



DESENVOLVIMENTO DE FERRAMENTAS PARA MODELAGEM DO VENTO PARA GERAÇÃO DE ENERGIA

Ricardo Zely Figueiredo de Carvalho

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Luiz Pereira Calôba, Dr.Ing.

Rio de Janeiro

Janeiro de 2011

DESENVOLVIMENTO DE FERRAMENTAS PARA MODELAGEM DO VENTO PARA
GERAÇÃO DE ENERGIA

Ricardo Zely Figueiredo de Carvalho

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM
ENGENHARIA ELÉTRICA.

Examinada por:

Prof. Luiz Pereira Calôba, Dr.Ing.

Prof. Maria Regina de Oliveira Pereira de Araújo, D.Sc.

Prof. Alexandre Pinto Alves da Silva, Ph.D.

RIO DE JANEIRO, RJ - BRASIL

JANEIRO DE 2011

Carvalho, Ricardo Zely Figueiredo de

Desenvolvimento de Ferramentas para Modelagem do Vento para Geração de Energia/ Ricardo Zely Figueiredo de Carvalho. - Rio de Janeiro: UFRJ/COPPE, 2011.

XII, 73 p.: il.; 29,7 cm.

Orientador: Luiz Calôba

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2011.

Referências Bibliográficas: p. 72-73.

1. MCP. 2. Previsão do Vento. I. Calôba, Luiz Pereira. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

Dedico este trabalho a minha família.

AGRADECIMENTOS

Gostaria de agradecer a Prof. Regina Araújo, quem primeiro me abriu as portas para o fascinante universo da energia eólica e que generosamente compartilhou seu valioso conhecimento e experiência.

Meus agradecimentos sinceros ao meu orientador, Prof. Luiz Calôba, que sempre esteve disponível para as orientações de valor inestimável me conduzindo sabiamente por caminhos seguros.

Sou muito agradecido a Fernanda de Carvalho que com grande paciência sempre me apoiou nas diversas etapas desse empreendimento.

Por fim, agradeço especialmente ao meu pai Antonio Carlos de Carvalho, a minha mãe Vanda Figueiredo e ao meu irmão Rafael Carvalho que sempre me incentivaram, apoiaram e que estiveram ao meu lado durante todo o trabalho.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M. Sc.)

DESENVOLVIMENTO DE FERRAMENTAS PARA MODELAGEM DO VENTO
PARA GERAÇÃO DE ENERGIA

Ricardo Zely Figueiredo de Carvalho

Janeiro/2011

Orientador: Luiz Pereira Calôba

Programa: Engenharia Elétrica

Este trabalho se propõe a criar e melhorar técnicas de correlação dos dados de vento entre estações de medições, contribuindo para a solução de alguns dos principais desafios para o aproveitamento da energia eólica.

Existem diversos métodos para tratar o problema, sendo que cada um apresenta suas limitações específicas. Desta forma, o tema possui grande espaço para avanços e melhorias.

Foram elaboradas duas abordagens distintas de ferramentas. Na primeira buscou-se incorporar alguns aspectos da dinâmica dos ventos, de forma a considerar as distâncias entre as estações, além da direção e velocidade dos ventos. Na segunda parte, as ferramentas correlacionavam diretamente o comportamento sazonal de cada estação, sem levar em conta nenhuma hipótese específica.

No caso da primeira abordagem os resultados evidenciaram que para estações próximas seria possível desenvolver ferramentas que se beneficiariam de informações extraídas da fenomenologia do vento. Para estações distantes estas informações seriam de pouca utilidade.

Na segunda abordagem os resultados mostraram que é possível melhorar significativamente as correlações, principalmente nos casos em que as correlações clássicas são baixas. Foi possível desenvolver uma ferramenta que apresentou melhoras na ordem de 4% nas correlações.

Abstract of Dissertation to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

DEVELOPMENT OF TOOLS FOR WIND MODELLING FOR ENERGY PRODUCTION

Ricardo Zely Figueiredo de Carvalho

January/2011

Advisor: Luiz Pereira Calôba

Department: Electrical Engineering

This work aims to develop tools for improving the correlation of wind data between measuring stations, contributing to solve some of the main challenges for the utilization of wind energy.

There are several methods that address these problems, each one with its own limitations. Therefore, this subject-matter has great room for advances and improvements.

Two different approaches were developed. At first we tried to incorporate some aspects of the dynamics of the winds, in order to consider the distances between stations as well as direction and wind speed. In the second part, the tools directly correlate the seasonal behavior of each station, without regarding any specific hypothesis.

For the first approach results showed that for nearby stations it would be possible to develop tools benefitting from information obtained from the phenomenology of the wind. For distant stations these information would be of little use.

In the second approach the results showed that it is possible to significantly improve the correlations, especially in cases where the classic correlations are low. It was possible to develop a tool that improved about 4%.

Sumário

1	Introdução	1
1.1	Motivação	1
1.1.1	Desafios	2
1.1.2	Estimativa de geração de longo prazo	2
1.1.3	Qualidade dos dados medidos	3
1.1.4	Controle ou previsão da geração	4
1.2	Objetivo	5
1.3	Estrutura	6
1.4	Estado da Arte	6
2	O vento	14
2.1	Principais causas	14
2.2	Dados de vento utilizados na pesquisa	17
3	Desenvolvimento das ferramentas	19
3.1	Ferramentas para dados residuais	20
3.1.1	Hipóteses	20
3.1.2	Ferramenta 1	24
3.1.2.1	Teste da hipótese da trajetória	33
3.1.2.2	Teste da hipótese da frente de ação	34
3.1.3	Ferramenta 2	37
3.1.4	Conclusão (análise de resíduos)	40
3.2	Ferramentas para dados “sazonalizados”	43
3.2.1	Ferramenta 3	43
3.2.1.1	Versão 1	43
3.2.1.2	Versão 2	50
3.2.1.3	Aplicação da ferramenta	54
4	Conclusões e trabalhos futuros	57
	Anexo A – Sazonalidade	59
	Anexo B – Dados originais e sazonalidades	64
	Referências Bibliografia	72

Lista de Figuras

Figura 1.1 – Evolução do aproveitamento da energia dos ventos.	1
Figura 1.2 – Potência instalada no planeta.....	2
Figura 1.3 – Exemplo de variabilidade do vento no longo prazo (LP).....	3
Figura 1.4 - Exemplo de falhas sendo corrigidas com dados de outra estação.....	4
Figura 1.5 – A produção de energia para satisfazer a demanda deve considerar a previsão de geração eólica.	5
Figura 1.6 – Dados medidos no local do projeto e dados de longo prazo medidos em uma estação de referência com períodos coincidentes.....	7
Figura 1.7 – O período coincidente é utilizado para se obter a relação entre os dados.....	7
Figura 1.8 – A relação obtida é utilizada para prever os dados na estação do projeto utilizando-se os dados de longo prazo.	7
Figura 1.9 – Regressão linear entre os dados das estações para cada setor de direção.	8
Figura 1.10 – Esquema de um neurônio básico.	12
Figura 1.11 – Rede Neural feedforward de 3 camadas.....	13
Figura 2.1 – Principais influencias globais do vento.	14
Figura 2.2 – Circulação global do vento (www.topnews.in).....	15
Figura 2.3 – Perfil de velocidade do vento e aceleração em relevos altos.	15
Figura 2.4 – Exemplo de relevos íngremes onde podem ocorrer descolamento do fluxo de vento. ...	16
Figura 2.5 – Deslocamentos causados pelos efeitos terra-mar.	16
Figura 2.6 – Movimento causado pelas diferenças de temperaturas entre vales e colinas.....	16
Figura 2.8 – Localização aproximada das estações utilizadas e direção predominante na estação de referência.....	17
Figura 3.1 – Dado de vento sendo decomposto em sazonalidade e Dado residual.	19
Figura 3.2 – Correlação estação de referência Vs. estações auxiliares em vários intervalos.	20
Figura 3.3 – Correlograma estação de referência Vs. Estações auxiliares, incluindo a Autocorrelação da estação de referência.....	21
Figura 3.4 – Comparação entre passos do correlograma e distâncias entre estações.	21
Figura 3.5 – Hipótese da trajetória do vento ilustrando o deslocamento do comportamento do vento no espaço.	22
Figura 3.6 – Direção do vento Vs. Distância para calculo do passo estimado.....	23
Figura 3.7 - Direção do vento Vs. Distância para calculo do passo estimado.	23
Figura 3.8 – Cálculo do Passo estimado.	24
Figura 3.9 – Ilustra que altas correlações podem ocorrer com vários dias de defasagem em função dos ciclos diários.	25
Figura 3.10 – Exemplo de dois períodos que passaram nos critérios de seleção.	26
Figura 3.11 – Varredura para encontrar a correlação máxima, com o espaço de busca sendo centralizado pelo passo estimado.	27

Figura 3.12 – Diagrama resumo da ferramenta de correlação.....	28
Figura 3.13 – Gráfico de Velocidade Vs. Direção médios para os períodos encontrados com os respectivos passos encontrados – Estação 6.....	30
Figura 3.14 – Gráfico de Velocidade Vs. Passos encontrados para as principais direções – Estação 6.....	30
Figura 3.15 – Indicando que os resultados para a estação original ficaram pouco acima do que para a estação de validação.....	32
Figura 3.16 – Caso em que a direção do vento está alinhada com a reta que liga as estações.....	33
Figura 3.17 - Caso em que a direção do vento é tal que o vento chega ao mesmo tempo em ambas as estações.....	35
Figura 3.18 – Médias das correlações para a Est. 1.....	38
Figura 3.19 – Médias das correlações para a Est. 2.....	38
Figura 3.20 – Médias das correlações para a Est.3.....	39
Figura 3.21 – Médias das correlações para a Est.4.....	39
Figura 3.22 – Médias das correlações para a Est.5.....	39
Figura 3.23 – Médias das correlações para a Est.6.....	39
Figura 3.24 – Médias das correlações para a Est.7.....	39
Figura 3.25 – Médias das correlações para a Est.8.....	39
Figura 3.26 – Médias das correlações para a Est.9.....	40
Figura 3.27 – Médias das correlações para a Est.10.....	40
Figura 3.28 – Curva de potência típica de um aerogerador.....	41
Figura 3.29 – Dados de vento da estação de referência.....	43
Figura 3.30 – Sazonalidades da estação de referência e da estação 9, evidenciando a diferenças significativas.....	44
Figura 3.31 –Representação da ferramenta de correlação, a qual faz uma varredura de duas dimensões na estação de projeto em busca das correlações máximas.....	45
Figura 3.32 – A sub-matriz pode varrer livremente pelos dois eixos.....	45
Figura 3.33 – Exemplo da criação da Matriz das Correlações.....	46
Figura 3.34 – Matrizes de dados e matriz das Correlações para a estação 6.....	47
Figura 3.35 – Matrizes de dados e matriz das Correlações para a estação 9.....	48
Figura 3.36 – Matrizes de dados e matriz das Correlações para a estação Estação 10.....	49
Figura 3.37 – Representação da sub-matriz e espaço de varredura apenas no eixo das horas.....	50
Figura 3.38 – Matriz das Correlações para a Estação 1.....	51
Figura 3.39 – Matriz das Correlações para a Estação 2.....	51
Figura 3.40 – Matriz das Correlações para a Estação 3.....	51
Figura 3.41 – Matriz das Correlações para a Estação 4.....	52
Figura 3.42 – Matriz das Correlações para a Estação 5.....	52
Figura 3.43 – Matriz das Correlações para a Estação 6.....	52
Figura 3.44 – Matriz das Correlações para a Estação 7.....	53
Figura 3.45 – Matriz das Correlações para a Estação 8.....	53

Figura 3.46 – Matriz das Correlações para a Estação 9.	53
Figura 3.47 – Matriz das Correlações para a Estação 10.	54
Figura 3.48 – Exemplo de situação onde alguns dados são contabilizados mais de uma vez enquanto outros não são contabilizados.	55
Figura A 1 - Dia típico anual e mensal da estação de referência.	59
Figura A 2 - Médias mensais e médias de 5 dias da estação de referência.	59
Figura A 3 – Dados estação estação de referência.	60
Figura A 4 – Média exponencialmente ponderada no eixo dos dias e no eixo das horas.	60
Figura A 5 – Ilustração da média ponderada sendo aplicada.	61
Figura A 6 – Dado original da estação de referência.	62
Figura A 7 – Dado “sazonalizado” com $D = 3$ e $\lambda d = 0.3$	62
Figura A 8 – Dado “sazonalizado” com $D = 5$ e $\lambda d = 0.3$	62
Figura A 9 – Dado “sazonalizado” com $D = 9$ e $\lambda d = 0.2$	63
Figura A 10 – Dado “sazonalizado” com $D = 15$ e $\lambda d = 0.18$	63
Figura A 11 – Dado “sazonalizado” com $D = 21$ e $\lambda d = 0.12$	63
Figura B 1 – Dados originais da estação de referência.	64
Figura B 2 – Dados “sazonalizados” da estação de referência.	64
Figura B 3 – Dados originais da estação 1.	64
Figura B 4 – Dados “sazonalizados” da estação 1.	65
Figura B 5 – Dados originais da estação 2.	65
Figura B 6 – Dados “sazonalizados” da estação 2.	65
Figura B 7 – Dados originais da estação 3.	66
Figura B 8 – Dados “sazonalizados” da estação 3.	66
Figura B 9 – Dados originais da estação 4.	66
Figura B 10 – Dados “sazonalizados” da estação 4.	67
Figura B 11 – Dados originais da estação 5.	67
Figura B 12 – Dados “sazonalizados” da estação 5.	67
Figura B 13 – Dados originais da estação 6.	68
Figura B 14 – Dados “sazonalizados” da estação 6.	68
Figura B 15 – Dados originais da estação 7.	68
Figura B 16 – Dados “sazonalizados” da estação 7.	69
Figura B 17 – Dados originais da estação 8.	69
Figura B 18 – Dados “sazonalizados” da estação 8.	69
Figura B 19 – Dados originais da estação 9.	70
Figura B 20 – Dados “sazonalizados” da estação 9.	70
Figura B 21 – Dados originais da estação 10.	70
Figura B 22 – Dados “sazonalizados” da estação 10.	71

