>F12rep18</i>	0.7957	0.7877	0.7731	0.7953	<i>F8rep24</i>	0.1567	0.1385	0.1072	0.1563	<i>F19rep15</i>	0.5269	0.5051	0.4745	0.5252
151	<i>F11rep2</i>	0.7942	0.7869	0.7728	0.7939	<i>F2rep16</i>	0.156	0.1359	0.1142	0.1548	<i>F6rep7</i>	0.5266	0.5184	0.5032	0.5264

152	<i>F20rep17</i>	0.794	0.7806	0.7609	0.7931	<i>F3rep4</i>	0.1549	0.1422	0.1242	0.1545	<i>F20rep28</i>	0.5265	0.4155	0.3593	0.5046
153	<i>F20rep19</i>	0.7937	0.7687	0.7451	0.7885	<i>F11rep20</i>	0.1536	0.1402	0.114	0.1564	<i>F7rep20</i>	0.525	0.4854	0.4431	0.5215
154	<i>F15rep30</i>	0.7927	0.7829	0.7669	0.7922	<i>F8rep26</i>	0.1534	0.1359	0.1057	0.153	<i>F3rep9</i>	0.5227	0.4962	0.4569	0.5212
155	<i>F14rep14</i>	0.7923	0.7709	0.7431	0.7893	<i>F20rep23</i>	0.1531	0.1438	0.1184	0.223	<i>F14rep26</i>	0.5212	0.5066	0.4841	0.5201
156	<i>F12rep1</i>	0.7916	0.7813	0.7643	0.7912	<i>F1rep10</i>	0.1528	0.1358	0.1153	0.1519	<i>F10rep23</i>	0.5205	0.4955	0.4575	0.5189
157	<i>F18rep25</i>	0.7915	0.7591	0.7323	0.7854	<i>F19rep20</i>	0.1505	0.1314	0.0965	0.1502	<i>F4rep16</i>	0.5203	0.5083	0.4881	0.5196
158	<i>F10rep25</i>	0.7915	0.7683	0.7345	0.789	<i>F4rep29</i>	0.1504	0.1353	0.1151	0.1497	<i>F7rep16</i>	0.5198	0.5025	0.471	0.5191
159	<i>F7rep1</i>	0.7911	0.7454	0.7153	0.7763	<i>F10rep6</i>	0.1482	0.1378	0.114	0.1746	<i>F5rep4</i>	0.5189	0.5062	0.4815	0.5185
160	<i>F19rep9</i>	0.7905	0.7663	0.7391	0.7859	<i>F15rep6</i>	0.1473	0.1325	0.104	0.1472	<i>F10rep16</i>	0.5167	0.4983	0.4718	0.5154
161	<i>F16rep28</i>	0.7886	0.776	0.7589	0.7879	<i>F1rep19</i>	0.1459	0.1371	0.1229	0.1456	<i>F18rep16</i>	0.5149	0.4419	0.3945	0.5037
162	<i>F4rep28</i>	0.7882	0.7725	0.7524	0.7868	<i>F4rep2</i>	0.1456	0.1333	0.1152	0.1452	<i>F17rep13</i>	0.51	0.5007	0.4823	0.5097
163	<i>F10rep6</i>	0.788	0.7663	0.7433	0.7846	<i>F7rep23</i>	0.1447	0.1341	0.1124	0.1647	<i>F4rep9</i>	0.5091	0.4589	0.4133	0.5038
164	<i>F17rep9</i>	0.788	0.7686	0.7451	0.7854	<i>F17rep5</i>	0.1443	0.1505	0.1241	-0.7566	<i>F5rep11</i>	0.5089	0.4982	0.4776	0.5085
165	<i>F19rep7</i>	0.7878	0.7811	0.7677	0.7875	<i>F12rep12</i>	0.1441	0.1387	0.1177	0.2625	<i>F10rep14</i>	0.5088	0.4957	0.4697	0.5083
166	<i>F16rep14</i>	0.7872	0.7804	0.7661	0.7869	<i>F6rep29</i>	0.1439	0.1366	0.1217	0.1437	<i>F10rep17</i>	0.5083	0.5005	0.486	0.508
167	<i>F5rep3</i>	0.7867	0.776	0.7582	0.7861	<i>F20rep22</i>	0.1433	0.132	0.1065	0.1729	<i>F4rep22</i>	0.5073	0.4823	0.4431	0.506
168	<i>F14rep26</i>	0.7866	0.7703	0.7483	0.7853	<i>F17rep25</i>	0.1424	0.1352	0.1121	0.2379	<i>F10rep10</i>	0.5054	0.4667	0.4249	0.5007
169	<i>F10rep26</i>	0.7863	0.7725	0.7517	0.7854	<i>F2rep30</i>	0.1407	0.1279	0.1106	0.1401	<i>F14rep14</i>	0.505	0.4683	0.4269	0.5005
170	<i>F17rep10</i>	0.7857	0.7644	0.7415	0.7825	<i>F5rep29</i>	0.1407	0.1276	0.1093	0.1402	<i>F5rep26</i>	0.5043	0.4408	0.3935	0.4962
171	<i>F16rep15</i>	0.7854	0.7454	0.7085	0.7762	<i>F14rep14</i>	0.1404	0.1341	0.1118	0.2304	<i>F4rep1</i>	0.5035	0.4959	0.481	0.5033
172	<i>F8rep15</i>	0.785	0.7574	0.7211	0.7798	<i>F1rep26</i>	0.1382	0.1266	0.1104	0.1378	<i>F2rep17</i>	0.5034	0.4952	0.4798	0.5032
173	<i>F14rep1</i>	0.7849	0.7364	0.6957	0.7734	<i>F4rep22</i>	0.1381	0.1302	0.1162	0.1379	<i>F16rep8</i>	0.5032	0.4463	0.4001	0.4964
174	<i>F18rep5</i>	0.7845	0.7762	0.7609	0.784	<i>F19rep1</i>	0.138	0.1277	0.1035	0.1726	<i>F18rep6</i>	0.5015	0.4035	0.3489	0.489
175	<i>F2rep12</i>	0.7839	0.7766	0.7623	0.7836	<i>F11rep24</i>	0.1364	0.1215	0.0945	0.1361	<i>F19rep22</i>	0.5011	0.4806	0.4494	0.4999
176	<i>F12rep10</i>	0.7839	0.7787	0.766	0.7837	<i>F5rep30</i>	0.1361	0.1206	0.1014	0.1354	<i>F5rep30</i>	0.5005	0.4854	0.458	0.4998
177	<i>F6rep19</i>	0.7835	0.7537	0.7247	0.777	<i>F8rep20</i>	0.1351	0.1407	0.1169	-0.5246	<i>F20rep26</i>	0.4994	0.4865	0.4659	0.4985
178	<i>F12rep21</i>	0.7825	0.7721	0.7554	0.7819	<i>F16rep18</i>	0.1343	0.1272	0.1059	0.2008	<i>F10rep3</i>	0.498	0.4921	0.4793	0.4978
179	<i>F18rep7</i>	0.7824	0.776	0.7624	0.7822	<i>F8rep25</i>	0.134	0.1193	0.094	0.1337	<i>F14rep21</i>	0.4974	0.4773	0.4486	0.496
180	<i>F15rep23</i>	0.7819	0.7554	0.7295	0.7776	<i>F4rep15</i>	0.1322	0.1272	0.1143	0.1321	<i>F8rep11</i>	0.4965	0.4433	0.3983	0.4904
181	<i>F8rep3</i>	0.7811	0.7622	0.7398	0.7791	<i>F14rep18</i>	0.1304	0.1363	0.1126	-0.5945	<i>F14rep17</i>	0.4961	0.4379	0.3886	0.4889
182	<i>F7rep23</i>	0.7807	0.7455	0.7083	0.775	<i>F13rep30</i>	0.1298	0.1247	0.1059	0.2275	<i>F2rep21</i>	0.4938	0.4829	0.4627	0.4933
183	<i>F15rep10</i>	0.7807	0.7593	0.7366	0.7789	<i>F9rep24</i>	0.1297	0.1253	0.1066	0.2528	<i>F10rep20</i>	0.4921	0.4827	0.4635	0.4919
184	<i>F20rep1</i>	0.7806	0.7538	0.7174	0.7762	<i>F11rep12</i>	0.1297	0.1179	0.0948	0.1296	<i>F10rep29</i>	0.4913	0.4826	0.4659	0.4911
185	<i>F3rep26</i>	0.7805	0.7711	0.7554	0.78	<i>F4rep12</i>	0.1296	0.1227	0.1096	0.1295	<i>F5rep8</i>	0.49	0.4817	0.466	0.4897
186	<i>F3rep15</i>	0.7792	0.7681	0.7519	0.7787	<i>F11rep26</i>	0.1294	0.1223	0.1022	0.1835	<i>F17rep16</i>	0.4872	0.4753	0.4528	0.4867
187	<i>F14rep19</i>	0.7792	0.7405	0.7043	0.7702	<i>F5rep11</i>	0.129	0.1177	0.1012	0.1286	<i>F2rep22</i>	0.4868	0.4805	0.4674	0.4866
188	<i>F14rep21</i>	0.7792	0.772	0.7571	0.7789	<i>F4rep4</i>	0.1286	0.1176	0.1013	0.1282	<i>F2rep2</i>	0.4823	0.4229	0.3746	0.4743
189	<i>F6rep30</i>	0.7787	0.7719	0.7585	0.7785	<i>F12rep15</i>	0.1255	0.1216	0.1035	0.2557	<i>F10rep30</i>	0.4805	0.4739	0.4606	0.4803
190	<i>F15rep15</i>	0.7785	0.7517	0.7151	0.7749	<i>F11rep1</i>	0.1237	0.114	0.0934	0.1362	<i>F6rep2</i>	0.4803	0.4488	0.4117	0.478

191	<i>F2rep16</i>	0.7779	0.7544	0.7311	0.7741	<i>F10rep23</i>	0.1235	0.1275	0.1064	-1.0014	<i>F3rep1</i>	0.4796	0.4736	0.461	0.4794
192	<i>F16rep2</i>	0.7763	0.7701	0.7567	0.7761	<i>F10rep21</i>	0.1234	0.1276	0.1065	-0.8613	<i>F3rep12</i>	0.479	0.4384	0.3963	0.4755
193	<i>F12rep16</i>	0.7759	0.7658	0.7492	0.7754	<i>F18rep6</i>	0.1233	0.1125	0.0892	0.1378	<i>F10rep12</i>	0.4785	0.4496	0.4161	0.4763
194	<i>F19rep6</i>	0.7751	0.7519	0.7237	0.7711	<i>F9rep23</i>	0.1224	0.1275	0.1059	-0.4478	<i>F15rep8</i>	0.4752	0.4606	0.4365	0.4743
195	<i>F4rep24</i>	0.7748	0.6884	0.6344	0.7638	<i>F14rep27</i>	0.1217	0.1118	0.0904	0.134	<i>F8rep22</i>	0.4742	0.4636	0.4435	0.4738
196	<i>F15rep29</i>	0.7747	0.7618	0.7424	0.7737	<i>F4rep20</i>	0.1217	0.1172	0.1053	0.1216	<i>F20rep17</i>	0.4738	0.4577	0.4337	0.4727
197	<i>F17rep2</i>	0.7741	0.7258	0.6805	0.7664	<i>F11rep14</i>	0.1212	0.1151	0.0968	0.1806	<i>F18rep4</i>	0.4733	0.3748	0.3289	0.4553
198	<i>F10rep24</i>	0.774	0.769	0.7566	0.7739	<i>F4rep27</i>	0.1211	0.1128	0.0989	0.1209	<i>F7rep30</i>	0.4722	0.4604	0.4395	0.4717
199	<i>F10rep14</i>	0.7734	0.7508	0.7227	0.7704	<i>F2rep5</i>	0.1208	0.1099	0.0952	0.1203	<i>F4rep15</i>	0.4695	0.4583	0.4362	0.4691
200	<i>F17rep13</i>	0.7732	0.7502	0.7233	0.7684	<i>F15rep4</i>	0.1206	0.1138	0.0946	0.1737	<i>F10rep25</i>	0.4636	0.4166	0.3724	0.4589
201	<i>F14rep16</i>	0.7728	0.7524	0.731	0.7713	<i>F20rep21</i>	0.1206	0.1147	0.095	0.2041	<i>F10rep27</i>	0.4628	0.4552	0.4401	0.4626
202	<i>F18rep14</i>	0.772	0.704	0.6599	0.7583	<i>F18rep23</i>	0.1199	0.1127	0.0929	0.1774	<i>F1rep18</i>	0.462	0.4525	0.436	0.4615
203	<i>F12rep23</i>	0.7715	0.7615	0.7449	0.7711	<i>F9rep3</i>	0.1189	0.1247	0.1031	-0.3451	<i>F10rep28</i>	0.4617	0.3701	0.3202	0.4494
204	<i>F18rep21</i>	0.7711	0.7651	0.7518	0.7709	<i>F20rep29</i>	0.1185	0.1152	0.0968	0.284	<i>F20rep15</i>	0.4607	0.431	0.3969	0.4583
205	<i>F18rep11</i>	0.7707	0.7446	0.7089	0.7665	<i>F15rep2</i>	0.118	0.1273	0.1025	-0.2301	<i>F15rep1</i>	0.4607	0.4352	0.4029	0.4582
206	<i>F8rep4</i>	0.7704	0.7602	0.7438	0.77	<i>F8rep27</i>	0.1179	0.1076	0.0887	0.1194	<i>F7rep28</i>	0.4604	0.4546	0.4426	0.4602
207	<i>F2rep11</i>	0.7699	0.7463	0.7134	0.7666	<i>F18rep19</i>	0.1172	0.1216	0.1005	-0.8425	<i>F18rep21</i>	0.4601	0.391	0.3453	0.4496
208	<i>F5rep13</i>	0.7698	0.742	0.7185	0.7649	<i>F17rep19</i>	0.1168	0.1123	0.0937	0.2336	<i>F1rep25</i>	0.4592	0.4495	0.4298	0.4589
209	<i>F12rep24</i>	0.7696	0.7615	0.7475	0.7692	<i>F20rep20</i>	0.1168	0.1124	0.0937	0.2334	<i>F1rep24</i>	0.4588	0.452	0.439	0.4586
210	<i>F20rep13</i>	0.7684	0.7524	0.7305	0.7668	<i>F3rep16</i>	0.1164	0.108	0.0952	0.1161	<i>F4rep11</i>	0.4587	0.4521	0.4388	0.4585
211	<i>F18rep4</i>	0.7683	0.7409	0.7149	0.7648	<i>F18rep28</i>	0.116	0.1094	0.0904	0.1789	<i>F19rep18</i>	0.4587	0.4509	0.4361	0.4583
212	<i>F10rep30</i>	0.7672	0.7617	0.7489	0.767	<i>F2rep19</i>	0.1155	0.1053	0.0914	0.115	<i>F7rep5</i>	0.4569	0.4273	0.3926	0.4547
213	<i>F12rep30</i>	0.7665	0.7599	0.7468	0.7663	<i>F11rep29</i>	0.115	0.1255	0.1003	-0.1643	<i>F15rep30</i>	0.4561	0.428	0.3957	0.4539
214	<i>F19rep27</i>	0.766	0.7561	0.7395	0.7656	<i>F14rep5</i>	0.1145	0.1146	0.0966	0.6305	<i>F20rep25</i>	0.4559	0.4444	0.4251	0.4554
215	<i>F10rep11</i>	0.7654	0.7397	0.7179	0.7597	<i>F15rep23</i>	0.1141	0.1096	0.0927	0.2059	<i>F19rep3</i>	0.4555	0.4441	0.4226	0.455
216	<i>F17rep24</i>	0.7648	0.7576	0.7427	0.7645	<i>F12rep6</i>	0.114	0.1098	0.0932	0.2084	<i>F15rep18</i>	0.4531	0.4372	0.4134	0.452
217	<i>F1rep26</i>	0.7638	0.7406	0.7181	0.7594	<i>F1rep16</i>	0.1138	0.1053	0.0925	0.1135	<i>F6rep5</i>	0.4529	0.4476	0.4362	0.4527
218	<i>F1rep12</i>	0.762	0.6686	0.6206	0.747	<i>F18rep7</i>	0.1135	0.1189	0.0977	-0.5201	<i>F16rep9</i>	0.4526	0.4423	0.4246	0.452
219	<i>F15rep26</i>	0.7617	0.7566	0.7445	0.7615	<i>F9rep13</i>	0.113	0.1085	0.0924	0.2026	<i>F10rep8</i>	0.4521	0.437	0.4098	0.4515
220	<i>F1rep2</i>	0.7614	0.7396	0.7163	0.7576	<i>F3rep10</i>	0.1129	0.1047	0.0922	0.1126	<i>F4rep25</i>	0.4513	0.3923	0.3469	0.4434
221	<i>F11rep10</i>	0.7603	0.7525	0.7373	0.7599	<i>F14rep11</i>	0.1118	0.1179	0.0968	-0.3728	<i>F7rep14</i>	0.4512	0.4441	0.4306	0.4509
222	<i>F10rep18</i>	0.7601	0.7369	0.7106	0.7551	<i>F1rep1</i>	0.1116	0.1044	0.0928	0.1114	<i>F2rep16</i>	0.4501	0.4334	0.4064	0.4493
223	<i>F15rep1</i>	0.7599	0.7302	0.6964	0.7534	<i>F5rep26</i>	0.1107	0.1036	0.0909	0.1106	<i>F1rep29</i>	0.4476	0.4368	0.4185	0.4471
224	<i>F4rep2</i>	0.7598	0.7515	0.7364	0.7594	<i>F16rep26</i>	0.1104	0.1033	0.0858	0.1431	<i>F17rep7</i>	0.4472	0.4345	0.414	0.4464
225	<i>F10rep11</i>	0.7598	0.7345	0.7094	0.7562	<i>F10rep4</i>	0.1103	0.1097	0.093	0.4578	<i>F18rep25</i>	0.4462	0.4276	0.4019	0.4448
226	<i>F12rep2</i>	0.7597	0.7428	0.7214	0.7574	<i>F20rep1</i>	0.1103	0.1055	0.0878	0.2033	<i>F1rep30</i>	0.4454	0.4149	0.3796	0.4418
227	<i>F7rep15</i>	0.7592	0.7309	0.6972	0.7529	<i>F8rep23</i>	0.11	0.1138	0.0949	-0.5711	<i>F2rep26</i>	0.4437	0.4264	0.3963	0.4428
228	<i>F2rep29</i>	0.7587	0.7403	0.7174	0.7567	<i>F14rep1</i>	0.1099	0.111	0.0931	1.0425	<i>F3rep24</i>	0.4435	0.4346	0.4166	0.4432
229	<i>F15rep20</i>	0.7573	0.7403	0.7201	0.7556	<i>F14rep8</i>	0.1079	0.116	0.0937	-0.2219	<i>F4rep18</i>	0.4431	0.4036	0.3652	0.4395