Lista de Tabelas

Tabela 1.1 – Exemplo de matriz com os registros de direção de ambas as estações.....	10
Tabela 1.2 - Percentual de registros, $W_{i,j}$. O somatório em cada setor da estação de referência é 100%.....	10
Tabela 1.3 - Percentual de registros, $Z_{i,j}$. O somatório em cada setor da estação do projeto é 100%.....	11
Tabela 3.1 – Exemplo dos resultados obtidos para a estação 6, com as estatísticas de cada período encontrado.....	28
Tabela 3.2 – Períodos encontrados para a Estação 6.	31
Tabela 3.3 - Períodos encontrados para a Estação de validação 6.....	32
Tabela 3.4 – Somatório dos períodos encontrados para diversas configurações.....	33
Tabela 3.5 - Somatório dos períodos encontrados para diversas configurações.	34
Tabela 3.6 – Resultados para o teste da “frente de ação”, com etapas intermediárias.....	36
Tabela 3.7 – Faixas de seleção para os períodos encontrados na estação de referência.	38
Tabela 3.8 – Diferença na estimativa de geração entre Sazonalidade Vs. Dados originais.....	41
Tabela 3.9 – Resultado das correlações utilizando-se os passos encontrados.....	55
Tabela 10 – Constantes de decaimento utilizadas na análise das sazonalidades.....	61

1 Introdução

1.1 Motivação

Mudanças climáticas e sustentabilidade

A preocupação com as mudanças climáticas e com o uso sustentável dos recursos naturais são temas cada vez mais em pauta no cenário mundial. Fontes como petróleo, carvão e gás, além de emitirem gases de efeito estufa, são fontes esgotáveis e, portanto, não será possível contar com elas futuramente. Todas estas questões impulsionam o interesse por fontes alternativas que, além de não emitirem gases de efeito estufa, são fontes renováveis e, portanto, sempre estarão disponíveis.

Neste sentido a energia eólica se mostra uma das mais promissoras fontes de energia renováveis, caracterizada por uma tecnologia madura com capacidade de gerar grande quantidade de energia de forma limpa e sustentável.

Origens e perspectivas

Desde a antiguidade o vento é utilizado como uma importante fonte de energia. Seja através das velas que moviam os barcos ou pelos moinhos que bombeavam água ou moíam grãos. O vento sempre foi uma fonte imprescindível de energia para o ser humano (FERREIRA *et al*, 2010). A Figura 1.1 ilustra a evolução da utilização da energia eólica.

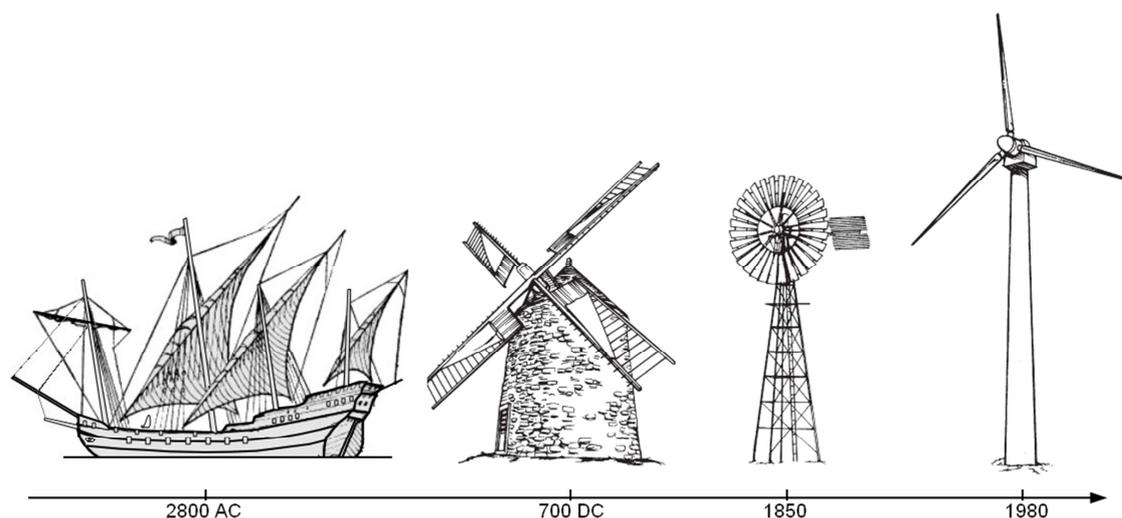


Figura 1.1 – Evolução do aproveitamento da energia dos ventos.

No entanto, foi a partir da década de 80 que esta fonte começou a ser utilizada na geração de energia elétrica. Desde então, sua utilização vem crescendo mais de 25% ao ano, de forma que em 2009 atingiu-se a notável marca de mais de 150GW de potencia instalada no planeta. A Figura 1.2

(GWEC, 2010) mostra a evolução da energia eólica no mundo, indicando um crescimento exponencial e consistente.

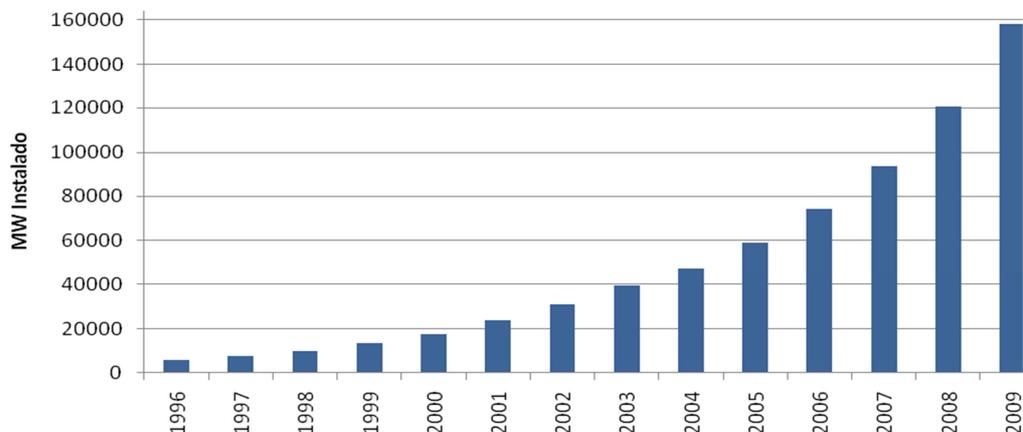


Figura 1.2 – Potência instalada no planeta.

Estudos realizados na universidade de Stanford (ARCHER et al, 2005) estimam que o potencial eólico mundial seja de aproximadamente 72TW, o que representa 7 vezes a demanda por eletricidade atual do planeta. Neste contexto é importante ressaltar que a tecnologia para aproveitar este potencial está cada vez mais eficiente, confiável e acessível. Os aerogeradores dos anos 80, que possuíam 15 KW de potencia, com pás de 8m, deram lugar aos modernos aerogeradores que chegam à capacidade de 5.000KW de potencia, com pás de mais de 60m (EWEA, 2010). Por estes motivos a importância da energia eólica no contexto global é cada vez mais evidente, contribuindo para a diversificação e segurança no fornecimento de energia de forma alinhada com as necessidades de fontes renováveis e não poluentes.

1.1.1 Desafios

Como em qualquer atividade de engenharia, no setor da energia eólica existem diversos desafios inerentes ao seu aproveitamento e adequada inserção no sistema elétrico. Nos itens seguintes são apresentados três desses desafios cujas soluções estão diretamente relacionadas com os temas estudados nesta dissertação. Neste sentido é possível mostrar a extensão das aplicações e importância das questões tratadas neste trabalho.

1.1.2 Estimativa de geração de longo prazo

De forma geral, parques eólicos são projetados para ficar em operação por 20 anos. Consequentemente, para a análise de viabilidade econômica é necessário estimar a energia que será produzida durante todos os 20 anos em que estará em funcionamento. A principal metodologia utilizada para estas estimativas sustenta-se na hipótese de que o vento no futuro terá um

comportamento muito similar ao dos ventos passados. Desta forma, a difícil tarefa de prever o vento no longo prazo se transforma numa tarefa muito mais simples, medi-lo.

Obviamente, medir o vento por 20 anos inviabilizaria economicamente o projeto. Por este motivo, a prática comum é medir o vento no local do empreendimento por pelo menos 1 ou 2 anos, em várias alturas, em intervalos de 10 minutos. Este período é suficiente para capturar características importantes do vento, tais como índice de turbulência, sazonalidades, coeficientes de extrapolação e parâmetros da distribuição de Weibull, comumente utilizada para modelar os dados.

Entretanto, devido a grande variabilidade do vento ao longo dos anos faz-se necessário ajustar os dados com medições de longo prazo, normalmente disponíveis em aeroportos e institutos meteorológicos. Ainda assim, para que os ajustes possam ser aplicados é fundamental que haja boa correlação entre ambos os dados. Se a correlação não for satisfatória os ajustes não poderão ser aplicados e, conseqüentemente, as estimativas de geração de energia incorrerão em grandes incertezas diminuindo as estimativas de rendimento e, conseqüentemente, a viabilidade do empreendimento.

A Figura 1.3 exemplifica um caso em que a campanha de medição foi realizada durante um período cuja velocidade estava abaixo da média histórica. Como pode ser visto na medição de longo prazo, a partir do ano de 2003 a velocidade apresenta uma diminuição significativa quando comparado aos anos anteriores e justamente neste período foi realizada a medição no local do projeto. Neste caso, não aplicar os ajustes de longo prazo diminuiria consideravelmente a estimativa de geração, o que poderia inviabilizar, indevidamente, a construção do parque.

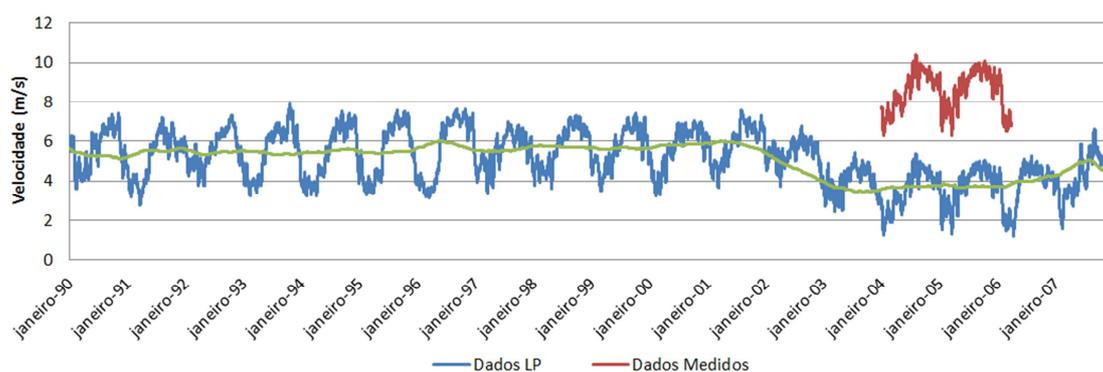


Figura 1.3 – Exemplo de variabilidade do vento no longo prazo (LP).

1.1.3 Qualidade dos dados medidos

Outro fator fundamental na obtenção de uma estimativa de geração confiável encontra-se na qualidade dos dados medidos. Estes dados servirão como base para todas as demais etapas do projeto de um parque, incluindo otimização da posição dos aerogeradores, cálculos de carga nos

componentes mecânicos e culminando com a própria estimativa de geração. Neste sentido, a importância de se obter dados de alta qualidade é incontestável.

Desta forma, apesar dos grandes cuidados orientados a uma boa campanha de medição, é muito comum verificar falhas ou inconsistências nos dados. As torres meteorológicas ficam expostas continuamente a condições de climas adversos com tempestades, raios, ventos com areia e maresia que acabam por danificar os sensores, conexões e estruturas da torre. Além disso, não é raro que atos de vandalismo e roubos causem problemas nas medições.

Sempre que são detectadas essas falhas ou inconsistências nos dados buscam-se formas de se reaver a qualidade e a representatividade dos mesmos, objetivando diminuir as incertezas das estimativas. A principal forma de corrigir os dados com problemas é através da utilização de outras medições, em outros níveis de altura ou em estações vizinhas. Naturalmente, quanto maior for a correlação entre os dados utilizados, menor será a incerteza considerada. A Figura 1.4 ilustra a reparação de “buracos” encontrados na estação 1 através de dados da estação 2.

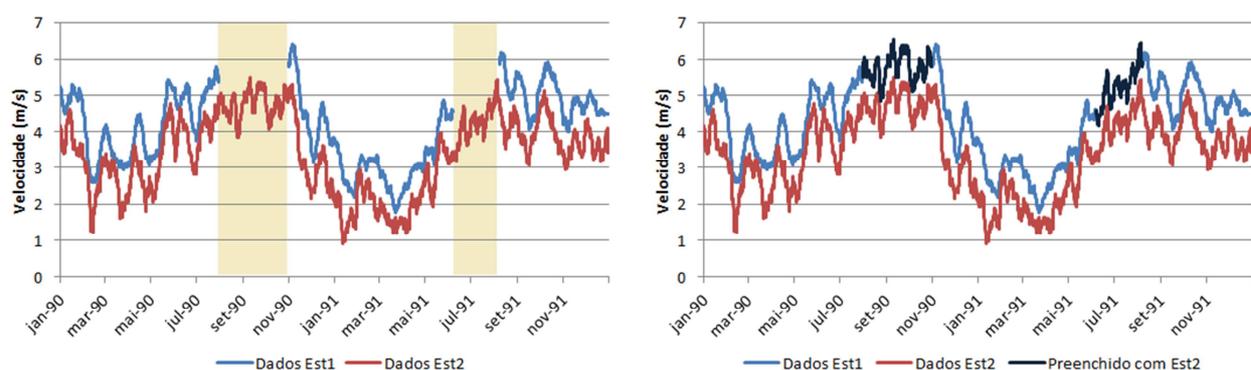


Figura 1.4 - Exemplo de falhas sendo corrigidas com dados de outra estação.