230	<i>F6rep9</i>	0.7564	0.7492	0.7354	0.7561	<i>F14rep4</i>	0.1074	0.1137	0.093	-0.3145	<i>F14rep25</i>	0.4396	0.4232	0.3992	0.4384
231	<i>F19rep14</i>	0.7564	0.7287	0.7011	0.7507	<i>F6rep13</i>	0.1066	0.1036	0.0926	0.1065	<i>F5rep21</i>	0.4382	0.4061	0.371	0.4354
232	<i>F12rep19</i>	0.7563	0.7376	0.7177	0.7549	<i>F4rep11</i>	0.1061	0.098	0.0853	0.1059	<i>F4rep24</i>	0.437	0.424	0.4042	0.4363
233	<i>F16rep23</i>	0.7562	0.7457	0.7297	0.7557	<i>F20rep3</i>	0.106	0.1222	0.0927	-0.1035	<i>F14rep8</i>	0.4364	0.421	0.3983	0.4353
234	<i>F10rep12</i>	0.7561	0.7176	0.6906	0.744	<i>F3rep1</i>	0.1045	0.0977	0.0869	0.1042	<i>F8rep17</i>	0.4347	0.4265	0.4116	0.4343
235	<i>F14rep5</i>	0.7549	0.7328	0.7097	0.7521	<i>F11rep10</i>	0.1035	0.1003	0.0852	0.2128	<i>F17rep1</i>	0.4345	0.4234	0.4015	0.4341
236	<i>F5rep8</i>	0.7547	0.7246	0.6855	0.7511	<i>F1rep11</i>	0.1032	0.0966	0.0861	0.103	<i>F4rep2</i>	0.4338	0.4281	0.4165	0.4337
237	<i>F19rep29</i>	0.7546	0.7378	0.7158	0.7532	<i>F10rep25</i>	0.1031	0.1043	0.0881	1.3393	<i>F2rep27</i>	0.4333	0.4227	0.4047	0.4328
238	<i>F17rep23</i>	0.754	0.7259	0.6936	0.7501	<i>F19rep27</i>	0.103	0.1066	0.0881	-0.8973	<i>F18rep28</i>	0.4328	0.4092	0.379	0.4305
239	<i>F19rep1</i>	0.7524	0.7418	0.726	0.7519	<i>F10rep7</i>	0.1027	0.1027	0.0869	0.5509	<i>F1rep15</i>	0.4311	0.4176	0.3968	0.4301
240	<i>F10rep7</i>	0.7517	0.7457	0.7327	0.7514	<i>F20rep10</i>	0.1026	0.112	0.089	-0.1799	<i>F1rep26</i>	0.4307	0.4179	0.398	0.4297
241	<i>F7rep21</i>	0.7507	0.7282	0.7059	0.7465	<i>F17rep24</i>	0.1025	0.1109	0.0888	-0.2001	<i>F14rep23</i>	0.4305	0.4255	0.4146	0.4303
242	<i>F5rep28</i>	0.7506	0.7323	0.71	0.7486	<i>F19rep16</i>	0.1023	0.1007	0.0844	0.3248	<i>F10rep22</i>	0.4303	0.4071	0.3769	0.4287
243	<i>F10rep30</i>	0.7503	0.7335	0.7127	0.7479	<i>F19rep8</i>	0.1016	0.0961	0.0795	0.1607	<i>F7rep21</i>	0.4301	0.4221	0.4069	0.4299
244	<i>F3rep30</i>	0.7496	0.7372	0.7205	0.7489	<i>F11rep7</i>	0.1014	0.1098	0.0883	-0.1648	<i>F15rep19</i>	0.4279	0.3208	0.2786	0.4072
245	<i>F10rep3</i>	0.7491	0.7432	0.7304	0.7489	<i>F16rep25</i>	0.1006	0.0973	0.0825	0.201	<i>F5rep15</i>	0.4277	0.4212	0.4089	0.4275
246	<i>F6rep22</i>	0.749	0.7439	0.7318	0.7488	<i>F9rep4</i>	0.0994	0.0931	0.0779	0.127	<i>F19rep25</i>	0.4262	0.4052	0.3772	0.4246
247	<i>F20rep15</i>	0.7488	0.7442	0.7324	0.7487	<i>F7rep24</i>	0.0991	0.103	0.0859	-0.3014	<i>F8rep6</i>	0.426	0.3411	0.2996	0.4121
248	<i>F6rep2</i>	0.7487	0.7228	0.6915	0.7431	<i>F17rep14</i>	0.0989	0.0994	0.0833	0.8042	<i>F8rep21</i>	0.4235	0.4136	0.395	0.4231
249	<i>F10rep9</i>	0.7477	0.7284	0.7083	0.7463	<i>F9rep28</i>	0.0984	0.0976	0.083	0.3867	<i>F18rep12</i>	0.4227	0.3377	0.2898	0.406
250	<i>F5rep6</i>	0.7476	0.6416	0.5977	0.7136	<i>F5rep20</i>	0.0984	0.0939	0.084	0.0983	<i>F1rep8</i>	0.4217	0.4121	0.3956	0.4212
251	<i>F6rep5</i>	0.7475	0.6854	0.6383	0.7381	<i>F11rep15</i>	0.0981	0.0932	0.0785	0.1489	<i>F15rep14</i>	0.4212	0.3807	0.3422	0.4176
252	<i>F3rep6</i>	0.7472	0.7392	0.7242	0.7468	<i>F15rep16</i>	0.098	0.1032	0.0847	-0.3472	<i>F5rep9</i>	0.4208	0.414	0.4006	0.4206
253	<i>F10rep16</i>	0.7466	0.736	0.7204	0.7461	<i>F10rep16</i>	0.0967	0.102	0.0839	-0.2846	<i>F4rep30</i>	0.4193	0.4048	0.3838	0.4182
254	<i>F8rep20</i>	0.7465	0.7417	0.7299	0.7463	<i>F18rep14</i>	0.0967	0.1114	0.0846	-0.0941	<i>F15rep25</i>	0.4183	0.4086	0.3918	0.4178
255	<i>F20rep11</i>	0.7458	0.727	0.7054	0.7422	<i>F14rep29</i>	0.0962	0.0913	0.0762	0.1469	<i>F14rep19</i>	0.418	0.4077	0.3881	0.4176
256	<i>F3rep24</i>	0.7448	0.7398	0.7278	0.7446	<i>F17rep1</i>	0.0946	0.0954	0.0797	0.9631	<i>F8rep9</i>	0.4167	0.3721	0.3312	0.412
257	<i>F3rep29</i>	0.7444	0.7398	0.7282	0.7443	<i>F20rep8</i>	0.0945	0.1028	0.0819	-0.1723	<i>F7rep6</i>	0.4161	0.4024	0.3811	0.4151
258	<i>F17rep29</i>	0.7442	0.7183	0.6941	0.7405	<i>F19rep17</i>	0.0945	0.1053	0.0822	-0.1243	<i>F19rep10</i>	0.4161	0.4048	0.3843	0.4155
259	<i>F3rep20</i>	0.7425	0.7369	0.7242	0.7423	<i>F18rep25</i>	0.0938	0.0947	0.0791	0.8867	<i>F5rep24</i>	0.416	0.4059	0.386	0.4157
260	<i>F18rep12</i>	0.7421	0.7332	0.7185	0.7416	<i>F17rep12</i>	0.0938	0.1009	0.0812	-0.2025	<i>F2rep15</i>	0.416	0.4083	0.3941	0.4156
261	<i>F6rep18</i>	0.7416	0.7017	0.6627	0.7326	<i>F10rep8</i>	0.0937	0.0966	0.0807	-0.7911	<i>F10rep7</i>	0.4159	0.4083	0.3939	0.4156
262	<i>F5rep10</i>	0.7413	0.7221	0.7004	0.7392	<i>F4rep10</i>	0.0937	0.09	0.0809	0.0936	<i>F3rep10</i>	0.4148	0.4073	0.3925	0.4146
263	<i>F18rep27</i>	0.7402	0.7197	0.6981	0.7383	<i>F3rep7</i>	0.0935	0.0879	0.0788	0.0933	<i>F8rep24</i>	0.4139	0.4014	0.3824	0.4129
264	<i>F8rep8</i>	0.74	0.7234	0.7054	0.7389	<i>F3rep17</i>	0.0934	0.087	0.077	0.0931	<i>F10rep6</i>	0.4134	0.4036	0.3869	0.413
265	<i>F6rep11</i>	0.7394	0.7173	0.6956	0.7353	<i>F8rep12</i>	0.0928	0.0924	0.0784	0.4415	<i>F17rep24</i>	0.4131	0.3909	0.3622	0.4116
266	<i>F10rep3</i>	0.7392	0.7217	0.7004	0.7373	<i>F3rep6</i>	0.0927	0.0876	0.0793	0.0925	<i>F8rep30</i>	0.4131	0.4071	0.3952	0.4129
267	<i>F19rep12</i>	0.7389	0.7251	0.7052	0.7372	<i>F6rep24</i>	0.0925	0.0886	0.0794	0.0925	<i>F11rep15</i>	0.4126	0.3955	0.3719	0.4113
268	<i>F15rep13</i>	0.7388	0.7271	0.7093	0.7381	<i>F20rep24</i>	0.0923	0.0997	0.0799	-0.1929	<i>F11rep5</i>	0.4105	0.3979	0.3771	0.4097

269	<i>F6rep24</i>	0.7388	0.7237	0.7061	0.7379	<i>F9rep9</i>	0.0921	0.0964	0.0798	-0.2814	<i>F8rep16</i>	0.4097	0.4043	0.3935	0.4095
270	<i>F2rep8</i>	0.7386	0.6997	0.6651	0.7298	<i>F6rep1</i>	0.0918	0.0858	0.0753	0.0917	<i>F20rep13</i>	0.4096	0.3927	0.3672	0.4086
271	<i>F3rep2</i>	0.7384	0.7294	0.7145	0.738	<i>F4rep1</i>	0.0916	0.0886	0.0795	0.0916	<i>F10rep7</i>	0.4092	0.3992	0.3822	0.4087
272	<i>F6rep12</i>	0.7375	0.7148	0.6898	0.7335	<i>F10rep1</i>	0.0915	0.0905	0.0769	0.3146	<i>F4rep8</i>	0.409	0.4005	0.3835	0.4087
273	<i>F5rep12</i>	0.7371	0.711	0.6822	0.7324	<i>F12rep18</i>	0.0907	0.0916	0.0774	1.1008	<i>F8rep26</i>	0.4085	0.4026	0.3909	0.4083
274	<i>F8rep14</i>	0.7357	0.7117	0.6773	0.7324	<i>F15rep9</i>	0.0896	0.0879	0.0743	0.2374	<i>F1rep22</i>	0.4081	0.3961	0.374	0.4076
275	<i>F3rep25</i>	0.7356	0.7162	0.6903	0.7329	<i>F2rep8</i>	0.0893	0.0841	0.0756	0.0891	<i>F19rep14</i>	0.408	0.3821	0.352	0.406
276	<i>F1rep18</i>	0.7356	0.7179	0.696	0.7327	<i>F3rep2</i>	0.0888	0.0837	0.0752	0.0886	<i>F10rep13</i>	0.4068	0.3942	0.3766	0.4061
277	<i>F10rep24</i>	0.735	0.7291	0.7165	0.7347	<i>F14rep3</i>	0.0885	0.0932	0.0765	-0.3176	<i>F17rep10</i>	0.4066	0.3951	0.3766	0.4058
278	<i>F6rep13</i>	0.7346	0.7144	0.6887	0.7314	<i>F15rep27</i>	0.0885	0.085	0.0717	0.1581	<i>F1rep12</i>	0.4059	0.4	0.3883	0.4057
279	<i>F1rep21</i>	0.7341	0.7258	0.7121	0.7337	<i>F4rep3</i>	0.0876	0.0849	0.0762	0.0876	<i>F8rep7</i>	0.4052	0.3748	0.3392	0.4032
280	<i>F16rep4</i>	0.7341	0.6938	0.6586	0.7245	<i>F7rep4</i>	0.0867	0.09	0.0752	-0.2822	<i>F4rep29</i>	0.4046	0.3988	0.3871	0.4045
281	<i>F3rep4</i>	0.7334	0.7213	0.703	0.7326	<i>F1rep21</i>	0.0865	0.0821	0.0745	0.0863	<i>F10rep6</i>	0.4022	0.3921	0.3756	0.4015
282	<i>F4rep7</i>	0.7323	0.7207	0.7031	0.7315	<i>F20rep17</i>	0.0862	0.0982	0.0752	-0.0907	<i>F10rep16</i>	0.3997	0.385	0.3632	0.3987
283	<i>F5rep30</i>	0.7322	0.6528	0.6081	0.7178	<i>F13rep15</i>	0.0861	0.0846	0.0719	0.2452	<i>F17rep11</i>	0.3988	0.3427	0.3018	0.3934
284	<i>F4rep12</i>	0.732	0.7006	0.6639	0.7281	<i>F4rep9</i>	0.0858	0.0823	0.074	0.0857	<i>F2rep8</i>	0.3986	0.386	0.3662	0.3977
285	<i>F10rep26</i>	0.732	0.7026	0.6752	0.7266	<i>F19rep12</i>	0.0854	0.0951	0.0743	-0.1137	<i>F7rep19</i>	0.3974	0.3906	0.3776	0.3971
286	<i>F4rep10</i>	0.732	0.7267	0.7147	0.7318	<i>F19rep21</i>	0.0846	0.091	0.0732	-0.1905	<i>F8rep2</i>	0.3974	0.3934	0.3838	0.3973
287	<i>F1rep4</i>	0.7304	0.7169	0.6977	0.7287	<i>F9rep19</i>	0.0846	0.081	0.069	0.1451	<i>F19rep28</i>	0.3962	0.3889	0.376	0.3958
288	<i>F5rep16</i>	0.7303	0.724	0.7105	0.73	<i>F16rep16</i>	0.0846	0.0884	0.073	-0.3969	<i>F20rep4</i>	0.396	0.3134	0.2694	0.3775
289	<i>F6rep14</i>	0.7299	0.6972	0.6731	0.7219	<i>F9rep16</i>	0.0844	0.0852	0.0722	1.4011	<i>F11rep23</i>	0.3951	0.3896	0.3785	0.395
290	<i>F10rep12</i>	0.7299	0.7249	0.7127	0.7298	<i>F19rep2</i>	0.0841	0.0973	0.0736	-0.0796	<i>F5rep6</i>	0.3941	0.3859	0.3717	0.3936
291	<i>F2rep7</i>	0.7299	0.7229	0.7096	0.7296	<i>F19rep26</i>	0.0838	0.0847	0.0707	0.9334	<i>F17rep22</i>	0.3927	0.3755	0.3521	0.3914
292	<i>F5rep7</i>	0.7296	0.7117	0.6888	0.7276	<i>F18rep5</i>	0.0838	0.0944	0.073	-0.0978	<i>F11rep10</i>	0.3927	0.3746	0.3486	0.3914
293	<i>F6rep16</i>	0.7274	0.7228	0.7114	0.7273	<i>F11rep25</i>	0.0836	0.082	0.0696	0.2232	<i>F3rep4</i>	0.3918	0.3868	0.3767	0.3917
294	<i>F13rep25</i>	0.7271	0.6939	0.6566	0.7194	<i>F17rep21</i>	0.0832	0.0894	0.072	-0.1812	<i>F7rep25</i>	0.3902	0.384	0.3718	0.39
295	<i>F8rep2</i>	0.7269	0.7116	0.6911	0.7252	<i>F13rep7</i>	0.0832	0.0861	0.0717	-0.5252	<i>F20rep8</i>	0.3888	0.3838	0.3736	0.3886
296	<i>F20rep27</i>	0.7266	0.7106	0.6912	0.7251	<i>F16rep10</i>	0.0828	0.0853	0.0712	-1.1973	<i>F15rep28</i>	0.3888	0.3217	0.2796	0.3801
297	<i>F1rep13</i>	0.7265	0.7163	0.6996	0.726	<i>F17rep11</i>	0.0824	0.0857	0.0708	-0.4952	<i>F6rep8</i>	0.3887	0.3819	0.3688	0.3885
298	<i>F10rep8</i>	0.7264	0.7115	0.6901	0.7246	<i>F4rep16</i>	0.0824	0.0804	0.072	0.0823	<i>F7rep7</i>	0.3879	0.3824	0.3713	0.3877
299	<i>F17rep17</i>	0.7258	0.7196	0.7059	0.7256	<i>F5rep15</i>	0.0818	0.0788	0.0706	0.0818	<i>F1rep10</i>	0.3872	0.3832	0.3736	0.3871
300	<i>F12rep22</i>	0.7254	0.6922	0.6631	0.7184	<i>F1rep27</i>	0.0816	0.0778	0.0708	0.0815	<i>F19rep30</i>	0.3872	0.3602	0.3297	0.3848
301	<i>F6rep3</i>	0.7249	0.7204	0.7089	0.7248	<i>F14rep2</i>	0.0811	0.0846	0.0699	-0.4188	<i>F17rep17</i>	0.3854	0.3781	0.3649	0.3851
302	<i>F12rep28</i>	0.7248	0.7155	0.7003	0.7244	<i>F11rep4</i>	0.081	0.0899	0.071	-0.0933	<i>F14rep30</i>	0.385	0.3125	0.267	0.3732
303	<i>F18rep10</i>	0.7246	0.6978	0.6761	0.718	<i>F5rep16</i>	0.0808	0.0785	0.0701	0.0807	<i>F3rep27</i>	0.3848	0.3809	0.3716	0.3847
304	<i>F16rep3</i>	0.7242	0.6962	0.6641	0.718	<i>F14rep6</i>	0.0806	0.0897	0.0704	-0.0996	<i>F8rep1</i>	0.3842	0.3703	0.3496	0.3832
305	<i>F16rep29</i>	0.7231	0.7117	0.6964	0.7225	<i>F19rep28</i>	0.0806	0.0847	0.0694	-0.3322	<i>F7rep17</i>	0.3838	0.3773	0.3647	0.3835
306	<i>F8rep28</i>	0.7219	0.7128	0.6975	0.7215	<i>F10rep27</i>	0.0806	0.0856	0.07	-0.1924	<i>F20rep6</i>	0.3829	0.3699	0.3507	0.382
307	<i>F11rep23</i>	0.7218	0.7138	0.6991	0.7214	<i>F6rep28</i>	0.08	0.0769	0.0689	0.0799	<i>F14rep15</i>	0.3825	0.3747	0.3611	0.3821

308	<i>F8rep30</i>	0.7217	0.7087	0.6907	0.7208	<i>F17rep10</i>	0.0796	0.0887	0.0693	-0.1024	<i>F10rep27</i>	0.3821	0.3768	0.3663	0.3819
309	<i>F7rep4</i>	0.7216	0.705	0.6833	0.7195	<i>F5rep8</i>	0.0794	0.0775	0.0692	0.0794	<i>F11rep3</i>	0.3792	0.3653	0.3451	0.3782
310	<i>F10rep23</i>	0.7214	0.7066	0.6859	0.7199	<i>F15rep10</i>	0.0789	0.0868	0.0687	-0.1136	<i>F1rep13</i>	0.3787	0.3738	0.3639	0.3785
311	<i>F6rep10</i>	0.7208	0.7145	0.7021	0.7206	<i>F16rep30</i>	0.0787	0.082	0.0679	-0.434	<i>F6rep4</i>	0.3781	0.3724	0.3626	0.378
312	<i>F6rep1</i>	0.7195	0.715	0.7036	0.7194	<i>F13rep25</i>	0.0786	0.079	0.0667	0.5703	<i>F3rep15</i>	0.378	0.3729	0.363	0.3778
313	<i>F14rep3</i>	0.719	0.7039	0.6867	0.7181	<i>F6rep22</i>	0.0779	0.0737	0.0655	0.0778	<i>F10rep2</i>	0.3758	0.3585	0.3348	0.3745
314	<i>F18rep20</i>	0.719	0.7065	0.6903	0.7182	<i>F5rep18</i>	0.0777	0.0739	0.0657	0.0776	<i>F18rep3</i>	0.3748	0.3613	0.339	0.3742
315	<i>F8rep5</i>	0.7186	0.7133	0.701	0.7185	<i>F13rep20</i>	0.0775	0.0776	0.0656	0.4305	<i>F10rep1</i>	0.3726	0.368	0.3585	0.3724
316	<i>F18rep24</i>	0.7184	0.6987	0.6736	0.7153	<i>F17rep28</i>	0.0773	0.0824	0.0668	-0.2052	<i>F4rep20</i>	0.3725	0.3667	0.3575	0.3724
317	<i>F16rep17</i>	0.7177	0.7114	0.699	0.7174	<i>F6rep30</i>	0.0768	0.0743	0.0664	0.0768	<i>F6rep25</i>	0.3715	0.3657	0.355	0.3713
318	<i>F4rep23</i>	0.7173	0.6707	0.624	0.7131	<i>F11rep16</i>	0.0766	0.0846	0.067	-0.0922	<i>F7rep10</i>	0.3706	0.3663	0.357	0.3704
319	<i>F20rep30</i>	0.7166	0.7067	0.6917	0.7161	<i>F5rep22</i>	0.0762	0.0739	0.0661	0.0761	<i>F5rep12</i>	0.3701	0.3651	0.3559	0.37
320	<i>F4rep15</i>	0.7159	0.6469	0.5993	0.7053	<i>F12rep2</i>	0.076	0.0845	0.0667	-0.0868	<i>F1rep20</i>	0.3681	0.3635	0.3541	0.368
321	<i>F18rep9</i>	0.7159	0.6859	0.653	0.709	<i>F6rep9</i>	0.0752	0.0709	0.0627	0.0752	<i>F20rep11</i>	0.3662	0.337	0.3055	0.3637
322	<i>F20rep21</i>	0.7159	0.6976	0.6769	0.7139	<i>F5rep28</i>	0.075	0.0736	0.0656	0.075	<i>F10rep3</i>	0.3656	0.3611	0.3518	0.3654
323	<i>F19rep5</i>	0.7148	0.6904	0.6612	0.7097	<i>F19rep7</i>	0.0747	0.0862	0.0653	-0.0713	<i>F4rep19</i>	0.3601	0.3552	0.3451	0.36
324	<i>F5rep17</i>	0.7145	0.7097	0.6981	0.7144	<i>F6rep5</i>	0.0746	0.0722	0.0646	0.0746	<i>F7rep3</i>	0.3593	0.3543	0.3441	0.3591
325	<i>F3rep7</i>	0.7133	0.7081	0.696	0.7131	<i>F18rep16</i>	0.074	0.0769	0.0635	-0.4976	<i>F19rep16</i>	0.3586	0.3522	0.3404	0.3583
326	<i>F12rep17</i>	0.7133	0.6831	0.6511	0.7063	<i>F13rep23</i>	0.074	0.0791	0.0643	-0.1521	<i>F10rep17</i>	0.3569	0.3486	0.3334	0.3565
327	<i>F14rep7</i>	0.7129	0.7055	0.6924	0.7126	<i>F14rep24</i>	0.0739	0.0804	0.0643	-0.1228	<i>F2rep12</i>	0.3562	0.3516	0.3423	0.356
328	<i>F19rep15</i>	0.7124	0.688	0.6624	0.7077	<i>F19rep24</i>	0.0738	0.079	0.0637	-0.1818	<i>F14rep10</i>	0.3547	0.3034	0.2667	0.3494
329	<i>F8rep25</i>	0.7121	0.7054	0.6923	0.7118	<i>F10rep20</i>	0.0736	0.0817	0.0645	-0.0849	<i>F8rep12</i>	0.3521	0.3459	0.3343	0.3519
330	<i>F5rep14</i>	0.7109	0.6172	0.5742	0.6764	<i>F15rep25</i>	0.0735	0.0828	0.0643	-0.0805	<i>F1rep9</i>	0.3507	0.3452	0.3348	0.3506
331	<i>F5rep15</i>	0.7107	0.6905	0.6687	0.7068	<i>F7rep2</i>	0.0735	0.0781	0.064	-0.1206	<i>F3rep25</i>	0.3477	0.3433	0.3342	0.3476
332	<i>F7rep3</i>	0.7084	0.6302	0.5858	0.6961	<i>F9rep26</i>	0.0735	0.078	0.0638	-0.1522	<i>F20rep1</i>	0.3476	0.3417	0.3311	0.3473
333	<i>F2rep19</i>	0.7084	0.6467	0.5991	0.7001	<i>F1rep7</i>	0.0732	0.0701	0.0638	0.0731	<i>F2rep18</i>	0.3473	0.3434	0.3347	0.3472
334	<i>F2rep6</i>	0.7079	0.689	0.6657	0.7052	<i>F11rep5</i>	0.0732	0.0792	0.0637	-0.118	<i>F14rep4</i>	0.3471	0.3227	0.2951	0.3451
335	<i>F3rep1</i>	0.7078	0.7031	0.6917	0.7076	<i>F2rep25</i>	0.0731	0.0698	0.0635	0.073	<i>F2rep4</i>	0.3466	0.3419	0.3322	0.3464
336	<i>F10rep27</i>	0.7071	0.6849	0.6648	0.7021	<i>F5rep9</i>	0.073	0.0709	0.0634	0.073	<i>F19rep19</i>	0.3462	0.3414	0.3319	0.3461
337	<i>F12rep14</i>	0.7054	0.7011	0.6899	0.7053	<i>F17rep17</i>	0.073	0.0828	0.0637	-0.0781	<i>F17rep20</i>	0.3459	0.3311	0.3107	0.3447
338	<i>F6rep8</i>	0.7053	0.7005	0.689	0.7051	<i>F9rep5</i>	0.073	0.0785	0.0635	-0.1175	<i>F2rep28</i>	0.3458	0.3413	0.3321	0.3456
339	<i>F10rep20</i>	0.7053	0.7	0.6881	0.7051	<i>F1rep14</i>	0.073	0.0685	0.0612	0.0728	<i>F11rep11</i>	0.3452	0.3175	0.287	0.3433
340	<i>F11rep8</i>	0.703	0.6933	0.6774	0.7025	<i>F7rep29</i>	0.0724	0.0771	0.0631	-0.1148	<i>F11rep14</i>	0.3423	0.3104	0.2791	0.3398
341	<i>F4rep13</i>	0.7017	0.6735	0.6421	0.6952	<i>F10rep15</i>	0.0722	0.077	0.0627	-0.1529	<i>F18rep10</i>	0.3422	0.3335	0.319	0.3418
342	<i>F11rep21</i>	0.7013	0.6959	0.6839	0.7011	<i>F5rep27</i>	0.0717	0.0677	0.0601	0.0716	<i>F13rep26</i>	0.3419	0.2815	0.2397	0.3329
343	<i>F4rep25</i>	0.6996	0.6836	0.6582	0.6979	<i>F20rep28</i>	0.0712	0.0748	0.0612	-0.2919	<i>F8rep28</i>	0.3411	0.3369	0.3282	0.3409
344	<i>F14rep4</i>	0.6992	0.6719	0.6456	0.6948	<i>F20rep4</i>	0.0712	0.0776	0.0617	-0.1253	<i>F6rep18</i>	0.3395	0.3145	0.2847	0.3379
345	<i>F19rep25</i>	0.6991	0.6907	0.676	0.6986	<i>F4rep18</i>	0.071	0.0693	0.0621	0.071	<i>F15rep16</i>	0.3394	0.3306	0.3166	0.3388
346	<i>F7rep25</i>	0.6981	0.6911	0.6765	0.6978	<i>F1rep2</i>	0.0707	0.0679	0.0622	0.0706	<i>F14rep24</i>	0.3393	0.3102	0.2794	0.337