1.1.4 Controle ou previsão da geração

Desde que a energia elétrica se tornou essencial para a atividade humana a tarefa de suprir esta necessidade passou a ser um desafio constante para as empresas de energia. A energia elétrica tem que ser produzida na mesma proporção em que está sendo utilizada e o casamento entre oferta e demanda é uma das tarefas mais desafiadoras do setor elétrico. Neste contexto, a energia eólica, por depender inteiramente de um fenômeno não controlável e bastante aleatório, não proporciona os meios de controle da produção que seriam tão importantes para este desafio do setor.

Por outro lado, este problema pode ser em grande parte amenizado quando se é capaz, ao menos, de prever o comportamento do vento, permitindo estimar a geração com alguma antecedência. Através dessa previsão, seria possível ajustar a oferta total de energia com as fontes controláveis,

tais como as hidrelétricas e termoelétricas. Países como a Dinamarca possuem quase 20% de sua energia proveniente de fontes eólicas e conseguem equacionar de forma bem sucedida este desafio.

Métodos de correlação entre estações de medição do vento são muito úteis em previsões de curto prazo, pois podem antecipar comportamentos detectados nos arredores.

A Figura 1.5 ilustra o casamento da oferta e da demanda por energia sendo equacionados através da previsão da energia eólica e, em seguida, programação das demais fontes que são controláveis.

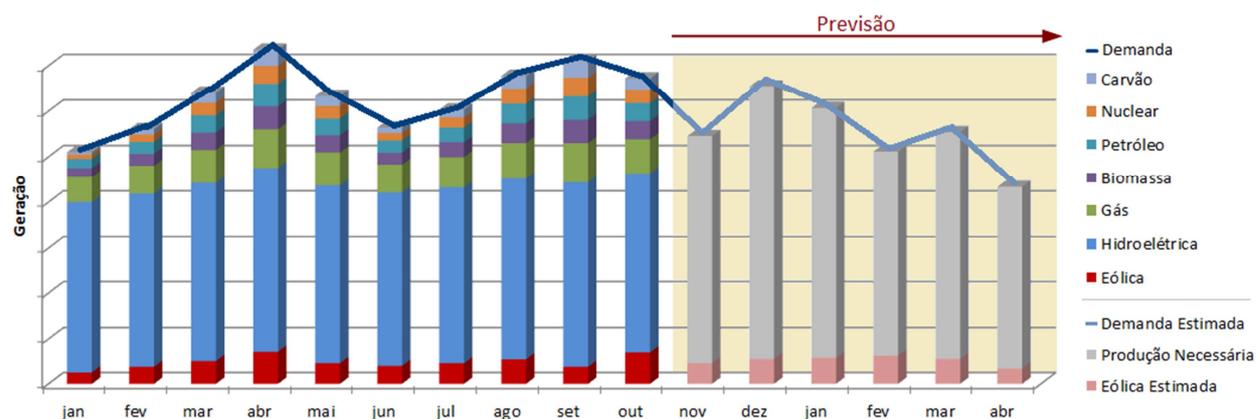


Figura 1.5 – A produção de energia para satisfazer a demanda deve considerar a previsão de geração eólica.

1.2 Objetivo

O objetivo desta pesquisa é criar ferramentas que permitam aprimorar as técnicas clássicas de correlação, contribuindo para a solução de alguns dos principais desafios para o aproveitamento da energia eólica.

Todos os desafios apresentados anteriormente apoiam-se, em grande parte, nos métodos de correlação que permitem aproveitar as informações registradas em outras localidades e “trazê-las” ao local de estudo. Desta forma, é possível utilizar os dados das estações com medições de longo prazo para o estudo de viabilidade nos 20 anos de operação do parque, assim como completar os “buracos” e inconsistências na medição com estações próximas, além de apoiar as técnicas de previsão de curto prazo fundamentais para se conseguir ajustar a oferta com a demanda de energia.

O principal método para fazer a correlação e previsão do vento é chamado de MCP, que será descrito em detalhes ainda neste capítulo. Este método, embora muito útil e amplamente utilizado, apresenta algumas limitações, principalmente quando utilizado em estações com baixas correlações entre si. O método, e suas variações, não modelam alguns aspectos da dinâmica do vento e na maioria das vezes usam equações lineares para representar comportamentos não-lineares inerentes ao vento.

Portanto, o principal objetivo deste trabalho é aprimorar os métodos de correlação entre estações de medição do vento, principalmente nos casos em que os métodos clássicos apresentam baixas correlações.

1.3 Estrutura

O trabalho foi estruturado segundo a ordem cronológica do desenvolvimento da pesquisa.

O primeiro Capítulo contextualiza a importância da energia eólica no cenário atual e apresenta alguns dos principais desafios que devem ser tratados pelo setor. Além disso, são apresentadas as principais ferramentas existentes e são traçados os objetivos da pesquisa.

O Capítulo 2 introduz alguns fatores que influenciam no comportamento dos ventos e que podem ser levados em conta no desenvolvimento das ferramentas.

No Capítulo 3 são apresentadas as ferramentas desenvolvidas. O Capítulo é dividido em duas partes de acordo com o tipo de abordagem das ferramentas e respeitando a ordem cronológica em que foram desenvolvidas. Na primeira parte são apresentadas as ferramentas baseadas em hipóteses sobre o comportamento do vento, enquanto que na segunda parte são apresentadas ferramentas que lidam diretamente com as sazonalidades.

No Capítulo 4 são feitas as conclusões tendo em vista os resultados encontrados e apresentadas propostas de continuidade para trabalhos futuros.

1.4 Estado da Arte

O método conhecido como MCP (medir-correlacionar-prever) busca mapear a relação entre duas estações de medição possibilitando a previsão dos dados, em uma das estações, a partir dos dados da outra. As principais aplicações destes métodos é fazer o ajuste de longo prazo e completar “buracos” nos dados. O método é composto das seguintes etapas:

1. *Medir*

É necessário obter dados das duas estações, que serão correlacionadas, com períodos de medição coincidentes. De forma geral, uma estação possui dados medidos no local do projeto (estação do projeto), com apenas poucos anos, enquanto a outra estação possui dados de longo prazo (estação de referência). A Figura 1.6 apresenta um exemplo de dados medidos em duas estações, com períodos coincidentes.



Figura 1.6 – Dados medidos no local do projeto e dados de longo prazo medidos em uma estação de referência com períodos coincidentes.

2. Correlacionar

Através dos dados coincidentes, algum método de correlação é aplicado para mapear a relação entre as estações. A Figura 1.7 indica esse processo de mapeamento.

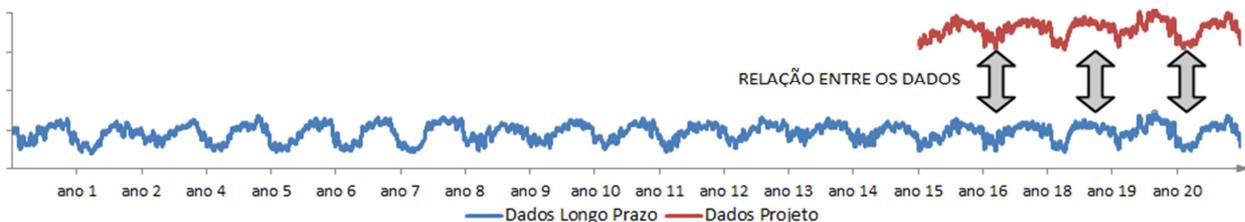


Figura 1.7 – O período coincidente é utilizado para se obter a relação entre os dados.

3. Prever

As relações encontradas na etapa anterior são aplicadas a todo o período de longo prazo da estação de referência de forma a prever os dados na estação do projeto durante todo longo prazo disponível. A Figura 1.8 indica que é feita a previsão dos dados através dos dados de longo prazo.

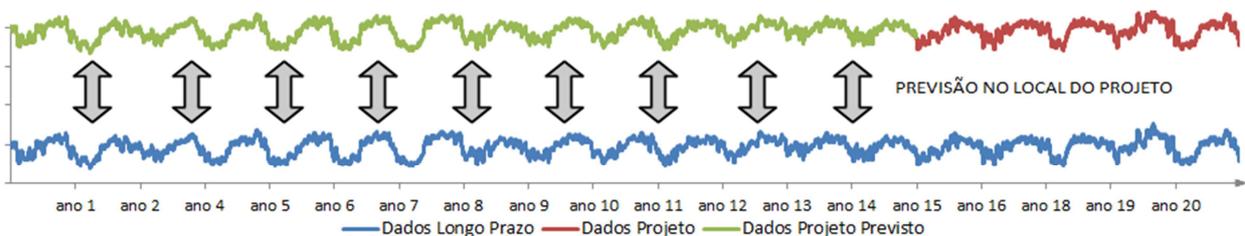


Figura 1.8 – A relação obtida é utilizada para prever os dados na estação do projeto utilizando-se os dados de longo prazo.

Existem diversas variações desse método, sendo que em todas elas apenas é modificado o método de correlação, ou seja, a 2ª etapa do MCP. ROGERS et al. (2005a) MORTIMER, (1994), DERRICK (1992), WOODS et al. (1997), TAYLOR et al. (2004), e BECHRAKIS et al. (2004) têm explorado esta metodologia, com várias técnicas de correlação. Nos próximos itens serão apresentadas as principais variações do MCP.

TÉCNICAS DE CORRELAÇÃO

Regressão Linear Simples

O método da regressão linear simples é o mais utilizado para modelar a relação entre as velocidades do vento em duas estações e foi introduzido por DERRICK (1992). Inicialmente os dados de ambas as estações são separados em setores de direção, tendo como base a estação de referência. Em seguida, para os dados de velocidade de cada um dos setores é feita uma regressão linear. A equação que modela a relação em cada setor pode ser expressa como:

$$\hat{y} = \beta_0 + \beta_1 x \quad (1)$$

onde x é a velocidade do vento no local de referência, \hat{y} é a velocidade do vento prevista no local de destino, e β_0 e β_1 são respectivamente os coeficientes linear e angular da equação linear. A Figura 1.9 ilustra este método.

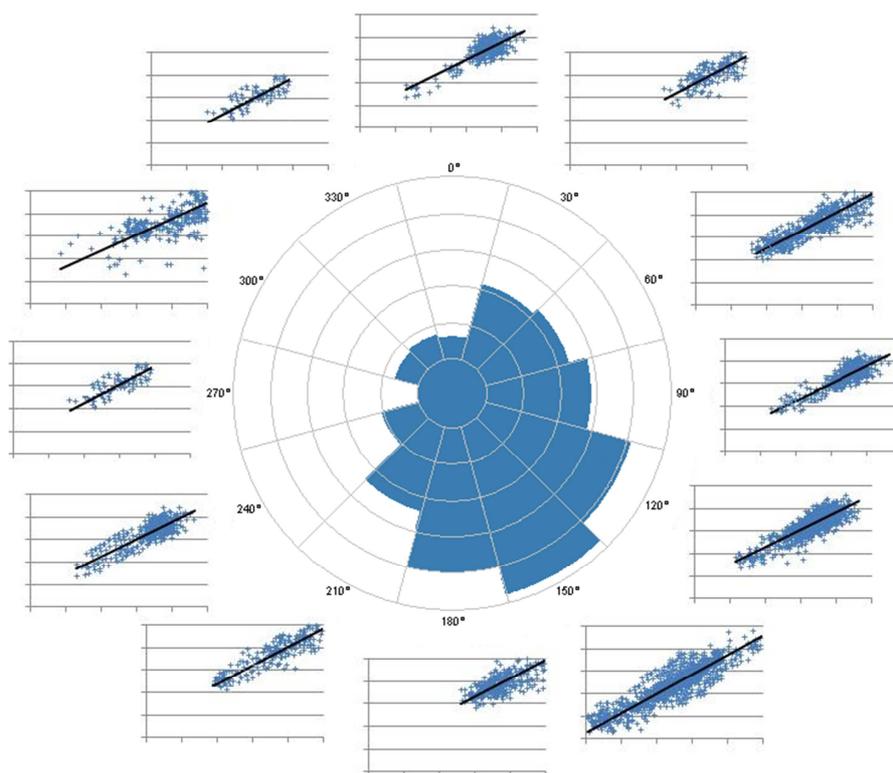


Figura 1.9 – Regressão linear entre os dados das estações para cada setor de direção.

Quando é utilizada a regressão linear, a velocidade média prevista na estação do projeto será próxima à média medida no período de treinamento. No entanto, ROGERS et al. (2005a) notaram que a variância prevista será menor que a variância medida na estação de projeto de acordo com a seguinte expressão:

$$\hat{s}^2 = s^2 r^2 \quad (2)$$

onde \hat{S}^2 e S^2 são as variâncias prevista e medida da velocidade do vento, respectivamente e r^2 é o coeficiente de determinação da regressão linear. Devido à relação não-linear entre a velocidade do vento e a energia produzida pelos aerogeradores, essa diferença pode resultar em significativas variações nas estimativas dos recursos eólicos, principalmente para situações onde a correlação entre as estações é baixa.