347	F10rep18	0.698	0.6813	0.6609	0.6961	F13rep27	0.0705	0.074	0.061	-0.2327	F18rep26	0.3381	0.3281	0.3125	0.3374
348	F6rep23	0.6978	0.6928	0.6812	0.6976	F8rep3	0.07	0.0769	0.0612	-0.0818	F12rep17	0.3377	0.3323	0.3221	0.3375
349	F12rep11	0.6968	0.6913	0.6794	0.6966	F11rep3	0.0698	0.0774	0.0611	-0.0799	F2rep14	0.3375	0.3301	0.3167	0.3372
350	F16rep5	0.6956	0.6813	0.6615	0.6943	F3rep30	0.0694	0.0662	0.0602	0.0693	F10rep29	0.3372	0.3153	0.2864	0.3359
351	F11rep29	0.6951	0.6352	0.5965	0.6795	F10rep19	0.0691	0.0714	0.0595	-0.4988	F18rep15	0.3361	0.2782	0.2365	0.3281
352	F16rep22	0.6939	0.6893	0.6781	0.6937	F17rep15	0.0689	0.0797	0.0606	-0.0651	F4rep3	0.3361	0.3287	0.3157	0.3357
353	F2rep13	0.6934	0.671	0.6453	0.6882	F9rep8	0.0687	0.0681	0.0579	0.295	F10rep21	0.3345	0.3305	0.322	0.3344
354	F19rep13	0.6923	0.6729	0.6524	0.6902	F7rep10	0.0685	0.0734	0.0598	-0.0952	F6rep23	0.334	0.3287	0.3187	0.3338
355	F7rep12	0.6915	0.6864	0.6749	0.6913	F19rep4	0.0684	0.0794	0.06	-0.0617	F3rep26	0.3338	0.3291	0.3196	0.3336
356	F3rep21	0.6911	0.6868	0.6758	0.691	F14rep25	0.0683	0.076	0.0596	-0.0845	F3rep29	0.3336	0.3269	0.315	0.3333
357	F10rep1	0.6908	0.6855	0.6737	0.6906	F13rep16	0.0677	0.0732	0.059	-0.1148	F1rep27	0.3327	0.3196	0.2991	0.3321
358	F10rep5	0.6891	0.6723	0.6518	0.6873	F18rep1	0.0673	0.0776	0.0588	-0.0641	F19rep23	0.3312	0.324	0.3108	0.3309
359	F20rep29	0.6888	0.67	0.6497	0.6863	F6rep8	0.0673	0.0655	0.0584	0.0672	F14rep20	0.3311	0.3253	0.3147	0.3308
360	F8rep23	0.6887	0.6798	0.6649	0.6883	F8rep1	0.0671	0.0707	0.0582	-0.1752	F2rep23	0.331	0.3269	0.3184	0.3309
361	F11rep3	0.687	0.6767	0.6623	0.6865	F7rep26	0.067	0.0717	0.0585	-0.098	F17rep9	0.3308	0.3118	0.2883	0.3295
362	F20rep22	0.6857	0.6639	0.6401	0.6815	F7rep25	0.0669	0.0691	0.0579	-0.2656	F2rep24	0.3307	0.3268	0.3185	0.3306
363	F12rep29	0.6839	0.6786	0.6669	0.6837	F15rep1	0.0668	0.0719	0.058	-0.1383	F17rep21	0.329	0.3213	0.3082	0.3287
364	F2rep27	0.6838	0.6744	0.66	0.6833	F14rep15	0.0666	0.0752	0.0587	-0.0728	F6rep24	0.3284	0.3224	0.3112	0.3282
365	F12rep27	0.6835	0.6698	0.6536	0.6828	F9rep11	0.0664	0.073	0.0582	-0.0785	F2rep11	0.3276	0.3239	0.3157	0.3275
366	F19rep4	0.6825	0.6648	0.6437	0.6803	F7rep20	0.0662	0.0716	0.0581	-0.0821	F7rep4	0.3272	0.3197	0.3066	0.3269
367	F12rep12	0.6813	0.675	0.6624	0.6811	F4rep17	0.0661	0.0645	0.0578	0.066	F8rep5	0.3263	0.3215	0.3121	0.3261
368	F17rep28	0.6809	0.6548	0.6245	0.6766	F17rep4	0.0656	0.0751	0.0573	-0.0641	F14rep6	0.3245	0.3044	0.2803	0.3229
369	F10rep10	0.6808	0.6647	0.6451	0.6783	F3rep21	0.0652	0.0621	0.0565	0.0651	F20rep5	0.3233	0.3046	0.2814	0.322
370	F4rep3	0.6807	0.6388	0.6009	0.6757	F1rep23	0.0651	0.0623	0.0569	0.065	F17rep27	0.323	0.3158	0.3035	0.3226
371	F16rep16	0.6805	0.6612	0.6375	0.6767	F13rep6	0.065	0.0702	0.0566	-0.1092	F11rep19	0.3229	0.2945	0.2654	0.3207
372	F6rep17	0.6792	0.6742	0.663	0.679	F20rep15	0.0649	0.0698	0.0561	-0.1462	F20rep16	0.3209	0.3086	0.2891	0.3203
373	F7rep14	0.6791	0.6539	0.6234	0.675	F4rep7	0.0642	0.0628	0.0565	0.0642	F6rep19	0.319	0.3122	0.2994	0.3187
374	F16rep8	0.6791	0.6277	0.5836	0.6726	F10rep30	0.0638	0.0701	0.0557	-0.0836	F8rep14	0.319	0.3155	0.3076	0.3189
375	F1rep16	0.6779	0.6613	0.6378	0.6759	F15rep8	0.0635	0.0718	0.0557	-0.0681	F1rep21	0.3183	0.3142	0.3058	0.3181
376	F15rep14	0.677	0.6675	0.6522	0.6765	F17rep3	0.0634	0.073	0.0555	-0.0606	F1rep11	0.3179	0.3084	0.2936	0.3173
377	F13rep17	0.6765	0.6632	0.6466	0.6754	F15rep22	0.0634	0.0713	0.0555	-0.0702	F20rep18	0.3171	0.3004	0.2786	0.316
378	F10rep6	0.6762	0.6183	0.5764	0.6699	F15rep14	0.0631	0.0712	0.0552	-0.0688	F17rep28	0.3165	0.2827	0.2531	0.3131
379	F3rep3	0.6758	0.6713	0.6604	0.6757	F10rep28	0.063	0.0702	0.0555	-0.071	F3rep16	0.3165	0.3127	0.3047	0.3164
380	F19rep28	0.6754	0.6365	0.6035	0.664	F5rep12	0.0628	0.0612	0.0546	0.0627	F5rep22	0.3154	0.2998	0.2789	0.3142
381	F5rep27	0.6749	0.6658	0.6502	0.6744	F11rep2	0.0625	0.0695	0.055	-0.0716	F1rep19	0.3152	0.3113	0.3032	0.3151
382	F3rep5	0.6747	0.6662	0.6519	0.6743	F9rep6	0.0624	0.0686	0.0547	-0.0735	F11rep20	0.3151	0.2866	0.258	0.3129
383	F12rep25	0.6741	0.6675	0.6551	0.6738	F8rep14	0.0623	0.0688	0.0548	-0.0713	F6rep11	0.3149	0.3114	0.3036	0.3148
384	F19rep16	0.6734	0.6681	0.6565	0.6732	F12rep24	0.0616	0.0665	0.0537	-0.1057	F5rep3	0.3147	0.311	0.3031	0.3146
385	F6rep20	0.6729	0.661	0.6447	0.6721	F17rep6	0.0616	0.0712	0.0541	-0.0582	F20rep3	0.3141	0.3097	0.3007	0.314

386	<i>F2rep20</i>	0.672	0.6474	0.6269	0.6665	<i>F10rep2</i>	0.0615	0.0684	0.0541	-0.0694	<i>F11rep16</i>	0.3141	0.3066	0.2942	0.3136
387	<i>F11rep22</i>	0.671	0.6643	0.652	0.6707	<i>F1rep6</i>	0.0615	0.0588	0.0535	0.0614	<i>F8rep18</i>	0.3141	0.3106	0.3028	0.314
388	<i>F16rep12</i>	0.6691	0.663	0.6505	0.6689	<i>F5rep6</i>	0.0611	0.0599	0.0534	0.0611	<i>F14rep22</i>	0.3125	0.3014	0.2829	0.312
389	<i>F12rep5</i>	0.6689	0.6555	0.6396	0.6682	<i>F19rep9</i>	0.0607	0.0706	0.0534	-0.0546	<i>F6rep14</i>	0.312	0.3084	0.3006	0.3119
390	<i>F20rep7</i>	0.6686	0.6518	0.6326	0.6666	<i>F14rep21</i>	0.0606	0.0683	0.0531	-0.0666	<i>F19rep5</i>	0.3115	0.3054	0.2946	0.3112
391	<i>F14rep6</i>	0.6683	0.6392	0.6096	0.6631	<i>F1rep20</i>	0.0605	0.0579	0.0527	0.0604	<i>F12rep4</i>	0.3112	0.2294	0.1909	0.2983
392	<i>F18rep2</i>	0.668	0.6626	0.6512	0.6678	<i>F16rep7</i>	0.0602	0.0658	0.0524	-0.0958	<i>F11rep17</i>	0.3106	0.3055	0.2953	0.3104
393	<i>F6rep7</i>	0.6679	0.6539	0.6349	0.6664	<i>F5rep21</i>	0.0599	0.0586	0.0523	0.0599	<i>F15rep26</i>	0.3105	0.2763	0.247	0.3068
394	<i>F18rep28</i>	0.6676	0.6621	0.6508	0.6675	<i>F16rep4</i>	0.0598	0.0655	0.0521	-0.0922	<i>F5rep14</i>	0.3099	0.306	0.2978	0.3098
395	<i>F7rep28</i>	0.6676	0.6516	0.632	0.6659	<i>F1rep30</i>	0.0593	0.0569	0.052	0.0592	<i>F6rep17</i>	0.3096	0.3054	0.2972	0.3095
396	<i>F3rep19</i>	0.6673	0.6632	0.6527	0.6672	<i>F6rep7</i>	0.0584	0.0568	0.0507	0.0584	<i>F11rep28</i>	0.3069	0.2805	0.2527	0.3048
397	<i>F14rep15</i>	0.6672	0.6521	0.6333	0.665	<i>F17rep23</i>	0.0581	0.067	0.0509	-0.055	<i>F14rep18</i>	0.3068	0.2976	0.2833	0.3062
398	<i>F4rep22</i>	0.6665	0.639	0.6094	0.6619	<i>F8rep15</i>	0.0579	0.0638	0.0508	-0.0669	<i>F18rep24</i>	0.3061	0.2903	0.2697	0.305
399	<i>F4rep17</i>	0.6662	0.6078	0.5631	0.6582	<i>F12rep21</i>	0.0578	0.0615	0.0502	-0.1357	<i>F6rep29</i>	0.3052	0.3014	0.2934	0.3051
400	<i>F18rep16</i>	0.6647	0.6509	0.632	0.6633	<i>F13rep18</i>	0.0575	0.064	0.0506	-0.0646	<i>F5rep19</i>	0.3046	0.2901	0.27	0.3036
401	<i>F4rep19</i>	0.6638	0.6518	0.6365	0.6631	<i>F7rep13</i>	0.0572	0.0618	0.05	-0.0713	<i>F19rep2</i>	0.3043	0.2975	0.2854	0.304
402	<i>F12rep26</i>	0.6638	0.6504	0.6315	0.6625	<i>F8rep16</i>	0.0572	0.0599	0.0495	-0.1778	<i>F18rep27</i>	0.3041	0.3006	0.2929	0.304
403	<i>F10rep23</i>	0.6636	0.6443	0.6246	0.6609	<i>F1rep15</i>	0.0571	0.0541	0.0491	0.057	<i>F2rep1</i>	0.3039	0.3004	0.2927	0.3038
404	<i>F10rep7</i>	0.6636	0.6559	0.6418	0.6631	<i>F14rep9</i>	0.0569	0.0642	0.05	-0.0613	<i>F18rep9</i>	0.3038	0.2967	0.2845	0.3035
405	<i>F17rep18</i>	0.6636	0.6514	0.6323	0.6621	<i>F8rep19</i>	0.0568	0.0625	0.0497	-0.0663	<i>F2rep5</i>	0.3023	0.2986	0.291	0.3021
406	<i>F12rep8</i>	0.6632	0.6544	0.6403	0.6628	<i>F2rep7</i>	0.0567	0.0547	0.0503	0.0566	<i>F1rep23</i>	0.302	0.2969	0.2872	0.3018
407	<i>F7rep17</i>	0.663	0.591	0.5473	0.6505	<i>F10rep17</i>	0.0565	0.063	0.0498	-0.0635	<i>F13rep19</i>	0.3009	0.2521	0.2129	0.2956
408	<i>F3rep13</i>	0.6627	0.6584	0.6479	0.6626	<i>F15rep17</i>	0.0558	0.0629	0.0488	-0.061	<i>F2rep13</i>	0.3008	0.2958	0.2861	0.3006
409	<i>F2rep24</i>	0.6602	0.6499	0.6337	0.6596	<i>F8rep6</i>	0.0557	0.0603	0.0485	-0.0796	<i>F10rep18</i>	0.3008	0.2968	0.2883	0.3007
410	<i>F1rep17</i>	0.6598	0.6496	0.6336	0.6592	<i>F11rep13</i>	0.0556	0.0621	0.0492	-0.0626	<i>F17rep18</i>	0.3007	0.2866	0.2667	0.2997
411	<i>F8rep27</i>	0.6594	0.6419	0.6235	0.6581	<i>F4rep8</i>	0.0556	0.0543	0.0488	0.0555	<i>F15rep7</i>	0.2993	0.2806	0.255	0.2982
412	<i>F1rep10</i>	0.6576	0.6395	0.6194	0.6552	<i>F16rep12</i>	0.0555	0.0625	0.0486	-0.0611	<i>F14rep27</i>	0.2958	0.2832	0.2647	0.295
413	<i>F6rep29</i>	0.6574	0.6525	0.6416	0.6572	<i>F19rep30</i>	0.0552	0.0643	0.0486	-0.0493	<i>F2rep6</i>	0.2946	0.2857	0.2697	0.2942
414	<i>F17rep30</i>	0.656	0.6229	0.5916	0.6491	<i>F9rep14</i>	0.0552	0.0605	0.0482	-0.0656	<i>F15rep10</i>	0.2938	0.2816	0.2635	0.2931
415	<i>F15rep25</i>	0.6557	0.6171	0.5901	0.6431	<i>F19rep23</i>	0.0551	0.064	0.0483	-0.0499	<i>F6rep28</i>	0.2935	0.2901	0.2827	0.2934
416	<i>F3rep28</i>	0.6557	0.6516	0.6411	0.6556	<i>F14rep16</i>	0.0539	0.0608	0.0472	-0.0581	<i>F20rep23</i>	0.2928	0.2679	0.2415	0.291
417	<i>F17rep20</i>	0.6553	0.6171	0.5833	0.648	<i>F20rep26</i>	0.0537	0.0624	0.047	-0.0488	<i>F15rep23</i>	0.2916	0.2882	0.2806	0.2915
418	<i>F10rep15</i>	0.6552	0.6493	0.6367	0.655	<i>F17rep27</i>	0.0536	0.0622	0.0473	-0.05	<i>F11rep7</i>	0.2915	0.2867	0.2772	0.2913
419	<i>F2rep18</i>	0.6551	0.6105	0.574	0.6485	<i>F12rep8</i>	0.0536	0.0579	0.0466	-0.0909	<i>F11rep24</i>	0.2911	0.263	0.2364	0.2882
420	<i>F11rep13</i>	0.6545	0.6455	0.6315	0.654	<i>F7rep7</i>	0.0534	0.0577	0.0468	-0.0664	<i>F6rep26</i>	0.2902	0.2869	0.2795	0.2901
421	<i>F20rep10</i>	0.6544	0.6495	0.6385	0.6542	<i>F16rep27</i>	0.0534	0.0588	0.0465	-0.0756	<i>F10rep25</i>	0.289	0.2706	0.2459	0.288
422	<i>F3rep10</i>	0.6542	0.6502	0.6399	0.6541	<i>F20rep19</i>	0.0533	0.0621	0.0469	-0.0477	<i>F20rep19</i>	0.2883	0.2812	0.2694	0.2879
423	<i>F15rep21</i>	0.6535	0.6347	0.6153	0.6517	<i>F12rep16</i>	0.053	0.0591	0.0467	-0.0597	<i>F18rep17</i>	0.2866	0.2759	0.2587	0.2861
424	<i>F4rep18</i>	0.6527	0.6383	0.6227	0.6518	<i>F3rep11</i>	0.0528	0.0506	0.0462	0.0528	<i>F15rep17</i>	0.2865	0.2746	0.257	0.2858

425	F17rep16	0.6526	0.6461	0.6341	0.6523	F9rep22	0.0526	0.0576	0.046	-0.0628	F6rep1	0.2859	0.2821	0.2741	0.2858
426	F15rep27	0.6516	0.6154	0.5775	0.6458	F15rep19	0.052	0.0591	0.0459	-0.055	F19rep17	0.2858	0.2768	0.2611	0.2854
427	F5rep19	0.6515	0.6432	0.6299	0.6511	F20rep13	0.0518	0.0602	0.0455	-0.0466	F3rep8	0.2851	0.2799	0.2701	0.2849
428	F3rep9	0.6514	0.6431	0.6294	0.651	F10rep5	0.0514	0.0572	0.0453	-0.058	F19rep27	0.2825	0.2709	0.2535	0.2818
429	F8rep17	0.6508	0.637	0.6216	0.6499	F4rep21	0.0512	0.05	0.0449	0.0511	F18rep11	0.2824	0.2704	0.2528	0.2816
430	F11rep18	0.6505	0.6169	0.5901	0.6437	F16rep23	0.0506	0.055	0.044	-0.087	F6rep10	0.2821	0.2785	0.2706	0.282
431	F11rep26	0.6505	0.6277	0.6085	0.6447	F18rep29	0.0506	0.059	0.0446	-0.0449	F18rep5	0.2816	0.2784	0.2713	0.2815
432	F3rep8	0.6501	0.6461	0.636	0.65	F2rep29	0.0504	0.0483	0.0441	0.0504	F7rep11	0.2814	0.2627	0.2386	0.2804
433	F10rep22	0.6486	0.6279	0.6083	0.6451	F11rep23	0.0503	0.056	0.0442	-0.0565	F20rep14	0.2813	0.2738	0.2616	0.2809
434	F19rep18	0.6486	0.633	0.6141	0.6469	F13rep1	0.0502	0.0541	0.0437	-0.0895	F11rep30	0.2812	0.2755	0.2644	0.281
435	F11rep15	0.6485	0.642	0.6286	0.6482	F12rep10	0.0496	0.0551	0.0434	-0.0564	F19rep11	0.2809	0.2777	0.2706	0.2808
436	F19rep22	0.6484	0.6434	0.6321	0.6482	F8rep11	0.0494	0.0547	0.0435	-0.056	F17rep3	0.28	0.277	0.2701	0.2799
437	F16rep7	0.6481	0.6272	0.5966	0.6455	F12rep14	0.0493	0.0529	0.0428	-0.0948	F6rep9	0.28	0.2766	0.2693	0.2798
438	F3rep16	0.6477	0.6439	0.6338	0.6476	F11rep8	0.049	0.0547	0.0432	-0.0549	F13rep27	0.2788	0.234	0.2047	0.2732
439	F5rep20	0.6474	0.6384	0.6236	0.6469	F20rep12	0.0487	0.0568	0.0429	-0.0434	F11rep21	0.2788	0.2586	0.2341	0.2776
440	F20rep5	0.6469	0.6226	0.6003	0.6433	F11rep22	0.0484	0.0541	0.0427	-0.054	F3rep2	0.2787	0.2759	0.2691	0.2786
441	F13rep13	0.6454	0.6244	0.594	0.6425	F8rep2	0.0482	0.0532	0.0423	-0.0552	F12rep7	0.2769	0.2704	0.2594	0.2766
442	F6rep25	0.6448	0.6405	0.6302	0.6447	F5rep24	0.0478	0.047	0.0419	0.0478	F15rep13	0.2768	0.2708	0.2597	0.2765
443	F10rep14	0.644	0.6269	0.608	0.6418	F7rep30	0.0473	0.0512	0.0415	-0.0585	F4rep14	0.2749	0.2689	0.2579	0.2746
444	F7rep29	0.6437	0.5784	0.5397	0.6293	F15rep18	0.047	0.0534	0.0415	-0.0494	F14rep1	0.2743	0.2534	0.2295	0.2729
445	F17rep14	0.6435	0.6284	0.6101	0.641	F11rep28	0.0458	0.051	0.0403	-0.0513	F18rep23	0.274	0.2579	0.2355	0.2733
446	F16rep19	0.6434	0.6346	0.6211	0.643	F1rep12	0.0457	0.0439	0.0401	0.0456	F14rep29	0.2737	0.2646	0.2491	0.2733
447	F2rep5	0.6418	0.6226	0.6028	0.6399	F20rep18	0.0452	0.0528	0.0399	-0.0401	F13rep9	0.2726	0.2575	0.2358	0.2719
448	F2rep3	0.6416	0.6336	0.6193	0.6412	F10rep11	0.0452	0.0503	0.0398	-0.0507	F6rep13	0.2723	0.2684	0.2606	0.2722
449	F6rep15	0.6411	0.6373	0.6277	0.641	F4rep28	0.045	0.044	0.0396	0.0449	F12rep8	0.2721	0.2486	0.224	0.2703
450	F8rep22	0.6404	0.6329	0.6197	0.64	F5rep13	0.0447	0.044	0.0393	0.0447	F20rep10	0.2711	0.2617	0.246	0.2707
451	F16rep24	0.6392	0.609	0.5717	0.6357	F6rep23	0.0446	0.0439	0.0393	0.0446	F11rep27	0.2711	0.2547	0.2321	0.2701
452	F10rep5	0.6385	0.6045	0.5777	0.6298	F1rep17	0.0444	0.0426	0.0389	0.0443	F17rep15	0.2707	0.2642	0.2531	0.2704
453	F3rep11	0.6378	0.6318	0.62	0.6375	F7rep15	0.0443	0.048	0.039	-0.0542	F19rep9	0.2707	0.2502	0.2265	0.2693
454	F3rep17	0.6369	0.6321	0.6214	0.6368	F16rep8	0.0442	0.0499	0.0386	-0.0474	F18rep7	0.2706	0.2623	0.2476	0.2703
455	F19rep30	0.6364	0.6322	0.6219	0.6363	F15rep5	0.0441	0.0501	0.039	-0.0466	F3rep3	0.27	0.2528	0.2297	0.2691
456	F1rep25	0.6354	0.6141	0.5949	0.631	F2rep15	0.044	0.0423	0.0388	0.0439	F11rep26	0.2687	0.2629	0.2522	0.2685
457	F3rep22	0.6346	0.6298	0.6191	0.6345	F1rep13	0.0439	0.0421	0.0385	0.0439	F15rep9	0.2676	0.2491	0.2259	0.2665
458	F6rep26	0.6334	0.6283	0.6175	0.6332	F20rep11	0.0439	0.0513	0.0388	-0.0388	F13rep7	0.2672	0.2242	0.189	0.2628
459	F15rep19	0.6333	0.6133	0.5943	0.6299	F11rep6	0.0438	0.049	0.0387	-0.0487	F5rep17	0.2669	0.2636	0.2568	0.2668
460	F7rep13	0.6332	0.5731	0.5371	0.6207	F4rep23	0.0437	0.0428	0.0385	0.0437	F18rep1	0.2651	0.2505	0.2293	0.2644
461	F13rep28	0.6329	0.6166	0.5969	0.6308	F18rep11	0.0436	0.0509	0.0385	-0.0388	F15rep15	0.2643	0.2458	0.2228	0.2632
462	F17rep19	0.6328	0.6218	0.6074	0.6322	F18rep2	0.0425	0.0497	0.0376	-0.0376	F15rep2	0.2642	0.2585	0.248	0.264
463	F10rep19	0.6321	0.6109	0.5824	0.6295	F5rep4	0.0424	0.0418	0.0374	0.0424	F17rep26	0.2639	0.2544	0.239	0.2635