Método da razão de variância

O método da razão de variância foi desenvolvido por ROGERS et al. (2005a), em resposta ao problema da variância mencionado anteriormente. Trata-se de forçar que a variância da velocidade do vento prevista no local do projeto seja igual a variância medida. A equação deste método é descrita da seguinte forma:

$$\hat{y} = \left(\bar{y} - \frac{s_y}{s_x} \bar{x} \right) + \frac{s_y}{s_x} x \quad (3)$$

onde x é a velocidade do vento na estação de referência, s_x e s_y são os desvios-padrão da velocidade do vento medidos nos locais de referência e de projeto, respectivamente, \bar{x} e \bar{y} são as médias das velocidades do vento nos locais de referência e de projeto, e \hat{y} é a velocidade do vento prevista no local de projeto.

Uma grande limitação desses dois métodos apresentados consiste na hipótese implícita de que a quantidade de registros em cada setor de direção de ambas as estações é equivalente. Em outras palavras, supõe-se que os histogramas de direção são semelhantes. No entanto, em terrenos complexos, é comum uma mudança de direção do vento entre as estações e, portanto, a hipótese de quantidade de ocorrências equivalente nos setores de direção nem sempre é válida.

Este método é mais indicado que o anterior quando se deseja utilizar os dados na estimativa de produção, tendo em vista que as curvas dos aerogeradores (potência versus velocidade do vento) são fortemente não lineares e, portanto, muito sensíveis a mudanças nas variâncias dos dados.

Método da Matriz

O método da matriz, WOODS et al. (1997), busca tratar a limitação dos métodos anteriores proporcionando uma melhor representação nos casos em que há diferença significativa nas rosas de direção das estações.

O método cria uma matriz que representa o número de registros em cada setor de direção de ambas as estações. Por exemplo, se cada setor compreender 30° , haveria 12 setores de direção. No caso

ideal, se ambas as estações fossem equivalentes o resultado seria uma matriz puramente diagonal. A Tabela 1.1 apresenta esta matriz para um caso qualquer, apenas para exemplificar.

Tabela 1.1 – Exemplo de matriz com os registros de direção de ambas as estações.

Setores de Dir. - Est. de Proj.	Setores de Direção - Estação de referência											
	1	2	3	4	5	6	7	8	9	10	11	12
1	480	118	25	3	3	3	6		1	9	17	95
2	42	175	115	37	12	8	2			1	10	9
3	14	47	130	96	12	19	2	1			3	3
4	14	79	125	73	17	6	2				4	1
5	8	20	57	143	349	265	17		1	4	2	7
6		4	8	7	39	763	70			1	3	2
7	3	6	7	2	3	191	932	62	5	6	10	1
8			2	1	1	4	178	744	165	18	7	1
9				1		2	38	70	567	148	9	3
10	1	1		1		3	14	10	70	550	76	6
11	2			1		4	10	2	3	87	340	61
12	119	4	5	3	2	1	8	3	1	17	108	443

Esta matriz proporciona uma descrição completa das direções encontradas em ambas as estações. A partir dela são geradas outras duas matrizes que representam o percentual de registros em cada setor, onde cada matriz tem como base uma das estações. A Tabela 1.2 e a Tabela 1.3 apresentam qual seriam os resultados considerando o mesmo exemplo anterior. Normalmente é aplicado um filtro para eliminar os casos pouco representativos.

Tabela 1.2 - Percentual de registros, $W_{i,j}$. O somatório em cada setor da estação de referência é 100%.

Setores de Dir. - Est. de Proj.	Setores de Direção - Estação de referência											
	1	2	3	4	5	6	7	8	9	10	11	12
1	74,9	34,7										15,9
2	6,5	51,5	30,2	9,2								
3		13,8	34,1	23,9								
4			20,7	31,2	17,3							
5			15	35,7	82,7	21,7						
6						62,6	5,9					
7						15,7	79					
8							15,1	91,4	20,6			
9								8,6	70,7	18,8		
10									8,7	70,1	14,5	
11										11,1	64,9	10,1
12	18,6										20,6	74
Soma	100	100	100	100	100	100	100	100	100	100	100	100

Tabela 1.3 - Percentual de registros, $Z_{i,j}$. O somatório em cada setor da estação do projeto é 100%.

Setores de Dir. - Est. de Proj.	Setores de Direção - Estação de referência												Soma
	1	2	3	4	5	6	7	8	9	10	11	12	
1	69,3	17	13,7										100
2	11,4	47,4	31,2	10									100
3		17,2	47,6	35,2									100
4			28,5	45,1	26,4								100
5			7	17,6	42,9	32,5							100
6						91,6	8,4						100
7						17	83						100
8							16,4	68,4	15,2				100
9								8,9	72,2	18,9			100
10									10,1	79	10,9		100
11										17,8	69,7	12,5	100
12	17,8										16,1	66,1	100

A Tabela 1.2 permitirá calcular a equivalência entre a quantidade de registros encontrados na estação de referência e a quantidade prevista para a estação do projeto para cada setor de direção através da seguinte expressão:

$$\hat{p}_j = \frac{\sum_{i=1}^{12} p_i W_{i,j}}{100} \quad (4)$$

Onde \hat{p}_j é a quantidade de registros estimada para a estação de projeto no setor j , p_i é a quantidade de registros na estação de longo prazo no setor i , e $W_{i,j}$ são os elementos da tabela que indica o percentual em cada setor pela estação de referência.

Para calcular a velocidade estimada na estação do projeto basta ponderar as relações encontradas pela regressão linear obtida em cada setor, como nos métodos anteriores, expresso por:

$$\hat{v}_j = \frac{\sum_{i=1}^{12} Z_{i,j} (m_i v_i + c_i)}{100} \quad (5)$$

Onde \hat{v}_j é a velocidade estimada na estação do projeto, v_i é a velocidade na estação de longo prazo, m_i e c_i são os coeficientes angular e linear, respectivamente, encontrados através da regressão em cada setor, e $Z_{i,j}$ são os percentuais obtidos em cada setor da estação do projeto, conforme a Tabela 1.3.

Este método é recomendado principalmente quando é verificado que as rosas de frequência entre as estações são muito distintas.

Método do ajuste de Weibull

Em grande parte dos casos o vento pode ser satisfatoriamente modelado pela distribuição de Weibull, que possui um parâmetro de forma A e um parâmetro de escala K. O *Ajuste de Weibull* é um método empírico bastante simples que busca fazer uma manipulação linear diretamente nos parâmetros da distribuição de Weibull das estações. O método tem a vantagem de estar consistente com a natureza do vento para a maioria dos casos. No entanto, é preciso estar atento para locais onde o vento não possui distribuição do tipo Weibull, ou quando as diferenças entre os parâmetros são muito grandes.

Além disso, ajustar linearmente os parâmetros da distribuição é uma hipótese bastante simples e até mesmo ousada. É importante que a distribuição das direções entre as estações sejam similares para que o método seja coerente, além de funcionar melhor quando apenas são necessárias pequenas correções. O método presume as seguintes relações:

$$\hat{A}_{proj} = \left(\frac{A_{proj}}{A_{LP}^c} \right) \cdot A_{LP} \quad (6)$$

$$\hat{K}_{proj} = \left(\frac{K_{proj}}{K_{LP}^c} \right) \cdot K_{LP} \quad (7)$$

Onde \hat{A}_{proj} e \hat{K}_{proj} são os parâmetros da distribuição de Weibull de longo prazo estimados para a estação de projeto, A_{proj} e K_{proj} os próprios parâmetros da estação do projeto, A_{LP}^c e K_{LP}^c os parâmetros oriundos dos dados da estação de referência no período coincidente e, A_{LP} e K_{LP} os parâmetros da distribuição durante todo o período de longo prazo da estação de referência.

Métodos utilizando Redes Neurais Artificiais (RNAs)

RNAs têm sido usadas para correlacionar e prever dados de vento por causa de sua capacidade para reconhecer padrões em casos não lineares. Simplificadamente, RNAs são compostas por "neurônios" interligados que recebem um conjunto de entradas ponderadas (Figura 1.10). A saída de cada neurônio, em muitos casos, é uma função logística da soma ponderada das entradas menos um valor específico para cada neurônio.

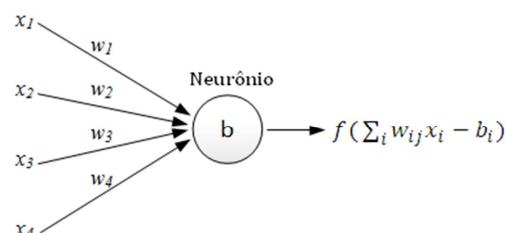


Figura 1.10 – Esquema de um neurônio básico.

Em uma rede neural feedforward, os neurônios são organizados em camadas, onde nenhuma conexão lateral ou para trás são permitidas (Figura 1.11). A primeira camada da rede é a camada de entrada. No caso da previsão do vento, esta seria os dados da estação de referência. As camadas internas da rede são chamadas de camadas intermediárias e a camada final, ou camada de saída, apresenta o resultado da previsão, ou a velocidade do vento no local do projeto. MOHANDES et al. (1998), ALEXIADIS et al.(1998), ADDISON (2000) e BECHRAKIS et al. (2004) utilizaram redes neurais para prever a velocidade do vento.

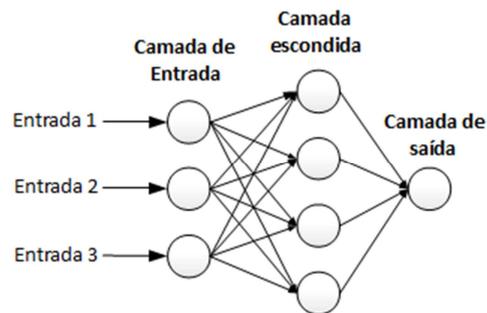


Figura 1.11 – Rede Neural feedforward de 3 camadas.

Uma vez que a RNA é definida, um algoritmo de treinamento supervisionado é empregado para determinar os pesos associados a cada neurônio. Este algoritmo atualiza iterativamente os pesos para minimizar uma função de erro, definida como a média dos resíduos ao quadrado entre a saída prevista e a saída conhecida. Muitos algoritmos de treinamento estão disponíveis e a maioria se baseia na determinação do gradiente da função erro com respeito aos pesos da rede neural. De acordo com ADDISON (2000) métodos baseados em Redes Neurais podem melhorar a acurácia da previsão de 5 à 12%.

Método da Probabilidade Conjunta

RAMÓN G. (2004) propõe um método puramente estatístico usando uma técnica de probabilidade conjunta. Segundo o autor, as vantagens deste método são que a necessidade de boa correlação entre as estações analisadas são relaxadas e até mesmo o fato dos dados de vento das estações estarem perfeitamente sincronizados não é tão importante. A condição de “simultaneidade” dos dados é convertida na condição de “similaridade”. Além disso, a quantidade de dados exigida para a obtenção de bons resultados é menos proporcional quando comparados aos métodos clássicos de MCP.

2 O vento

Neste capítulo são apresentados alguns dos principais fatores na geração do vento, assim como os dados utilizados neste trabalho.

2.1 Principais causas

O vento é o deslocamento de massas de ar que ocorrem pelas diferenças de pressão. As massas de ar sempre se deslocam das regiões de alta pressão para as de baixa pressão. Entre os principais mecanismos atuantes, destaca-se o aquecimento desigual da superfície terrestre, que ocorre tanto em escala global quanto local, assim como o movimento de rotação do planeta.

Influencias globais

Do ponto de vista global, existem dois fatores relacionados com as radiações solares que influenciam os ventos. O primeiro ocorre em função da maior área de absorção de calor nas regiões próximas a linha do equador, fazendo com que esta zona tenha temperaturas mais altas que nos pólos e criando uma componente em direção ao equador. O segundo fator é resultado do fato que durante o dia as temperaturas são maiores que durante a noite e, por este motivo, o vento tende a seguir as regiões iluminadas pelo dia. Além desses fatores, os ventos recebem a influencia da força de Coriolis causada pelo movimento de rotação da terra acentuando consideravelmente a componente na direção oeste. A Figura 2.1 apresenta os três principais fatores globais, onde as cores escuras representam zonas mais frias. No primeiro globo as zonas mais frias se deslocam em função do dia.



Figura 2.1 – Principais influencias globais do vento.

Como o sistema atmosférico é um sistema fechado, sempre que o ar de determinada região se desloca, um “novo” ar deve ocupar o local “desocupado”, de maneira que se formam circuitos de vento. A Figura 2.2 representa as resultantes dos principais efeitos globais do vento.

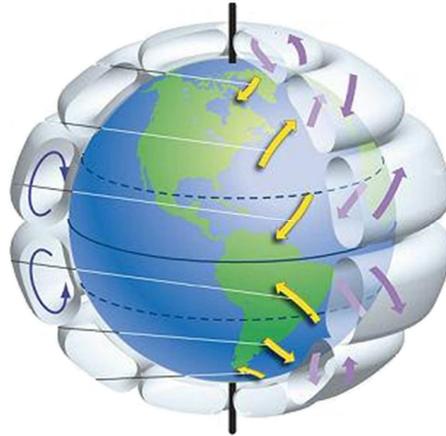


Figura 2.2 – Circulação global do vento (www.topnews.in).

Influências locais

Como a superfície terrestre não é uniforme, mas composta por zonas de terra e mar, com relevos e vegetações diversos, os ventos globais acabam se perturbando em função dos fatores locais. Estas várias interações são extremamente complexas transformando o vento num fenômeno que embora caótico apresenta tendências muito marcantes.

Existem vários fatores locais que influenciam os ventos. Colinas e montanhas são regiões onde normalmente há um aumento na velocidade dos ventos. Isto é em parte resultado da própria altitude, visto que de forma geral o vento é maior na medida em que a altitude aumenta, em função dos efeitos da rugosidade e de obstáculos próximos ao solo. E também, em parte, resultado da aceleração do fluxo de vento que, em torno desse tipo de relevo, acaba sendo canalizado e aumentando assim sua velocidade.

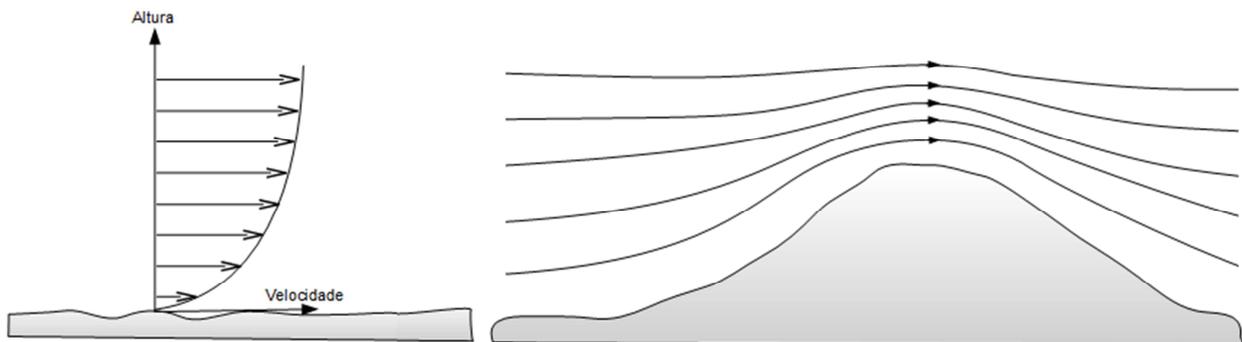


Figura 2.3 – Perfil de velocidade do vento e aceleração em relevos altos.

Por outro lado, em casos em que o relevo é muito íngreme o vento acaba se descolando causando zonas de baixa velocidade, como ilustrado na Figura 2.4.

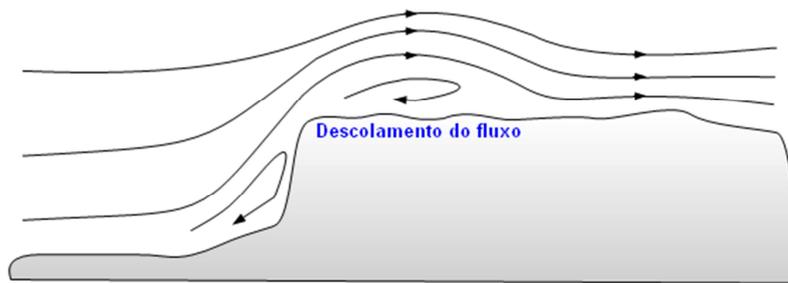


Figura 2.4 – Exemplo de relevos íngremes onde podem ocorrer descolamento do fluxo de vento.

Regiões costeiras são frequentemente ventosas por causa das diferenças de temperatura entre a terra e o mar. Durante o dia a terra é mais quente que o mar, gerando um movimento do ar que flui em direção a terra. A noite este movimento é invertido, visto que neste período é o mar que apresenta temperaturas maiores que a terra.

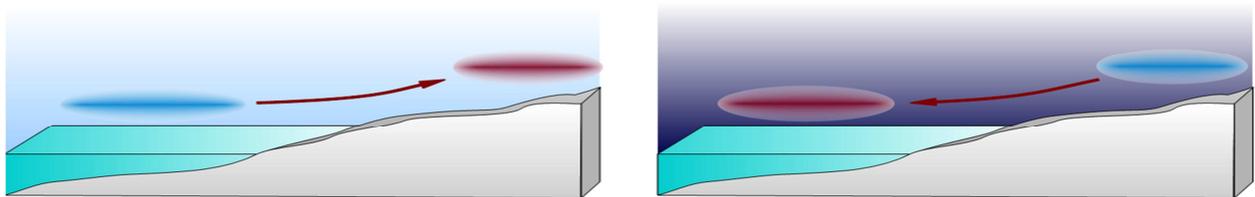


Figura 2.5 – Deslocamentos causados pelos efeitos terra-mar.

Os efeitos térmicos também podem ocorrer em função das diferenças de altitude. Desta forma, o ar frio das montanhas podem baixar para as zonas de baixas altitudes causando ventos descendentes. Naturalmente estes movimentos ocorrem formando círculos onde o ar quente sobe em função de sua densidade menor. Para o estudo em questão, estamos apenas interessados nas componentes que ocorrem próximas ao solo, pois podem ser aproveitados para geração de energia pelos aerogeradores atuais.

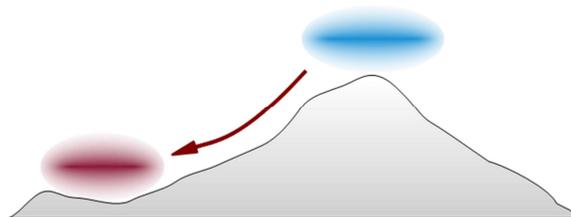


Figura 2.6 – Movimento causado pelas diferenças de temperaturas entre vales e colinas.

Ciclos e sazonalidades

Em função das influencias causadas pelo Sol, existem dois comportamentos periódicos típicos nos ventos, diário e anual. O diário, naturalmente, é causado pelo ciclo dia-noite. Por sua vez, o anual ocorre em função da translação da Terra ao redor do Sol determinando também as quatro estações e uma significativa variação de temperatura ao longo do ano. Assim, é natural que as velocidades e direções do vento apresentem sazonalidades diurnas e anuais, além do comportamento aleatório.

Existem também variações que ocorrem em períodos de longo prazo. No entanto, além de serem pouco compreendidas, estas variações são suaves e com pouco impacto no curto e médio prazo. Por estas razões, normalmente, não são levadas em conta nos estudos relacionados à energia eólica (DEMETRI *et al*, 1996).

2.2 Dados de vento utilizados na pesquisa

Para esta pesquisa foram utilizados dados de vento de 11 estações meteorológicas localizadas no estado do Rio Grande do Norte. Estes dados são de propriedade da empresa Iberdrola e, portanto, algumas informações comercialmente estratégicas, como a velocidade média e localização exata, foram omitidas sem prejudicar o conteúdo da pesquisa e seus resultados.

Foram selecionados dados medidos durante um ano completo, o mesmo ano para todas as estações. Estes dados foram estatisticamente analisados e filtrados com o objetivo de garantir uma boa consistência. O percentual de disponibilidade médio foi de aproximadamente 99%, significando uma qualidade excepcional dos dados utilizados.

A figura a seguir mostra a localização aproximada das 11 estações.

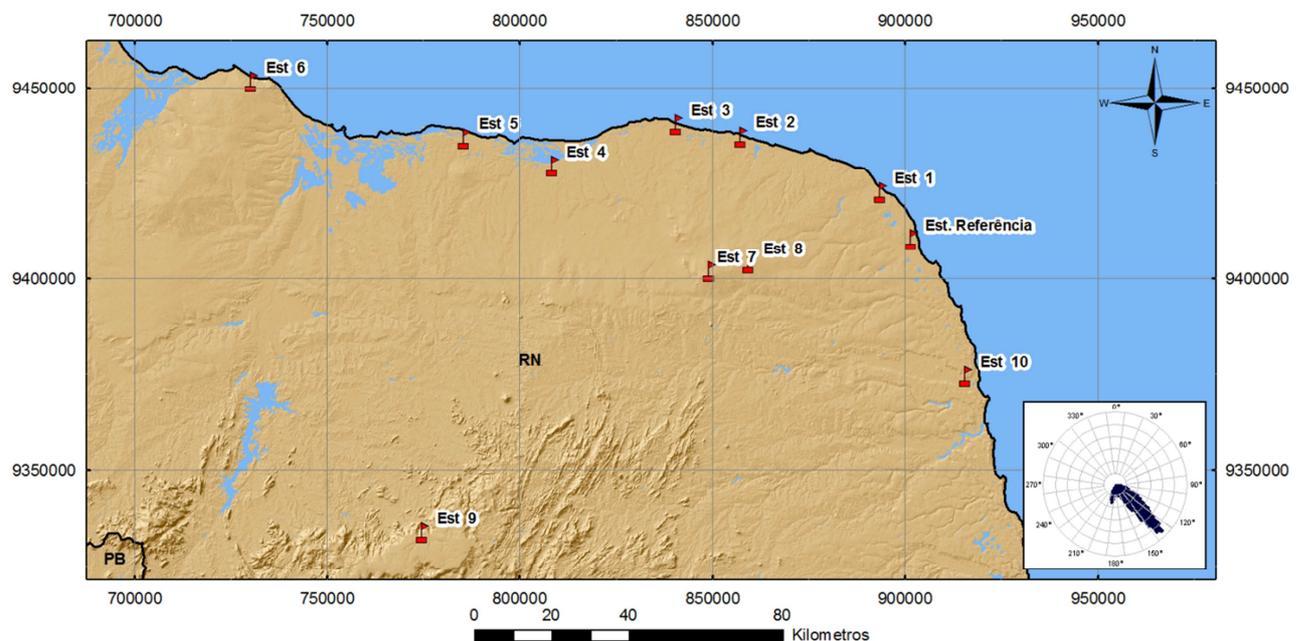


Figura 2.7 – Localização aproximada das estações utilizadas e direção predominante na estação de referência.

Os dados de vento para fins de energia eólica são comumente armazenados em médias de 10 minutos. Desta forma, num período de uma hora são registrados 6 valores, representando as médias de 10 minutos. Os dados analisado compreendem o período de um ano, de forma que são constituídos de 52.560 registros.

3 Desenvolvimento das ferramentas

Primeiramente, é importante ressaltar que o principal desafio das ferramentas desenvolvidas é encontrar relações entre duas estações de ventos nas quais se possui dados de vento num período coincidente. Este fato orienta a pesquisa para métodos que buscam relacionar diretamente os dados disponíveis, sem a necessidade de modelar o escoamento do vento através das equações de Navier-Stokes. Tais equações seriam indicadas principalmente nos casos em que se dispusesse apenas de uma estação de medição e se objetivasse estimar o vento numa outra localidade a partir destes dados.

Levando em conta as características dos ventos como sazonalidades, influências globais e locais, e também considerando alguns resultados preliminares, tais como os apresentados a seguir no item 3.1.1, foram desenvolvidas duas linhas distintas de ferramentas de correlação. Embora por um lado cada abordagem seja independente, com premissas próprias e técnicas específicas, por outro lado elas são complementares, na medida em que tratam de partes complementares dos dados.

Os dados de vento podem ser entendidos como sendo compostos por duas partes, relativa as sazonalidades e a outra que será chamada de resíduos ou, oscilações de frequências mais altas e aleatórias. A Figura 3.1 ilustra um trecho de dado de vento de 3 dias sendo decomposto nestas duas partes. Como pode ser visto, a parte das sazonalidades é muito similar nos 3 dias, enquanto que a componente residual possui comportamento bastante aleatório.

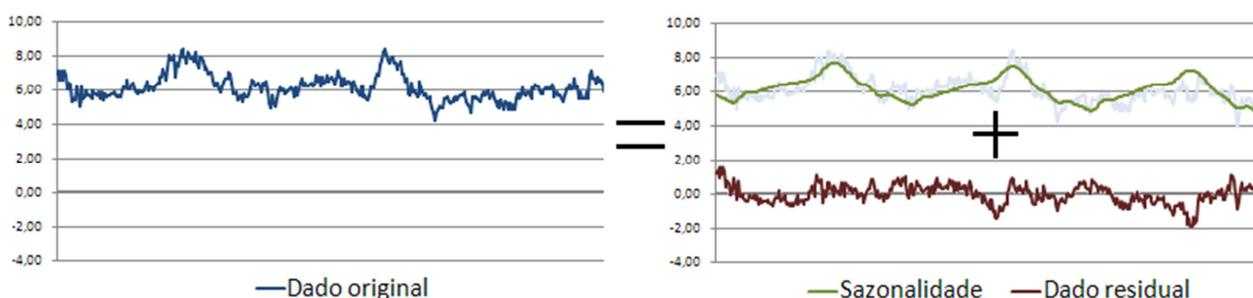


Figura 3.1 – Dado de vento sendo decomposto em sazonalidade e Dado residual.

As primeiras ferramentas tratam apenas da parte residual, buscando encontrar correlações entre as estações que não estejam vinculadas as sazonalidades. As ferramentas tentam fazer uso de fenômenos físicos baseados na trajetória percorrida pelo vento e buscam incorporar nos métodos de correlação parâmetros como distância entre estações, direção e velocidades médias do vento. Neste sentido, espera-se que algumas características do vento sejam mantidas durante sua trajetória, podendo ser detectadas por estes métodos de correlação.

Por outro lado, a segunda linha de ferramentas de correlação busca analisar a correlação entre as sazonalidades das estações, específicas de cada região. Nestas ferramentas não são levados em conta às distâncias entre as estações e nem a direção do vento. O objetivo é tentar mapear as sazonalidades de forma a aumentar a correlação entre as estações.

3.1 Ferramentas para dados residuais

3.1.1 Hipóteses

Os métodos tradicionais abordam o problema de correlação através da linearização da relação entre as frequências de ocorrência do vento em cada setor de direção. Estas abordagens, portanto, não levam em conta a dinâmica do vento e, por assim dizer, trabalham apenas no domínio da frequência, desconsiderando o domínio do tempo.

Ao se analisar a correlação entre estações, percebe-se que o coeficiente de correlação é maior à medida que agrupamos os dados em médias de períodos maiores. Em outras palavras, a correlação dos dados de médias diárias é maior que a correlação dos dados de 10 minutos. Por sua vez, a correlação em médias mensais é maior que em médias diárias e assim por diante. A Figura 3.2 mostra a variação da correlação da velocidade do vento em cada estação auxiliar com a estação de referência em função do intervalo considerado para os dados.