464	<i>F16rep6</i>	0.6301	0.6083	0.5791	0.6265	<i>F12rep1</i>	0.0424	0.0474	0.0374	-0.0473	<i>F17rep30</i>	0.2626	0.2576	0.2485	0.2624
465	<i>F3rep23</i>	0.63	0.6257	0.6154	0.6299	<i>F17rep7</i>	0.0424	0.0491	0.0374	-0.0398	<i>F17rep25</i>	0.2625	0.2576	0.2487	0.2623
466	<i>F1rep27</i>	0.6291	0.6133	0.5949	0.6273	<i>F2rep18</i>	0.0424	0.0407	0.0374	0.0423	<i>F3rep21</i>	0.2609	0.258	0.2514	0.2608
467	<i>F10rep8</i>	0.6287	0.624	0.6131	0.6286	<i>F10rep24</i>	0.0424	0.0472	0.0373	-0.0475	<i>F19rep7</i>	0.2609	0.255	0.2445	0.2607
468	<i>F8rep18</i>	0.6287	0.6071	0.5882	0.6234	<i>F17rep30</i>	0.0423	0.0491	0.0374	-0.0394	<i>F11rep8</i>	0.2606	0.2167	0.1902	0.2533
469	<i>F17rep4</i>	0.6284	0.6081	0.588	0.6261	<i>F1rep8</i>	0.0421	0.0405	0.0371	0.0421	<i>F11rep22</i>	0.2604	0.2442	0.2221	0.2595
470	<i>F17rep1</i>	0.6264	0.5672	0.5315	0.6148	<i>F18rep9</i>	0.042	0.0491	0.0372	-0.037	<i>F11rep9</i>	0.2597	0.2179	0.1907	0.2544
471	<i>F12rep13</i>	0.6256	0.6101	0.5916	0.6231	<i>F6rep11</i>	0.0406	0.0399	0.0356	0.0406	<i>F17rep19</i>	0.2597	0.2441	0.2228	0.2588
472	<i>F7rep16</i>	0.6247	0.616	0.6018	0.6242	<i>F2rep24</i>	0.0397	0.0383	0.0351	0.0397	<i>F14rep7</i>	0.2591	0.2538	0.2435	0.2589
473	<i>F16rep27</i>	0.6236	0.6116	0.597	0.6228	<i>F11rep30</i>	0.0392	0.0439	0.0347	-0.0433	<i>F20rep7</i>	0.259	0.2427	0.2207	0.2581
474	<i>F2rep4</i>	0.6224	0.6038	0.5853	0.6194	<i>F5rep23</i>	0.0392	0.0386	0.0346	0.0392	<i>F13rep21</i>	0.2583	0.2406	0.2183	0.2572
475	<i>F19rep24</i>	0.6219	0.6143	0.6009	0.6214	<i>F5rep5</i>	0.0391	0.0385	0.0345	0.0391	<i>F11rep13</i>	0.2583	0.2555	0.2492	0.2582
476	<i>F13rep20</i>	0.6206	0.6058	0.5898	0.6196	<i>F3rep14</i>	0.0387	0.0371	0.034	0.0386	<i>F8rep4</i>	0.2577	0.2519	0.2416	0.2574
477	<i>F3rep14</i>	0.6188	0.6141	0.6037	0.6187	<i>F2rep20</i>	0.0379	0.0364	0.0333	0.0379	<i>F15rep11</i>	0.2568	0.2486	0.2344	0.2565
478	<i>F5rep1</i>	0.6182	0.6019	0.5836	0.616	<i>F18rep18</i>	0.0379	0.0443	0.0336	-0.0338	<i>F20rep22</i>	0.2567	0.2484	0.2341	0.2564
479	<i>F10rep29</i>	0.6176	0.6045	0.5865	0.6167	<i>F9rep7</i>	0.0377	0.0417	0.0333	-0.0432	<i>F16rep18</i>	0.2566	0.2515	0.2418	0.2564
480	<i>F4rep9</i>	0.6175	0.607	0.593	0.6169	<i>F3rep13</i>	0.0371	0.0356	0.0325	0.0371	<i>F11rep2</i>	0.2561	0.2477	0.2332	0.2558
481	<i>F11rep17</i>	0.6164	0.6082	0.5951	0.6161	<i>F5rep19</i>	0.0371	0.0367	0.033	0.0371	<i>F18rep30</i>	0.2556	0.2524	0.2455	0.2555
482	<i>F1rep8</i>	0.6164	0.5422	0.5034	0.6051	<i>F1rep25</i>	0.0367	0.0353	0.0324	0.0367	<i>F1rep28</i>	0.2556	0.252	0.2446	0.2555
483	<i>F20rep4</i>	0.616	0.6036	0.5864	0.6151	<i>F5rep1</i>	0.0366	0.0361	0.0324	0.0366	<i>F19rep6</i>	0.255	0.2494	0.2392	0.2548
484	<i>F18rep18</i>	0.6155	0.6108	0.6002	0.6153	<i>F16rep14</i>	0.0365	0.0414	0.0322	-0.0385	<i>F3rep5</i>	0.2547	0.2506	0.2423	0.2546
485	<i>F17rep5</i>	0.615	0.5517	0.515	0.6047	<i>F19rep14</i>	0.0365	0.0427	0.0323	-0.0321	<i>F14rep28</i>	0.2547	0.2494	0.2393	0.2545
486	<i>F18rep29</i>	0.6148	0.6086	0.5973	0.6145	<i>F12rep9</i>	0.0364	0.0407	0.0322	-0.0404	<i>F3rep20</i>	0.2526	0.2498	0.2434	0.2525
487	<i>F7rep19</i>	0.6141	0.604	0.5885	0.6135	<i>F8rep22</i>	0.0359	0.0397	0.0317	-0.0405	<i>F6rep15</i>	0.2524	0.2497	0.2435	0.2524
488	<i>F17rep27</i>	0.6133	0.5925	0.574	0.6087	<i>F15rep28</i>	0.0358	0.0408	0.0317	-0.0375	<i>F16rep21</i>	0.2521	0.2121	0.1786	0.2481
489	<i>F8rep12</i>	0.6131	0.6044	0.5903	0.6126	<i>F1rep22</i>	0.0358	0.0345	0.0317	0.0358	<i>F17rep29</i>	0.2515	0.2372	0.217	0.2508
490	<i>F14rep23</i>	0.6129	0.5995	0.5833	0.6117	<i>F6rep21</i>	0.0354	0.0349	0.0312	0.0354	<i>F19rep12</i>	0.2511	0.2467	0.2383	0.2509
491	<i>F1rep19</i>	0.6126	0.6081	0.5979	0.6124	<i>F1rep3</i>	0.0343	0.033	0.0303	0.0343	<i>F20rep9</i>	0.2499	0.2443	0.2343	0.2496
492	<i>F1rep29</i>	0.6108	0.5971	0.5794	0.6088	<i>F2rep11</i>	0.0338	0.0325	0.0299	0.0337	<i>F17rep5</i>	0.2497	0.2426	0.2294	0.2495
493	<i>F17rep11</i>	0.6102	0.598	0.5815	0.6085	<i>F3rep25</i>	0.0335	0.0323	0.0296	0.0335	<i>F11rep25</i>	0.2495	0.2437	0.2337	0.2492
494	<i>F14rep13</i>	0.6095	0.586	0.5624	0.6051	<i>F18rep13</i>	0.0333	0.039	0.0295	-0.0295	<i>F15rep6</i>	0.2478	0.2428	0.2332	0.2476
495	<i>F7rep26</i>	0.6078	0.5598	0.5187	0.6023	<i>F6rep2</i>	0.0332	0.0328	0.0294	0.0332	<i>F12rep20</i>	0.2472	0.208	0.1751	0.2433
496	<i>F16rep20</i>	0.6076	0.6038	0.5941	0.6075	<i>F16rep13</i>	0.0331	0.0376	0.0293	-0.0348	<i>F6rep12</i>	0.247	0.243	0.2349	0.2468
497	<i>F16rep1</i>	0.6073	0.5951	0.5807	0.6066	<i>F2rep4</i>	0.0328	0.0316	0.029	0.0328	<i>F6rep22</i>	0.2469	0.242	0.2324	0.2468
498	<i>F18rep8</i>	0.6059	0.5959	0.5813	0.6053	<i>F3rep8</i>	0.0317	0.0305	0.0279	0.0316	<i>F15rep24</i>	0.2459	0.2391	0.2265	0.2457
499	<i>F4rep16</i>	0.6056	0.5574	0.5231	0.5948	<i>F2rep13</i>	0.0315	0.0303	0.0279	0.0314	<i>F13rep18</i>	0.2452	0.2314	0.2117	0.2447
500	<i>F2rep28</i>	0.6053	0.6007	0.5903	0.6051	<i>F3rep19</i>	0.0308	0.0297	0.0273	0.0308	<i>F15rep12</i>	0.2447	0.229	0.2082	0.2438
501	<i>F5rep2</i>	0.6051	0.5884	0.5702	0.6029	<i>F16rep17</i>	0.0308	0.0351	0.0273	-0.0321	<i>F2rep7</i>	0.244	0.2393	0.23	0.2438
502	<i>F6rep21</i>	0.6043	0.5922	0.5749	0.6032	<i>F2rep26</i>	0.0306	0.0295	0.0271	0.0305	<i>F3rep6</i>	0.2437	0.2406	0.234	0.2436

503	<i>F12rep15</i>	0.6039	0.5915	0.5772	0.6031	<i>F6rep4</i>	0.0305	0.0301	0.027	0.0305	<i>F16rep27</i>	0.2437	0.2365	0.2235	0.2434
504	<i>F1rep6</i>	0.6034	0.5809	0.5544	0.6002	<i>F6rep18</i>	0.0305	0.03	0.0269	0.0304	<i>F8rep19</i>	0.2435	0.237	0.2245	0.2433
505	<i>F18rep30</i>	0.6013	0.5953	0.5843	0.6011	<i>F3rep12</i>	0.0303	0.0292	0.0268	0.0302	<i>F15rep5</i>	0.239	0.2357	0.2288	0.2389
506	<i>F5rep26</i>	0.6012	0.5901	0.5743	0.6003	<i>F12rep5</i>	0.0299	0.0335	0.0265	-0.0328	<i>F17rep23</i>	0.2389	0.2343	0.2251	0.2387
507	<i>F16rep11</i>	0.601	0.5954	0.5843	0.6008	<i>F16rep28</i>	0.0299	0.034	0.0265	-0.0312	<i>F2rep29</i>	0.2388	0.235	0.2273	0.2386
508	<i>F13rep23</i>	0.6	0.5769	0.5544	0.595	<i>F2rep2</i>	0.0295	0.0284	0.0261	0.0295	<i>F13rep22</i>	0.2385	0.2245	0.205	0.2378
509	<i>F10rep16</i>	0.5993	0.5862	0.568	0.598	<i>F6rep17</i>	0.0293	0.029	0.0259	0.0293	<i>F15rep3</i>	0.2378	0.2243	0.2051	0.2372
510	<i>F1rep23</i>	0.5987	0.5859	0.5686	0.5978	<i>F16rep6</i>	0.0286	0	0.0255	-0.029	<i>F11rep1</i>	0.2368	0.2294	0.2165	0.2365
511	<i>F17rep7</i>	0.5973	0.5834	0.5662	0.595	<i>F8rep4</i>	0.0286	0.0318	0.0254	-0.0318	<i>F6rep6</i>	0.2356	0.2332	0.2275	0.2355
512	<i>F11rep14</i>	0.5968	0.5811	0.5635	0.5951	<i>F6rep20</i>	0.0284	0.0281	0.0253	0.0284	<i>F12rep23</i>	0.2348	0.2283	0.2162	0.2346
513	<i>F7rep8</i>	0.5961	0.5806	0.5624	0.5941	<i>F18rep10</i>	0.0282	0.033	0.025	-0.0249	<i>F13rep8</i>	0.2347	0.1984	0.173	0.2307
514	<i>F18rep6</i>	0.5956	0.5881	0.5755	0.5953	<i>F7rep21</i>	0.0281	0.0306	0.025	-0.034	<i>F18rep13</i>	0.2337	0.1967	0.1721	0.2295
515	<i>F13rep4</i>	0.5955	0.5895	0.5786	0.5952	<i>F16rep1</i>	0.0281	0.032	0.0249	-0.0293	<i>F14rep9</i>	0.2333	0.2285	0.2195	0.2331
516	<i>F16rep9</i>	0.5953	0.5878	0.5752	0.595	<i>F20rep7</i>	0.028	0.0329	0.0248	-0.0246	<i>F16rep22</i>	0.233	0.2213	0.2033	0.2325
517	<i>F20rep26</i>	0.5948	0.5662	0.5443	0.5879	<i>F15rep13</i>	0.0279	0.0317	0.0247	-0.0291	<i>F16rep3</i>	0.232	0.2251	0.2126	0.2318
518	<i>F3rep18</i>	0.5945	0.5907	0.5814	0.5944	<i>F2rep22</i>	0.0278	0.0268	0.0246	0.0278	<i>F16rep4</i>	0.2317	0.2188	0.2005	0.2311
519	<i>F12rep4</i>	0.594	0.5862	0.5735	0.5937	<i>F3rep20</i>	0.0278	0.0268	0.0246	0.0278	<i>F3rep30</i>	0.2313	0.2199	0.202	0.2308
520	<i>F10rep1</i>	0.5935	0.5851	0.5716	0.5931	<i>F12rep25</i>	0.0276	0.0309	0.0245	-0.0301	<i>F13rep5</i>	0.2311	0.2246	0.2127	0.2309
521	<i>F5rep25</i>	0.5913	0.5779	0.5616	0.5899	<i>F3rep3</i>	0.0275	0.0265	0.0243	0.0275	<i>F11rep29</i>	0.2281	0.2161	0.1982	0.2275
522	<i>F2rep26</i>	0.5912	0.5797	0.5639	0.5897	<i>F6rep10</i>	0.0274	0.0271	0.0243	0.0274	<i>F15rep4</i>	0.2271	0.214	0.1956	0.2264
523	<i>F16rep10</i>	0.5891	0.5851	0.5757	0.5889	<i>F16rep11</i>	0.0273	0.0312	0.0243	-0.0284	<i>F16rep10</i>	0.225	0.2189	0.2075	0.2248
524	<i>F1rep1</i>	0.5889	0.5838	0.5729	0.5887	<i>F3rep23</i>	0.027	0.0261	0.024	0.027	<i>F17rep4</i>	0.2249	0.2187	0.2072	0.2247
525	<i>F18rep26</i>	0.5878	0.5812	0.5702	0.5875	<i>F16rep29</i>	0.0267	0.0305	0.0238	-0.0277	<i>F19rep26</i>	0.2242	0.2181	0.2066	0.224
526	<i>F12rep6</i>	0.5875	0.579	0.5668	0.5871	<i>F2rep3</i>	0.0267	0.0257	0.0236	0.0266	<i>F6rep20</i>	0.2239	0.2215	0.2158	0.2239
527	<i>F4rep4</i>	0.5864	0.5803	0.5677	0.5862	<i>F16rep20</i>	0.0264	0.03	0.0234	-0.0275	<i>F13rep30</i>	0.2231	0.1883	0.1581	0.2199
528	<i>F19rep2</i>	0.5861	0.5692	0.5515	0.5832	<i>F11rep11</i>	0.0264	0.0295	0.0233	-0.0292	<i>F15rep27</i>	0.2224	0.2117	0.1945	0.222
529	<i>F10rep20</i>	0.5843	0.5737	0.5573	0.583	<i>F12rep27</i>	0.0262	0	0.0234	-0.0275	<i>F14rep3</i>	0.2211	0.218	0.2117	0.221
530	<i>F10rep13</i>	0.5748	0.5683	0.5555	0.5744	<i>F2rep23</i>	0.0262	0.0252	0.0231	0.0261	<i>F18rep20</i>	0.2201	0.2135	0.2017	0.2198
531	<i>F13rep7</i>	0.5688	0.5545	0.5394	0.5677	<i>F16rep2</i>	0.0254	0	0.0226	-0.0253	<i>F13rep17</i>	0.2196	0.209	0.192	0.2192
532	<i>F7rep7</i>	0.5686	0.563	0.5519	0.5683	<i>F17rep18</i>	0.0252	0.0294	0.0224	-0.0231	<i>F16rep15</i>	0.2184	0.2077	0.1908	0.2179
533	<i>F15rep7</i>	0.5684	0.5523	0.5326	0.5652	<i>F18rep12</i>	0.0252	0.0295	0.0224	-0.022	<i>F16rep24</i>	0.2176	0.2133	0.205	0.2174
534	<i>F15rep24</i>	0.5631	0.5409	0.5166	0.5596	<i>F16rep3</i>	0.0244	0.0278	0.0216	-0.0255	<i>F13rep14</i>	0.2149	0.2092	0.1984	0.2147
535	<i>F14rep25</i>	0.5625	0.54	0.5184	0.5576	<i>F9rep29</i>	0.0242	0	0.0215	-0.026	<i>F19rep1</i>	0.2144	0.2032	0.1863	0.2139
536	<i>F12rep20</i>	0.5624	0.5532	0.5408	0.5619	<i>F12rep7</i>	0.024	0	0.0214	-0.0257	<i>F11rep12</i>	0.2132	0.2022	0.1854	0.2127
537	<i>F2rep25</i>	0.5604	0.5417	0.5151	0.558	<i>F2rep27</i>	0.024	0.0232	0.0213	0.024	<i>F3rep7</i>	0.2129	0.2088	0.2007	0.2128
538	<i>F14rep20</i>	0.5595	0.5389	0.516	0.5562	<i>F6rep16</i>	0.024	0.0237	0.0213	0.024	<i>F16rep7</i>	0.2117	0.2057	0.1948	0.2115
539	<i>F1rep15</i>	0.5588	0.5439	0.5268	0.557	<i>F2rep17</i>	0.024	0.0231	0.0213	0.024	<i>F17rep6</i>	0.2115	0.2006	0.1839	0.211
540	<i>F10rep10</i>	0.5582	0.5538	0.5442	0.558	<i>F6rep25</i>	0.0239	0.0236	0.0212	0.0239	<i>F16rep5</i>	0.2105	0.2064	0.1983	0.2103
541	<i>F4rep21</i>	0.5573	0.5454	0.5294	0.556	<i>F2rep9</i>	0.0238	0.023	0.0212	0.0238	<i>F6rep3</i>	0.2098	0.2043	0.1941	0.2096