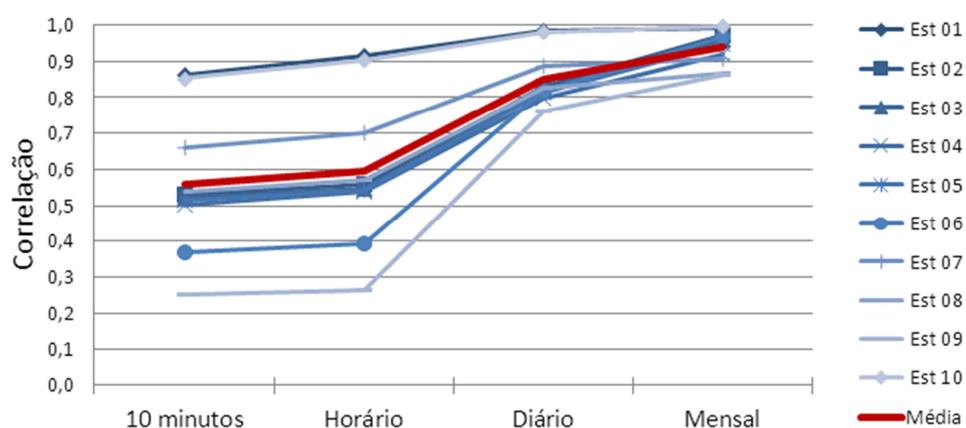


Figura 3.2 – Correlação estação de referência Vs. estações auxiliares em vários intervalos.

Uma explicação para este resultado estaria no fato de que embora os dados estejam relacionados entre si, as variações da velocidade do vento, medidas em cada estação, podem não ocorrer de forma sincronizada. Ou seja, uma mudança de velocidade que ocorra em determinada estação poderá também ocorrer em outra estação próxima, mas com algum intervalo de diferença. Desta forma, a correlação nos dados de 10 minutos pode não captar de forma adequada a relação entre as estações. Por outro lado, a correlação entre dados de médias diárias, ou mensais, poderia melhor

mapear esta relação, por permitir que as variações do vento em cada estação ocorram com alguma defasagem de tempo.

A partir desta observação surge a questão de que talvez fosse melhor considerar algum passo de defasagem ao se correlacionar os dados de 10 minutos, ao invés de utilizar os dados sincronizadamente. Para verificar essa possibilidade foi realizado um correlograma nos dados de forma a se obter a correlação entre as estações em função de vários passos de defasagem no tempo. A Figura 3.3 mostra o resultado do correlograma para as 5 estações que foram utilizadas no início da pesquisa. No gráfico, as defasagens ocorrem em passos de 10 minutos.

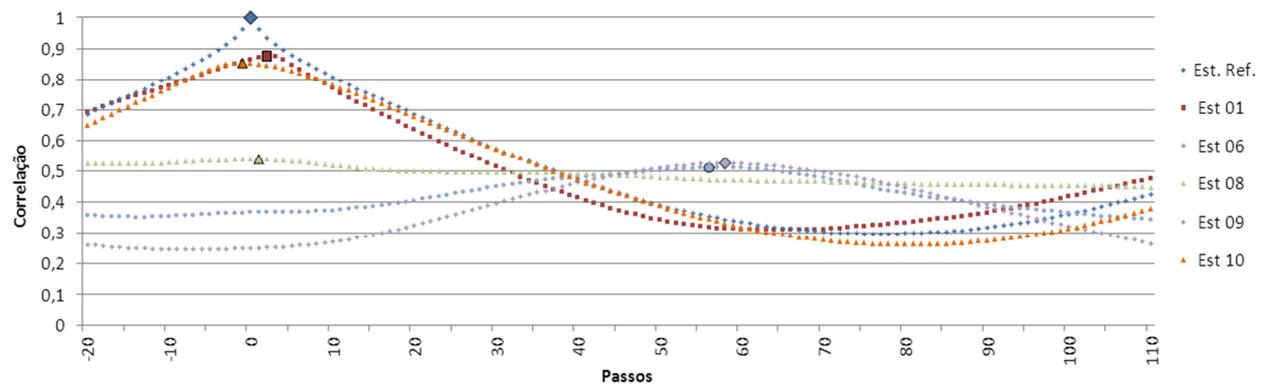


Figura 3.3 – Correlograma estação de referência Vs. Estações auxiliares, incluindo a Autocorrelação da estação de referência.

Através do correlograma fica evidente que cada estação possui um determinado passo que maximiza a correlação. No caso específico destas 5 estações, é possível ainda observar que os passos encontrados são proporcionais “grosso modo” às distâncias entre as estações, sobretudo para as maiores distâncias. A Figura 3.4 apresenta, de forma normalizada, os valores dos passos do correlograma assim como as distâncias das estações para a estação de referência.

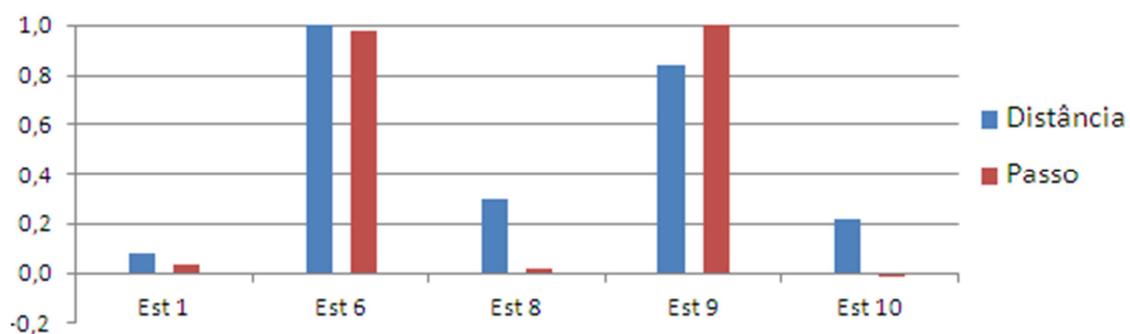


Figura 3.4 – Comparação entre passos do correlograma e distâncias entre estações.

Para se ter uma ideia da proporcionalidade destes resultados, a correlação (Distância Vs Passo) para estas 5 estações é 0.96, o que representa uma alta correlação.

Este resultado faz pensar que, após passar por uma estação, o vento leva determinado tempo até chegar à outra estação e que, desta forma, a correlação é máxima quando se considera uma defasagem de tempo proporcional a distancia percorrida.

Com o objetivo de tentar verificar esta relação, buscou-se definir hipóteses com o máximo de simplicidade possível apenas para sustentar ferramentas de análise preliminar.

Hipótese da trajetória

Da mesma forma que sinais sonoros se propagam pelo espaço através de um meio, seria possível pensar que algo equivalente poderia acontecer com os ventos. No sentido de que uma oscilação da velocidade do vento poderia ser transportada no espaço na direção de incidência deste. Sendo assim, estações de medição distantes entre si poderiam captar estas mesmas oscilações, porém em momentos diferentes. Este tempo de defasagem seria uma função do tempo que o vento leva para percorrer a distancia entre as estações.

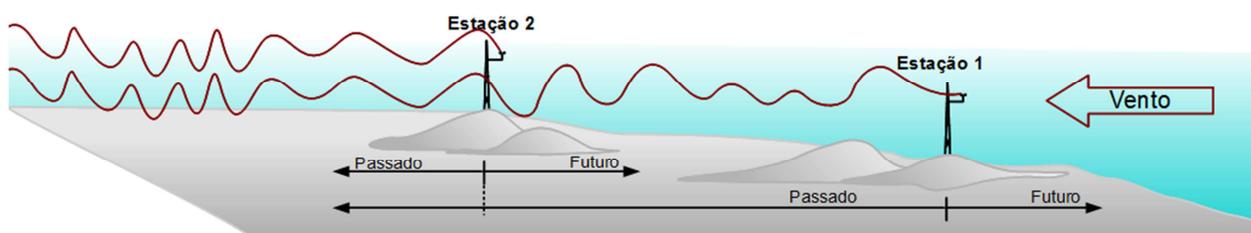


Figura 3.5 – Hipótese da trajetória do vento ilustrando o deslocamento do comportamento do vento no espaço.

Esta hipótese poderia explicar as defasagens encontradas no correlograma, que são proporcionais as distâncias. No entanto, naturalmente, o resultado do correlograma por si só não seria suficiente para sustentar esta hipótese, tendo em vista que não é levado em conta características importantes do vento. O correlograma, por exemplo, não leva em conta a natureza vetorial do vento, que varia tanto em velocidade quanto em direção. Desta forma, o passo que maximiza a correlação dependeria não apenas da distancia entre as estações, mas também da velocidade e da direção em que o vento está incidindo. Além disso, haveria que se considerar outras características como a rugosidade e a orografia entre as estações.

Para se verificar esta hipótese de forma mais adequada deve-se analisar as correlações e os passos de defasagem nos diversos casos de velocidade e direção, o que requer métodos mais específicos do que o correlograma.

Para ilustrar como os passos estimados poderiam variar em função da direção de incidência do vento, as figuras abaixo apresentam dois casos onde as direções são distintas. Na Figura 3.6 a trajetória percorrida pelo vento é significativamente maior que a trajetória percorrida na Figura 3.7. Da

mesma forma, espera-se que o passo de defasagem que maximiza a correlação seja proporcional as estas trajetórias.

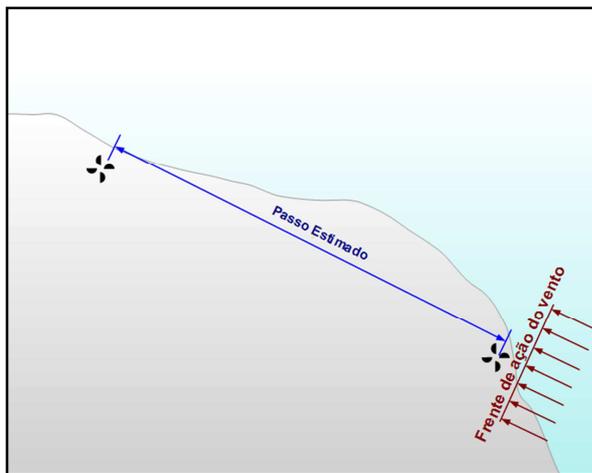


Figura 3.6 – Direção do vento Vs. Distância para cálculo do passo estimado.

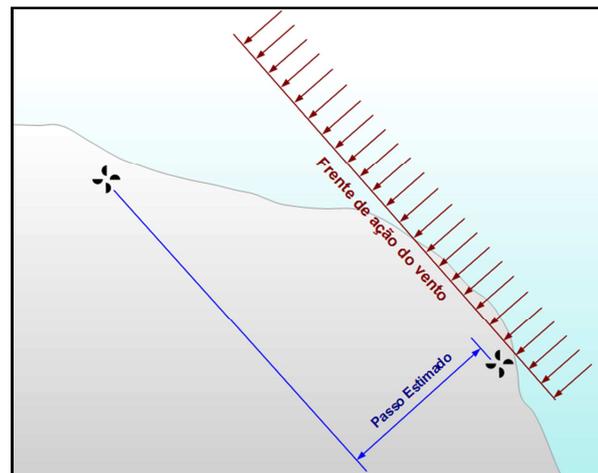


Figura 3.7 - Direção do vento Vs. Distância para cálculo do passo estimado.

Hipótese da frente de ação do vento

Para que esta hipótese da trajetória seja consistente com várias direções do vento, é necessário assumir uma segunda hipótese que é chamada de “frente de ação do vento”. Esta hipótese implica dizer que o vento se comporta de forma similar ao longo de uma determinada extensão adjacente. As figuras anteriores ilustram a necessidade de se assumir essa hipótese. É razoável pensar que esta “frente de ação” faça sentido numa extensão determinada, tendo em vista que o vento de localidades próximas são gerados através das mesmas influências externas, além de estarem ligados pelas forças viscosas do ar. Naturalmente, na medida em que a distância aumenta o comportamento do vento perderia as características similares, por estarem sujeitos a influências distintas. No entanto, apesar de que esta limitação esteja evidente, será interessante analisar como se comporta o vento em determinada região efetivamente, além de analisar até qual distância a hipótese faria sentido.

Sendo assim, e ainda assumindo diversas simplificações, esse modelo da defasagem estimada poderia ser expresso matematicamente pela seguinte expressão:

$$dist_{projetada} = dist_{estações} \cdot U_{dir} = |dist_{estações}| |U_{dir}| \cos \alpha dist_{estações}, U_{dir} \quad (8)$$

$$Passo_{Estimado} = \frac{Dist_{projetada}}{Vel_{média}} \quad (9)$$

Onde:

$dist_{projetada}$ é a trajetória estimada do vento até que a frente de ação do vento chegue na outra estação, $dist_{estações}$ é a distância entre as estações estudadas, U_{dir} é o vetor unitário que indica a direção de incidência do vento e $Passo_{Estimado}$ é o tempo que o vento levaria para chegar a outra estação.

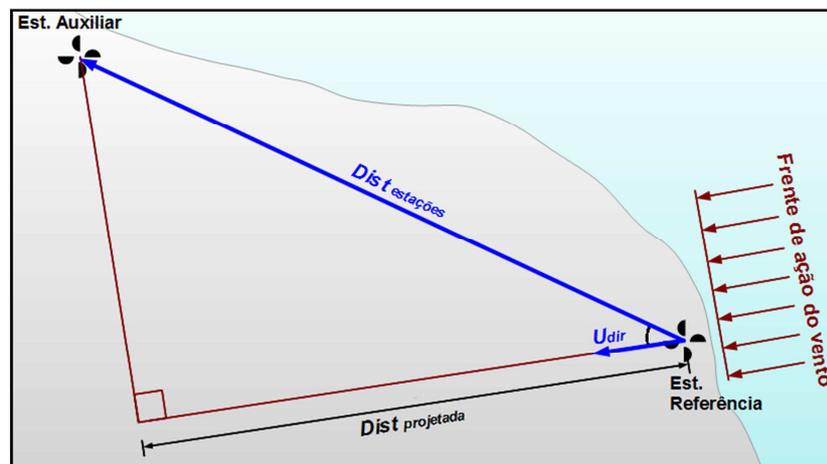


Figura 3.8 – Cálculo do Passo estimado.