542	<i>F12rep9</i>	0.5573	0.553	0.5434	0.5572	<i>F12rep20</i>	0.0237	0.0265	0.021	-0.0261	<i>F13rep3</i>	0.2095	0.1998	0.1835	0.2091
543	<i>F18rep22</i>	0.5543	0.5424	0.5267	0.5528	<i>F12rep13</i>	0.0236	0	0.021	-0.0253	<i>F13rep25</i>	0.2095	0.1797	0.1556	0.2069
544	<i>F15rep12</i>	0.5531	0.5386	0.5199	0.5511	<i>F2rep28</i>	0.0236	0.0228	0.0209	0.0236	<i>F16rep6</i>	0.2075	0.202	0.1919	0.2073
545	<i>F6rep4</i>	0.5528	0.547	0.5368	0.5525	<i>F13rep8</i>	0.0236	0.0264	0.0209	-0.0259	<i>F12rep25</i>	0.2063	0.1744	0.1464	0.2035
546	<i>F20rep20</i>	0.5509	0.5269	0.5018	0.547	<i>F6rep27</i>	0.0234	0.0231	0.0208	0.0234	<i>F13rep6</i>	0.2054	0.2021	0.1954	0.2053
547	<i>F13rep3</i>	0.55	0.546	0.5368	0.5499	<i>F6rep3</i>	0.0233	0.0231	0.0207	0.0233	<i>F13rep15</i>	0.2032	0.1726	0.1503	0.2002
548	<i>F10rep17</i>	0.5492	0.5269	0.5086	0.5445	<i>F14rep13</i>	0.0232	0	0.0206	-0.0232	<i>F18rep8</i>	0.2021	0.1919	0.1762	0.2017
549	<i>F2rep1</i>	0.5486	0.5344	0.5186	0.5469	<i>F12rep3</i>	0.023	0	0.0204	-0.0245	<i>F3rep23</i>	0.1995	0.1974	0.1926	0.1994
550	<i>F15rep16</i>	0.5485	0.5415	0.5302	0.5481	<i>F15rep15</i>	0.0229	0	0.0204	-0.0234	<i>F13rep4</i>	0.1992	0.1685	0.1469	0.196
551	<i>F6rep27</i>	0.5473	0.5441	0.5359	0.5472	<i>F3rep15</i>	0.0229	0.0221	0.0203	0.0228	<i>F12rep12</i>	0.1968	0.1916	0.1821	0.1966
552	<i>F15rep17</i>	0.5468	0.5426	0.5332	0.5467	<i>F12rep29</i>	0.0229	0	0.0203	-0.0244	<i>F12rep16</i>	0.1967	0.1876	0.1724	0.1964
553	<i>F7rep5</i>	0.5437	0.5266	0.5104	0.5404	<i>F13rep9</i>	0.0226	0	0.0201	-0.0228	<i>F12rep9</i>	0.1952	0.1901	0.1806	0.195
554	<i>F20rep6</i>	0.543	0.5384	0.5292	0.5428	<i>F10rep9</i>	0.0224	0	0.02	-0.0238	<i>F13rep29</i>	0.1948	0.1666	0.1447	0.1921
555	<i>F7rep9</i>	0.5418	0.5318	0.517	0.5411	<i>F13rep26</i>	0.0222	0	0.0198	-0.0224	<i>F13rep12</i>	0.1895	0.1809	0.1663	0.1892
556	<i>F10rep9</i>	0.5398	0.5255	0.5031	0.538	<i>F6rep12</i>	0.0222	0.0219	0.0197	0.0222	<i>F12rep27</i>	0.188	0.183	0.1738	0.1878
557	<i>F10rep2</i>	0.539	0.5311	0.5199	0.5386	<i>F12rep4</i>	0.0218	0	0.0194	-0.0229	<i>F12rep21</i>	0.1876	0.1791	0.1647	0.1873
558	<i>F15rep18</i>	0.534	0.5227	0.5081	0.5329	<i>F3rep18</i>	0.0217	0.021	0.0193	0.0217	<i>F12rep15</i>	0.1845	0.1758	0.1615	0.1841
559	<i>F10rep27</i>	0.5336	0.5233	0.5093	0.5324	<i>F12rep22</i>	0.0216	0	0.0192	-0.0228	<i>F13rep28</i>	0.1839	0.1753	0.1611	0.1835
560	<i>F1rep9</i>	0.5325	0.5161	0.4918	0.5305	<i>F12rep23</i>	0.0208	0	0.0186	-0.0216	<i>F12rep30</i>	0.1829	0.178	0.1688	0.1827
561	<i>F13rep5</i>	0.5316	0.4709	0.4404	0.5131	<i>F16rep24</i>	0.0202	0	0.018	-0.0201	<i>F16rep16</i>	0.1796	0.1546	0.1337	0.1777
562	<i>F14rep2</i>	0.5314	0.5272	0.518	0.5313	<i>F12rep17</i>	0.0198	0	0.0176	-0.0205	<i>F12rep28</i>	0.1796	0.1776	0.1729	0.1796
563	<i>F2rep23</i>	0.5301	0.513	0.4886	0.5278	<i>F3rep27</i>	0.0198	0.0191	0.0176	0.0198	<i>F16rep28</i>	0.1785	0.1703	0.1564	0.1781
564	<i>F13rep16</i>	0.5258	0.4636	0.4275	0.5147	<i>F2rep14</i>	0.0197	0.019	0.0175	0.0197	<i>F12rep24</i>	0.1776	0.1752	0.1701	0.1776
565	<i>F13rep10</i>	0.5255	0.5015	0.4703	0.5229	<i>F13rep22</i>	0.0193	0.0217	0.0172	-0.0209	<i>F12rep13</i>	0.1773	0.1694	0.1557	0.177
566	<i>F13rep2</i>	0.5235	0.5139	0.5019	0.5229	<i>F12rep11</i>	0.0189	0	0.0168	-0.0191	<i>F16rep2</i>	0.1771	0.1693	0.1555	0.1768
567	<i>F13rep9</i>	0.5233	0.5128	0.4998	0.5225	<i>F13rep2</i>	0.0187	0	0.0166	-0.0188	<i>F11rep6</i>	0.1766	0.1685	0.1548	0.1763
568	<i>F11rep9</i>	0.5225	0.4754	0.4467	0.5135	<i>F16rep9</i>	0.0181	0	0.0161	-0.018	<i>F16rep23</i>	0.1761	0.168	0.1543	0.1758
569	<i>F13rep12</i>	0.5207	0.5103	0.4979	0.5201	<i>F13rep11</i>	0.0176	0	0.0157	-0.0183	<i>F13rep16</i>	0.1733	0.1657	0.1521	0.173
570	<i>F5rep18</i>	0.5156	0.5034	0.4874	0.5144	<i>F6rep19</i>	0.0174	0.0172	0.0154	0.0174	<i>F12rep22</i>	0.1724	0.1649	0.1514	0.1722
571	<i>F15rep6</i>	0.5142	0.5033	0.4882	0.5127	<i>F13rep28</i>	0.0172	0.0194	0.0154	-0.0186	<i>F6rep30</i>	0.1671	0.1654	0.1614	0.167
572	<i>F13rep22</i>	0.4963	0.488	0.4756	0.4957	<i>F2rep6</i>	0.0169	0.0163	0.0151	0.0169	<i>F13rep2</i>	0.167	0.1445	0.1245	0.1655
573	<i>F14rep9</i>	0.4946	0.4851	0.4711	0.4939	<i>F18rep26</i>	0.0167	0	0.0149	-0.0131	<i>F12rep14</i>	0.1664	0.1438	0.124	0.1647
574	<i>F13rep15</i>	0.493	0.4607	0.4319	0.4873	<i>F6rep15</i>	0.0167	0.0165	0.0148	0.0167	<i>F12rep6</i>	0.1659	0.1633	0.158	0.1658
575	<i>F14rep30</i>	0.4909	0.4733	0.452	0.4885	<i>F3rep29</i>	0.0165	0.016	0.0147	0.0165	<i>F12rep3</i>	0.1659	0.1585	0.1456	0.1656
576	<i>F11rep16</i>	0.4907	0.4805	0.4656	0.4894	<i>F12rep30</i>	0.0162	0	0.0144	-0.0167	<i>F13rep11</i>	0.1636	0.1416	0.1219	0.1621
577	<i>F10rep15</i>	0.4884	0.4551	0.4224	0.4854	<i>F3rep5</i>	0.0158	0.0152	0.014	0.0158	<i>F16rep13</i>	0.1635	0.1562	0.1435	0.1632
578	<i>F14rep27</i>	0.4865	0.4723	0.456	0.4848	<i>F2rep10</i>	0.0158	0.0152	0.014	0.0157	<i>F13rep20</i>	0.1619	0.1548	0.1421	0.1616
579	<i>F11rep24</i>	0.4833	0.4674	0.4482	0.4811	<i>F13rep13</i>	0.0157	0	0.014	-0.0158	<i>F12rep29</i>	0.1598	0.1527	0.1403	0.1596
580	<i>F13rep8</i>	0.4817	0.4693	0.452	0.4804	<i>F3rep26</i>	0.0156	0.0151	0.0139	0.0156	<i>F16rep29</i>	0.1582	0.1552	0.1492	0.1581

581	<i>F13rep18</i>	0.4732	0.4611	0.4441	0.4718	<i>F16rep5</i>	0.0153	0	0.0136	-0.0154	<i>F16rep19</i>	0.158	0.1511	0.1387	0.1578
582	<i>F20rep16</i>	0.4722	0.4609	0.4475	0.4711	<i>F3rep22</i>	0.0151	0.0146	0.0135	0.0151	<i>F13rep24</i>	0.1579	0.1368	0.1177	0.1568
583	<i>F4rep6</i>	0.4693	0.4219	0.3921	0.4614	<i>F13rep4</i>	0.015	0	0.0134	-0.0151	<i>F16rep17</i>	0.1577	0.1536	0.1459	0.1576
584	<i>F15rep3</i>	0.4673	0.4643	0.4568	0.4672	<i>F3rep28</i>	0.0149	0.0144	0.0132	0.0149	<i>F13rep23</i>	0.157	0.136	0.117	0.1559
585	<i>F11rep27</i>	0.4623	0.4388	0.4195	0.4571	<i>F13rep12</i>	0.0145	0	0.013	-0.0149	<i>F12rep5</i>	0.1545	0.1478	0.1357	0.1543
586	<i>F13rep29</i>	0.4587	0.4473	0.4335	0.4568	<i>F13rep5</i>	0.0139	0	0.0124	-0.0138	<i>F13rep10</i>	0.1537	0.1333	0.1146	0.1526
587	<i>F15rep5</i>	0.4537	0.4153	0.387	0.4495	<i>F13rep10</i>	0.0139	0	0.0124	-0.0135	<i>F13rep1</i>	0.1534	0.1467	0.1348	0.1532
588	<i>F11rep7</i>	0.4532	0.4124	0.3863	0.4468	<i>F13rep14</i>	0.0136	0	0.0121	-0.0135	<i>F12rep18</i>	0.1524	0.1457	0.1338	0.1522
589	<i>F10rep21</i>	0.445	0.4306	0.4099	0.4433	<i>F2rep21</i>	0.0133	0.0129	0.0119	0.0133	<i>F12rep26</i>	0.1521	0.1455	0.1336	0.1519
590	<i>F13rep26</i>	0.4434	0.4392	0.431	0.4432	<i>F12rep26</i>	0.013	0	0.0116	-0.0131	<i>F16rep11</i>	0.152	0.1318	0.1133	0.151
591	<i>F4rep27</i>	0.4419	0.4299	0.4166	0.4402	<i>F16rep19</i>	0.0129	0	0.0115	-0.012	<i>F12rep10</i>	0.1512	0.1447	0.1329	0.151
592	<i>F13rep19</i>	0.4374	0.434	0.4264	0.4373	<i>F13rep17</i>	0.0127	0	0.0113	-0.0128	<i>F12rep19</i>	0.1497	0.1432	0.1314	0.1495
593	<i>F13rep1</i>	0.435	0.4205	0.4001	0.4328	<i>F16rep22</i>	0.0126	0	0.0112	-0.0125	<i>F13rep13</i>	0.1495	0.1428	0.1312	0.1492
594	<i>F11rep11</i>	0.4271	0.4091	0.3937	0.4244	<i>F6rep26</i>	0.0122	0.0121	0.0109	0.0122	<i>F16rep12</i>	0.1459	0.1266	0.1088	0.145
595	<i>F13rep11</i>	0.3959	0.3776	0.3542	0.3938	<i>F13rep19</i>	0.0121	0	0.0108	-0.0125	<i>F12rep11</i>	0.141	0.1348	0.1239	0.1408
596	<i>F13rep30</i>	0.3956	0.3917	0.3841	0.3954	<i>F13rep29</i>	0.0115	0	0.0102	-0.012	<i>F16rep14</i>	0.1401	0.1365	0.1297	0.14
597	<i>F13rep21</i>	0.3809	0.371	0.3574	0.3797	<i>F13rep24</i>	0.0112	0	0.01	-0.0111	<i>F16rep30</i>	0.1394	0.1211	0.104	0.1386
598	<i>F13rep27</i>	0.3796	0.3309	0.309	0.3656	<i>F13rep21</i>	0.0106	0	0.0094	-0.0112	<i>F16rep1</i>	0.1372	0.1346	0.1294	0.1371
599	<i>F13rep14</i>	0.3674	0.3595	0.3491	0.3664	<i>F3rep24</i>	0.0099	0.0096	0.0088	0.0099	<i>F16rep26</i>	0.1352	0.1294	0.1188	0.1351
600	<i>F13rep6</i>	0.3092	0.2993	0.2847	0.308	<i>F2rep12</i>	0.0095	0.0092	0.0084	0.0095	<i>F12rep1</i>	0.1288	0.1275	0.1244	0.1288