A equação (8) estima a distância que o vento deve percorrer entre as estações, considerando uma frente de ação. Para tanto, basta obter o produto escalar entre o vetor distância entre as estações e o vetor unitário da direção do vento.

Para se estimar o tempo de defasagem da “frente de ação”, assumindo que a velocidade do vento se mantém constante, bastaria dividir a distância projetada, pela velocidade média do vento, conforme equação (9).

É importante ressaltar que estas fórmulas representam apenas um parâmetro de referência, visto que o modelo é muito simplificado além de assumir hipóteses ainda não verificadas. A intensão deste trabalho não é explorar as equações da dinâmica dos fluidos, mas ao invés, tentar identificar empiricamente relações entre os dados de vento disponíveis em duas estações. Optou-se por simplificar ao máximo os modelos de deslocamento do vento para facilitar na definição de experimentos bem controlados, até porque nesta etapa da pesquisa a idéia é fazer apenas uma sondagem preliminar desta linha de pesquisa.

3.1.2 Ferramenta 1

A primeira ferramenta desenvolvida tem a finalidade de encontrar os passos que maximizam a correlação entre duas estações de vento para os vários casos de velocidade e direção. Desta forma, para uma determinada direção e velocidade busca-se saber qual a defasagem que maximiza a correlação entre as estações.

Esta ferramenta é composta por 4 etapas as quais serão descritas a seguir. Por convenção, a estação principal, comum a todas as análises, será chamada de “Estação de Referência”, enquanto as outras serão chamadas de “Estações Auxiliares”.

1ª Etapa – De-sazonalização dos dados

Para evitar que a ferramenta encontre altas correlações decorrentes dos comportamentos sazonal que ocorrem em função dos ciclos diários é necessário “desazonalizar” os dados. De outra forma, é de se esperar que ocorram altas correlações simplesmente em função das oscilações causadas pelas sazonalidades diárias. Estas correlações podem ocorrer com defasagens de vários dias, como é ilustrado na Figura 3.9, independentemente da trajetória percorrida pelo vento. Sempre que os ciclos diários das estações entrarem em fase, poderá ocorrer alta correlação. Mas ao contrário, esta ferramenta objetiva apenas analisar a existência de correlações decorrentes do deslocamento do vento no espaço, que não seja causado pelos ciclos diários. O processo para estimar a sazonalidade do vento é descrito em detalhes no anexo A

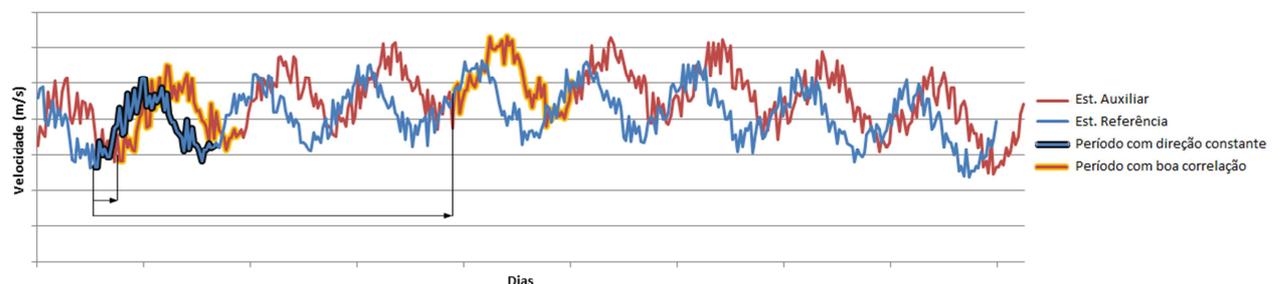


Figura 3.9 – Ilustra que altas correlações podem ocorrer com vários dias de defasagem em função dos ciclos diários.

2ª Etapa – Seleção de períodos com direção constante

Para o estudo específico da frente de ação do vento é necessário selecionar períodos onde o vento possui uma direção bem definida, com poucas variações. Tendo em vista que o passo estimado depende da direção do vento, é necessário analisar períodos em que a direção é praticamente constante, pois de outra forma a trajetória do ar não seria linear impossibilitando a estimativa de um passo de defasagem.

Dois parâmetros podem ser ajustados nesta etapa, o tamanho do período e o desvio-padrão máximo da direção. É importante definir um tamanho de período que contenha dados suficientes para que o valor da correlação seja representativo. Se o período for muito curto ainda que a correlação seja alta

ela pode não ser válida. Por outro lado, o desvio-padrão deste período não deve ultrapassar um determinado valor, garantindo que o vento tenha direção bem definida.

A ferramenta fará uma varredura em todo o dado de vento da estação de referência, buscando trechos com o tamanho definido e com desvio-padrão menor ou igual ao limite especificado. A Figura 3.10 ilustra a seleção de dois períodos que cumpriram os critérios especificados. Note que a busca é feita nos dados de direção, no entanto todos os dados são selecionados.

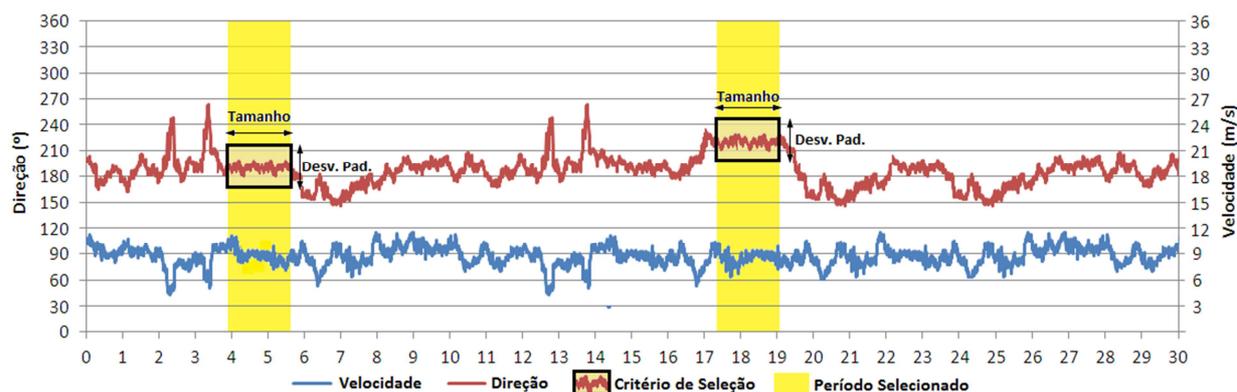


Figura 3.10 – Exemplo de dois períodos que passaram nos critérios de seleção.

3ª Etapa – Busca de correlação máxima

Cada período encontrado na 2ª etapa é correlacionado com cada uma das estações auxiliares. Nesta etapa são utilizados os dados de velocidade do vento. A correlação é feita considerando diversos passos de defasagens no intuito de encontrar aquele que possui a melhor correlação com a estação de referência. Desta forma cada período selecionado na estação de referência (etapa 2) fica vinculado a um período na estação auxiliar, através do passo de defasagem que maximizou a correlação. A expressão que calcula a correlação pode ser descrita por:

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (10)$$

Onde x_i e y_i são os dados da estação auxiliar e de referência e \bar{x} e \bar{y} as médias das estações, respectivamente.

Nesta etapa devem ser definidos outros dois parâmetros fundamentais, o tamanho do *espaço de busca*, e a *correlação mínima* aceitável. O *espaço de busca* restringe a varredura, evitando que sejam analisados períodos muito “afastados” no tempo e de fato não correlacionados. Por sua vez, a *correlação mínima* aceitável faz com que sejam rejeitados os casos em que não foram encontrados períodos com boa correlação. Em outras palavras, se a correlação máxima encontrada entre as estações for muito baixa, este caso será descartado.

Considerando que as estações estão situadas em distintos locais, espera-se que o passo encontrado seja proporcional “grosso modo” a distância entre elas. Neste sentido, espera-se que uma estação próxima tenha um passo de defasagem pequeno, enquanto que estações distantes, passo maiores. Portanto, o espaço de busca deveria, de alguma forma, levar em conta a distância entre as estações. A forma encontrada para incorporar esta questão foi centralizar o *espaço de busca* em função do *passo de estimado*, definido pelas equações (8) e (9). Ainda que o *passo estimado* seja uma aproximação pouco precisa servirá como um parâmetro de orientação do *espaço de busca*. A Figura 3.11 ilustra o processo de busca da correlação máxima indicando que o espaço de busca é centralizado pelo *passo estimado*

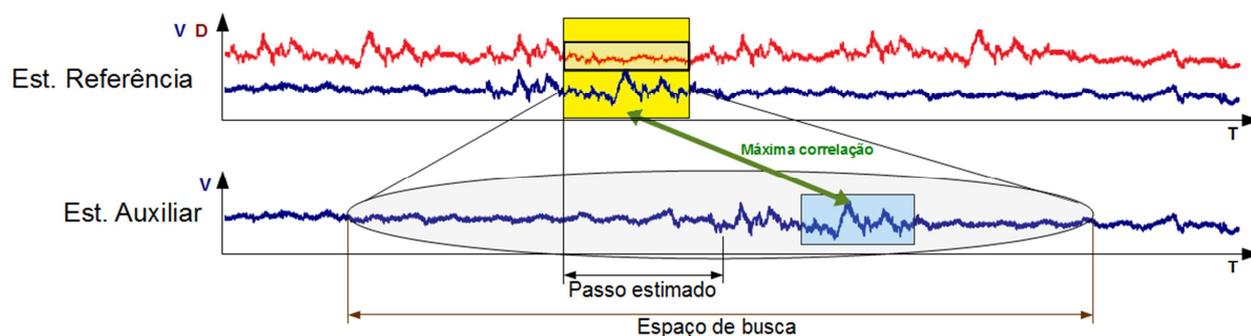


Figura 3.11 – Varredura para encontrar a correlação máxima, com o espaço de busca sendo centralizado pelo passo estimado.

4ª Etapa – Extração de informações e processamento

Nesta fase são coletadas diversas estatísticas com relação aos períodos encontrados em ambas as estações, tais como:

- Data Completa do período (ano, mês, dia, hora e min)
- Velocidade Média na Estação de Referência
- Velocidade Média na Estação Auxiliar
- Direção Média na Estação de Referência
- Direção Média na Estação Auxiliar
- Passo Encontrado (que maximizou a correlação)
- Passo Estimado (através das equações)
- Correlação Máxima (utilizando o passo encontrado)
- Correlação sem considerar defasagem
- Correlação da direção
- Desvio Padrão da Direção na Estação de Referência
- Desvio Padrão da Velocidade na Estação de Referência
- Desvio Padrão da Direção na Estação Auxiliar

- Desvio Padrão da Velocidade na Estação Auxiliar

Estas estatísticas serão utilizadas na tentativa de encontrar padrões nas correlações. Por exemplo, os períodos com direção e velocidade similares, serão agrupados e será verificado se possuem passos de defasagens também similares, como as hipóteses indicam. Por outro lado, os outros parâmetros coletados podem ser úteis para refinar a classificação dos padrões, proporcionando informações adicionais de filtragem e de agrupamento dos resultados.

Resumo da ferramenta

De maneira simplificada a Figura 3.12 apresenta um resumo desta ferramenta.

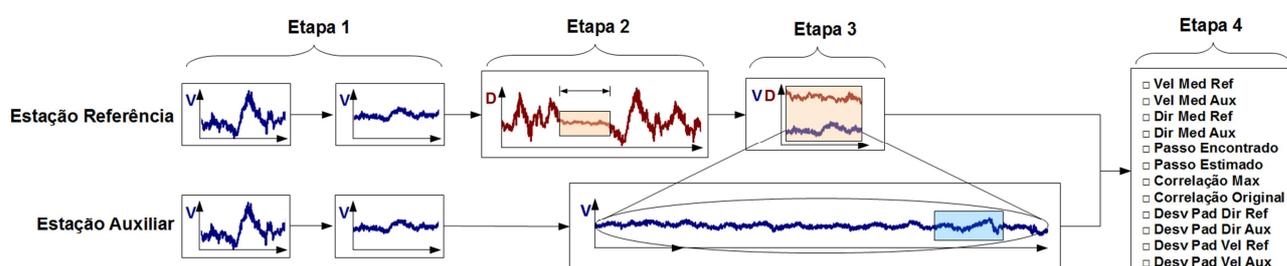


Figura 3.12 – Diagrama resumo da ferramenta de correlação.

RESULTADOS

A ferramenta foi utilizada com diversas configurações dos parâmetros acima mencionados e para as 10 estações auxiliares. A seguir serão apresentadas amostras dos resultados, mas que ilustram as conclusões obtidas através dos inúmeros experimentos realizados.

Cada vez que a ferramenta é executada, com determinada configuração e para uma estação específica, é gerada uma tabela com todos os períodos encontrados e com as estatísticas destes períodos. A Tabela 3.1 exemplifica alguns resultados obtidos para a estação 6, com tamanho do período de 3 horas (18 registros de 10 minutos), desvio padrão da direção máximo de 3 graus e correlação mínima aceitável de 0,6. Como pode ser visto, para este caso, foram encontrados 186 períodos os quais obtiveram correlação maior que 0,6.