<sup>a</sup>Estimativa da Eficiência com correção de viés

<sup>b</sup>Intervalo de Confiança para a estimativa da eficiência a um nível de confiança  $\alpha= 0.05$

## Bibliografia

- [1] MCCLOSKEY, D. The art of forecasting: From ancient to modern times. *Cato Journal*, CATO INSTITUTE, v. 12, p. 23–23, 1992. ISSN 0273-3072.
- [2] BOX, G. *et al. Time series analysis: forecasting and control*. [S.I.]: Holden-day San Francisco, 1976.
- [3] ENGLE, R. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the Econometric Society*, JSTOR, p. 987–1007, 1982. ISSN 0012-9682.
- [4] BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, Elsevier, v. 31, n. 3, p. 307–327, 1986. ISSN 0304-4076.
- [5] HAYKIN, S. *Neural networks: a comprehensive foundation*. [S.I.]: Prentice hall, 1999. ISBN 0132733501.
- [6] EIBEN, A.; SMITH, J. *Introduction to evolutionary computing*. [S.I.]: Springer Verlag, 2003. ISBN 3540401849.
- [7] FERREIRA, T.; VASCONCELOS, G.; ADEODATO, P. A new evolutionary method for time series forecasting. In: ACM. *Proceedings of the 2005 conference on Genetic and evolutionary computation*. [S.I.], 2005. p. 2221–2222. ISBN 1595930108.
- [8] RODRIGUES, A.; NETO, P. de M.; FERREIRA, T. A prime step in the time series forecasting with hybrid methods: The fitness function choice. In: IEEE. *Neural Networks, 2009. IJCNN 2009. International Joint Conference on*. [S.I.], 2009. p. 2703–2710. ISSN 1098-7576.
- [9] KASSAI, S. *Utilização da análise por envoltória de dados (DEA) na análise de demonstrações contábeis*. Tese (Doutorado) — Universidade de São Paulo, 2002.
- [10] WU, D.; YANG, Z.; LIANG, L. Using dea-neural network approach to evaluate branch efficiency of a large canadian bank. *Expert Systems with Applications*, Elsevier, v. 31, n. 1, p. 108–115, 2006.
- [11] MORETTIN, P.; TOLOI, C. de C. *Análise de séries temporais*. [S.I.]: Edgard Blucher, 2006. ISBN 8521203896.

- [12] BROCKWELL, P.; DAVIS, R. *Introduction to time series and forecasting*. [S.l.]: Springer Verlag, 2002. ISBN 0387953515.
- [13] CHATFIELD, C. *The analysis of time series: an introduction*. [S.l.]: CRC press, 2004. ISBN 1584883170.
- [14] EHLERS, R. Análise de séries temporais. *Departamento de Estatística, UFPR, Disponível em www.leg.ufpr.br/ehlers/notas*, v. 14, n. 03, 2008.
- [15] BEZERRA, M. Apostila de Análise de séries temporais. *DMEC / FCT / UNESP - Curso de Estatística*, 2006.
- [16] GUJARATI, D. N. *Basic Econometrics*. [S.l.]: McGraw-Hill Irwin, 2003. ISBN 0072335424.
- [17] SPITZER, F. *Principles of random walk*. [S.l.]: Springer Verlag, 2001. ISBN 0387951547.
- [18] MALKIEL, B. *A random walk down Wall Street*. [S.l.]: WW Norton & Company, 2000. ISBN 0393320405.
- [19] ABRAHAM, B.; LEDOLTER, J. *Statistical methods for forecasting*. [S.l.]: Wiley, 1983. ISBN 0471867640.
- [20] ARMSTRONG, J.; FORECASTING, L. *From Crystal Ball to Computer*. [S.l.]: Wiley, New York, 1978.
- [21] FAN, J.; YAO, Q. *Nonlinear time series: nonparametric and parametric methods*. [S.l.]: Springer Verlag, 2005.
- [22] ZHANG, G.; PATUWO, B. E. *et al.* Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, Elsevier, v. 14, n. 1, p. 35–62, 1998. ISSN 0169-2070.
- [23] FAUSETT, L. *Fundamentals of neural networks: architectures, algorithms, and applications*. [S.l.]: Prentice-Hall Englewood Cliffs, NJ, 1994. ISBN 0133341860.
- [24] NIGRIN, A. *Neural networks for pattern recognition*. [S.l.]: The MIT press, 1993. ISBN 0262140543.
- [25] RIPLEY, B. *Pattern recognition and neural networks*. [S.l.]: Cambridge Univ Pr, 2008.
- [26] MILLER, D.; KAMINSKY, E.; RANA, S. Neural network classification of remote-sensing data. *Computers & Geosciences*, Elsevier, v. 21, n. 3, p. 377–386, 1995. ISSN 0098-3004.
- [27] FERREIRA, T. *A new Intelligent Hybrid Methodology for the Time Serie Forecasting*. Tese (Doutorado) — PhD thesis, Federal University of Pernambuco, 50732-970, Recife-PE, Brazil, Febuary, 2006.
- [28] CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems (MCSS)*, Springer, v. 2, n. 4, p. 303–314, 1989. ISSN 0932-4194.

- [29] BÄCK, T.; SCHWEFEL, H. An overview of evolutionary algorithms for parameter optimization. *Evolutionary computation*, MIT Press, v. 1, n. 1, p. 1–23, 1993. ISSN 1063-6560.
- [30] HEITKOETTER, J.; BEASLEY, D. *The Hitch-Hiker's Guide to Evolutionary Computation: A list of Frequently Asked Questions (FAQ)*. *USENET: comp. ai. genetic*, Available via anonymous FTP from rtfm. [S.l.]: mit. edu:/pub/usenet/news. answers/ai-faq/genetic, 1997.
- [31] SCHWEFEL, H. *Evolution and Optimum Seeking: The Sixth Generation*. [S.l.]: John Wiley & Sons, Inc., 1993. ISBN 0471571482.
- [32] BEYER, H. *The theory of evolution strategies*. [S.l.]: Springer Verlag, 2001. ISBN 3540672974.
- [33] MEZURA-MONTES, E.; COELLO, C. An empirical study about the usefulness of evolution strategies to solve constrained optimization problems. *International Journal of General Systems*, Taylor & Francis, v. 37, n. 4, p. 443–473, 2008. ISSN 0308-1079.
- [34] BEYER, H.; SCHWEFEL, H. Evolution strategies—A comprehensive introduction. *Natural computing*, Springer, v. 1, n. 1, p. 3–52, 2002. ISSN 1567-7818.
- [35] WIDROW, B.; LEHR, M. 30 years of adaptive neural networks: Perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, IEEE, v. 78, n. 9, p. 1415–1442, 1990. ISSN 0018-9219.
- [36] YAO, X. A review of evolutionary artificial neural networks. *International journal of intelligent systems*, Wiley Online Library, v. 8, n. 4, p. 539–567, 1993. ISSN 1098-111X.
- [37] FARRELL, M. The measurement of productive efficiency. *Journal of the Royal Statistical Society. Series A (General)*, JSTOR, v. 120, n. 3, p. 253–290, 1957.
- [38] CHARNES, A. *Data envelopment analysis: theory, methodology, and application*. [S.l.]: Springer, 1994. ISBN 0792394798.
- [39] SOARES, D. JCCB; Angulo Meza, L.; Gomes, EG; Biondi Neto, L. Curso de Análise Envolvória de Dados. *Anais do XXXVII SBPO—Simpósio Brasileiro de Pesquisa Operacional*, [s.d.].
- [40] COOPER, W.; SEIFORD, L.; TONE, K. *Data envelopment analysis: a comprehensive text with models, applications, references and DEA-solver software*. [S.l.]: Springer Verlag, 2007. ISBN 0387452818.
- [41] MEZA, L.; GOMES, E.; FERNANDES, A. Seleccção de variáveis em DEA aplicada a uma análise do mercado de energia eléctrica. *Inv. Op*, v. 27, n. 1, p. 21–36, 2007.
- [42] COOPER, W.; SEIFORD, L.; TONE, K. *Introduction to data envelopment analysis and its uses: with DEA-solver software and references*. [S.l.]: Springer Verlag, 2006. ISBN 0387285806.
- [43] BANKER, R.; CHARNES, A.; COOPER, W. Some models for estimating technical and scale inefficiencies in data envelopment analysis. *Management science*, JSTOR, v. 30, n. 9, p. 1078–1092, 1984. ISSN 0025-1909.

- [44] EZEQUIEL, E. *et al.* O número de manchas solares, índice da atividade do sol. *Revista Brasileira de Ensino de Física*, v. 25, [s.d.]. ISSN 0102-4744.
- [45] MARRA, S.; MORABITO, F. Solar activity forecasting by incorporating prior knowledge from nonlinear dynamics into neural networks. In: IEEE. *Neural Networks, 2006. IJCNN'06. International Joint Conference on.* [S.l.], 2007. p. 3722–3728. ISBN 0780394909.
- [46] LINDEN R. A. M., t. S. t. Van der. *Online catalogue of the sunspot index.* 2011. [acesso em: 07 fev. 2011]. Disponível em: <<http://sidc.oma.be/html/sunspot.html>>.
- [47] INDEX, S. . P. . 2011. [acesso em: 07 fev. 2011]. Disponível em: <<http://www.standardandpoors.com>>.
- [48] VILELA, D. A importância econômica, social e nutricional do leite. *Revista Batavo*, 2001.
- [49] EMBRAPA, A. D. I. *Agronegócio do leite.* 2011. [acesso em: 07 fev. 2011]. Disponível em: <<http://www.agencia.cnptia.embrapa.br/Agencia8/AG01/Abertura.html>>.
- [50] SERVICE(NASS), N. A. S. *Milk Production.* 2011. [acesso em: 07 fev. 2011]. Disponível em: <<http://usda.mannlib.cornell.edu/MannUsda/homepage.do>>.
- [51] ARMSTRONG, J.; COLLOPY, F. Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, v. 8, n. 1, p. 69–80, 1992.
- [52] COLLOPY, F.; ARMSTRONG, J.; DEPT, W. S. M. *Another error measure for selection of the best forecasting method: the unbiased absolute percentage error.* [S.l.]: Wharton School, University of Pennsylvania, Marketing Dept., 1994.
- [53] FILDES, R. The evaluation of extrapolative forecasting methods. *International Journal of Forecasting*, Elsevier, v. 8, n. 1, p. 81–98, 1992.
- [54] CHATFIELD, C. Apples, oranges and mean square error. *International Journal of Forecasting*, Elsevier, v. 4, n. 4, p. 515–518, 1988.
- [55] GOODWIN, P.; LAWTON, R. On the asymmetry of the symmetric MAPE. *International Journal of Forecasting*, Elsevier, v. 15, n. 4, p. 405–408, 1999. ISSN 0169-2070.
- [56] JO, T. The Prediction of the Annual Number of Sunspots with Virtual Terms Generation Schemes. *The Proceeding of PACES/SPICIS*, v. 97, p. 135–141, 1997.
- [57] KAHN, K. Benchmarking sales forecasting performance measures. *THE JOURNAL OF BUSINESS*, v. 99, 1998.
- [58] TASHMAN, L. Out-of-sample tests of forecasting accuracy: an analysis and review. *International Journal of Forecasting*, Elsevier, v. 16, n. 4, p. 437–450, 2000.
- [59] THEIL, H. *Applied economic forecasting.* [S.l.]: North-Holland Pub. Co., 1966.
- [60] TEAM, R. D. C. R: A language and environment for statistical computing. r foundation for statistical computing, vienna, austria. ISBN, p. 3–900051, 2009.

- [61] BOGETOFT, P.; OTTO, L. *Benchmarking with DEA and SFA*. [S.l.], 2011. R package version 0.19.
- [62] WILSON, P. Fear: A software package for frontier efficiency analysis with r. *Socio-Economic Planning Sciences*, Elsevier, v. 42, n. 4, p. 247–254, 2008.
- [63] PRECHELT, L. *et al.* Proben1: A set of neural network benchmark problems and benchmarking rules. *Fakultät für Informatik, Univ. Karlsruhe, Karlsruhe, Germany, Tech. Rep*, Citeseer, v. 21, p. 94, 1994.
- [64] GOLANY, B.; ROLL, Y. An application procedure for DEA. *Omega*, Elsevier, v. 17, n. 3, p. 237–250, 1989. ISSN 0305-0483.
- [65] BOGETOFT, P.; OTTO, L. *Benchmarking with DEA, SFA, and R*. [S.l.]: Springer, 2011. ISBN 978-1-4419-7960-5.
- [66] SIMAR, L.; WILSON, P. Sensitivity analysis of efficiency scores: How to bootstrap in nonparametric frontier models. *Management science*, JSTOR, p. 49–61, 1998.
- [67] SIMAR, L.; WILSON, P. A general methodology for bootstrapping in non-parametric frontier models. *Journal of applied statistics*, Routledge, part of the Taylor & Francis Group, v. 27, n. 6, p. 779–802, 2000.
- [68] SIEGEL, S. Estatística não-paramétrica para as ciências do comportamento. *Estatística não-paramétrica para as ciências do comportamento*, McGraw-Hill do Brasil, 1975.
- [69] AKAIKE, H. A new look at the statistical model identification. *Automatic Control, IEEE Transactions on*, IEEE, v. 19, n. 6, p. 716–723, 1974.
- [70] SCHWARZ, G. Estimating the dimension of a model. *The annals of statistics*, JSTOR, p. 461–464, 1978.
- [71] WEINBERG, S.; ABRAMOWITZ, S. *Data analysis for the behavioral sciences using SPSS*. [S.l.]: Cambridge Univ Pr, 2002.
- [72] DEPRINS, D.; SIMAR, L.; TULKENS, H. Measuring labor-efficiency in post offices. *Public goods, environmental externalities and fiscal competition*, Springer, p. 285–309, 2006.
- [73] BÄCK, T.; HOFFMEISTER, F.; SCHWEFEL, H. A survey of evolution strategies. In: *Proceedings of the Fourth International Conference on Genetic Algorithms*. [S.l.]: Morgan Kaufmann, 1991. p. 2–9.
- [74] EFRON, B.; TIBSHIRANI, R. *An introduction to the bootstrap*. [S.l.]: Chapman & Hall/CRC, 1993.
- [75] BANKER, R. D. Hypothesis tests using data envelopment analysis. *Journal of Productivity Analysis*, Springer Netherlands, v. 7, p. 139–159, 1996. ISSN 0895-562X. 10.1007/BF00157038. Disponível em: <<http://dx.doi.org/10.1007/BF00157038>>.