Tabela 3.1 – Exemplo dos resultados obtidos para a estação 6, com as estatísticas de cada período encontrado.

Ind.	Data					Estação Referência				Estação Auxiliar				Passo		Correlação		
	Ano	Mês	Dia	Hora	Min	Vel. Média	Dir. Média	DSP Vel.	DSP Dir.	Vel. Média	Dir. Média	DSP Vel.	DSP Dir.	Encontrado	Estimado	Máxima	Sem Passos	Dir.

1	2003	1	10	17	0	7,5	117,9	0,3	3,0	8,0	114,4	1,2	5,4	49	37,9	0,71	-0,5	0,4
2	2003	1	11	5	20	6,6	105,6	0,8	2,6	5,3	45,3	0,4	5,6	62	44,2	0,64	-0,5	0,6
3	2003	1	11	6	30	6,2	109,5	0,7	2,3	5,2	45,0	0,3	5,4	50	46,8	0,81	0,0	0,2
4	2003	1	11	16	20	6,4	111,7	0,6	2,4	7,3	79,1	0,5	3,2	54	45,0	0,66	-0,2	-0,3
5	2003	1	11	18	20	7,1	112,0	0,8	2,2	7,3	79,9	0,6	5,6	26	40,6	0,63	0,3	0,4
6	2003	1	12	4	10	6,0	92,1	0,5	2,6	6,8	49,5	0,7	3,3	65	47,8	0,61	-0,5	0,1
7	2003	1	12	5	20	5,8	94,2	0,4	2,3	7,4	52,5	0,6	5,2	69	49,8	0,68	-0,5	0,6
...
180	2003	12	14	20	40	9,3	112,2	0,7	2,1	7,4	135,5	0,4	5,8	47	31,3	0,61	-0,4	0,1
181	2003	12	18	23	0	10,9	137,2	0,6	2,3	10,3	127,3	0,6	5,1	16	22,3	0,65	0,2	0,3
182	2003	12	19	0	10	11,1	137,8	0,5	2,3	10,0	129,9	0,7	4,5	15	21,7	0,65	0,3	0,1
183	2003	12	19	2	30	10,8	138,6	0,6	1,8	9,2	134,6	1,4	3,0	13	22,0	0,75	-0,2	0,5
184	2003	12	19	3	40	10,8	139,7	0,7	2,4	8,7	135,3	1,4	3,4	14	21,9	0,74	-0,2	0,1
185	2003	12	23	8	0	7,0	103,7	0,5	2,3	8,9	70,2	0,9	5,4	60	41,9	0,69	-0,2	0,0
186	2003	12	23	10	20	7,0	101,2	0,4	2,6	7,6	62,6	0,4	2,5	23	42,2	0,74	-0,6	-0,2

A partir destas tabelas buscou-se identificar padrões que pudessem ser aproveitados para o desenvolvimento de métodos computacionais de correlação. No entanto, analisando-se exaustivamente os inúmeros resultados, não foi possível encontrar comportamentos bem definidos. Por exemplo, casos em que a direção e a velocidade eram similares apresentaram passos de defasagem bastante diferentes.

A Figura 3.13 apresenta, para o mesmo caso apresentado Tabela 3.1, um gráfico de dispersão, onde no eixo das abcissas têm-se as velocidades médias e no eixo das ordenadas as direções médias dos períodos encontrados. As cores indicam qual foi o passo encontrado, que maximizou a correlação entre as estações. Era de se esperar que os casos com velocidades e direções similares teriam aproximadamente o mesmo passo de defasagem. Desta forma, os pontos do gráfico estariam sempre concentrados em torno de uma coordenada. Como pode ser visto na Figura 3.13 pontos de mesma cor encontram-se espalhados sem que seja possível identificar padrões bem definidos. Uma única exceção pode ser vista para os períodos com passos entre 0 e 10, apresentados em azul, cuja maioria possui direção média logo acima de 180 graus.

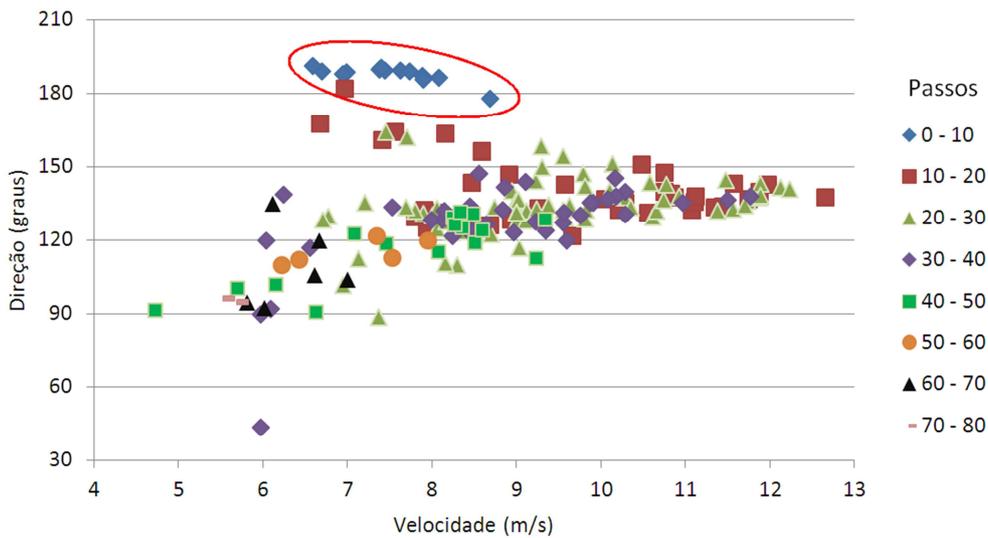


Figura 3.13 – Gráfico de Velocidade Vs. Direção médios para os períodos encontrados com os respectivos passos encontrados – Estação 6.

Outra forma de representar os resultados encontrados seria separá-los por direção e visualizar o comportamento dos passos encontrados em função da velocidade. Neste caso, é de se esperar que na medida em que as velocidades diminuem os passos sejam maiores, pois, a princípio o vento levaria mais tempo para chegar à estação analisada. A Figura 3.14 apresenta esta forma de representação para três das principais direções do vento. Como pode ser visto, é difícil identificar o comportamento esperado.

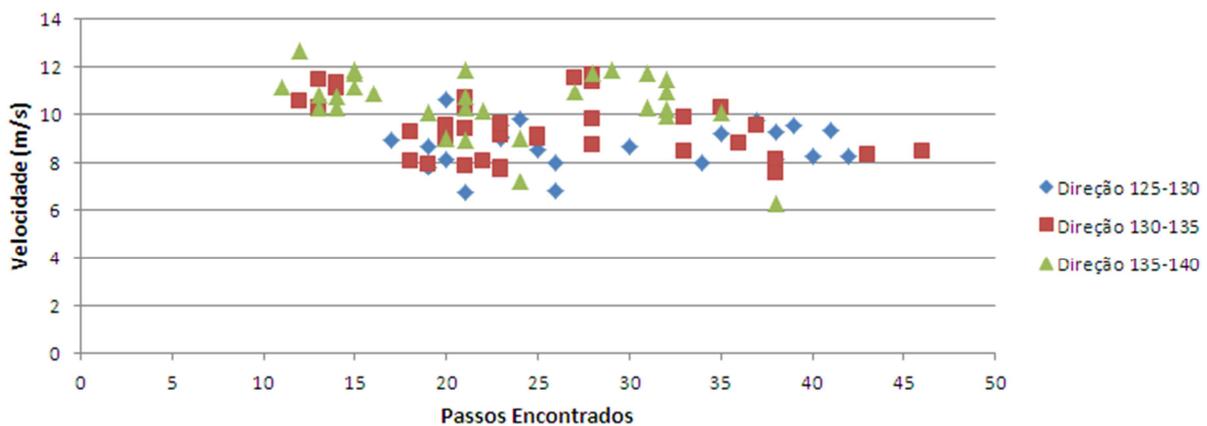


Figura 3.14 – Gráfico de Velocidade Vs. Passos encontrados para as principais direções – Estação 6.

Estações de validação

Após os primeiros resultados, verificou-se a possibilidade de que parte dos períodos que obtiveram boa correlação poderia ser mera casualidade e, portanto, poderiam estar nublando os padrões esperados. Inicialmente tentou-se ajustar os parâmetros na tentativa de evitar estas casualidades, como por exemplo, aumentando o tamanho do período com direção constante, ou o limite de

correlação aceitável. Em nenhum dos casos foi possível melhorar os resultados de forma significativa.

Para tentar evidenciar este problema criaram-se as *estações de validação*. Tais estações serão constituídas por dados de vento modificados de tal forma que qualquer boa correlação encontrada seria apenas um acaso. Desta forma, poderíamos comparar os resultados em ambas as estações e ter uma noção, ainda que aproximada, da aleatoriedade destes resultados.

As estações de validação criadas possuem as mesmas coordenadas geográficas das estações originais, mas os dados de vento foram deslocados no tempo em 3 meses, arbitrariamente, de forma a anular qualquer possibilidade de se encontrar correlações que sejam baseadas nas hipóteses assumidas.

Comparação entre as estações originais e as estações de validação

Novamente, a ferramenta foi utilizada com diversos parâmetros de configuração e os resultados foram obtidos tanto para as estações originais quanto para as estações de validação. Neste momento, ao invés de se buscar padrões nas estatísticas coletadas, apenas deseja-se comparar a quantidade de períodos encontrados, com boa correlação, para as estações originais e as estações de validação.

As duas tabelas a seguir mostram as quantidades de períodos encontrados para diversos parâmetros de “Espaço de Busca” e “Correlação Aceitável”, para a Estação 6 e para a sua respectiva estação de validação.

Tabela 3.2 – Períodos encontrados para a Estação 6.

ESPAÇO DE BUSCA	CORRELAÇÃO ACEITÁVEL									
	0,5	0,55	0,6	0,65	0,7	0,75	0,8	0,85	0,9	0,95
0,2	319	230	168	103	68	34	21	6	1	0
0,3	430	314	237	152	102	45	26	9	3	0
0,4	548	413	312	208	144	73	41	12	4	0
0,5	665	509	386	256	181	93	49	15	4	0
0,6	764	583	443	310	217	117	61	18	4	0
0,7	864	661	509	353	246	133	68	18	4	0
0,8	959	748	575	405	279	143	73	21	5	0
0,9	1038	801	611	432	301	155	79	21	5	0

Tabela 3.3 - Períodos encontrados para a Estação de validação 6.

ESPAÇO DE BUSCA	CORRELAÇÃO ACEITÁVEL									
	0,5	0,55	0,6	0,65	0,7	0,75	0,8	0,85	0,9	0,95
0,2	303	236	178	121	81	49	25	10	1	0
0,3	417	314	238	163	109	64	34	12	2	0
0,4	516	398	302	216	147	78	38	13	2	1
0,5	611	478	362	262	169	86	42	16	2	1
0,6	699	547	418	303	190	101	46	19	2	1
0,7	795	620	478	342	218	117	55	19	3	1
0,8	866	675	517	373	233	129	66	25	4	1
0,9	961	764	577	403	258	140	74	27	5	1

Como pode ser visto, à medida que se aumenta o espaço de busca mais períodos com boa correlação são encontrados. Por outro lado, quando se aumenta a Correlação Aceitável, menos períodos são encontrados, já que o critério fica mais restritivo. O principal resultado apresentado nestas tabelas é que a quantidade de períodos que satisfizeram os critérios em ambas as estações estão muito próximos. Mais precisamente, para o caso da estação 6, foram obtidos 27% mais períodos na estação original do que na estação de validação, indicando que, embora possa haver casos que sustentam a hipótese, grande parte destes períodos foram encontrados aleatoriamente. Por este motivo não foi possível identificar padrões úteis ao se analisar as estatísticas dos períodos. A Figura 3.15 apresenta a soma dos períodos encontrados em função da correlação aceitável.

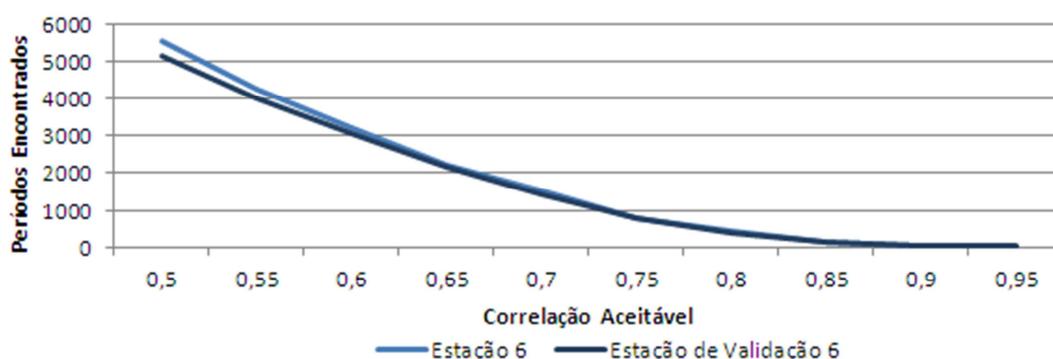


Figura 3.15 – Indicando que os resultados para a estação original ficaram pouco acima do que para a estação de validação.

Estações mais próximas à estação de referência obtiveram um percentual menor de períodos aleatórios. A Tabela 3.4 apresenta a soma dos resultados para as diversas configurações apresentadas na Tabela 3.2 e Tabela 3.3, para cada estação auxiliar, assim como para suas respectivas estações de validação. Por exemplo, a estação 2, que se encontra consideravelmente mais próxima do que a estação 6, apresentou 49% mais períodos do que sua respectiva estação de validação. Por outro lado, outras estações obtiveram percentuais menores. Conseqüentemente, ainda que possam existir resultados consistentes com as hipóteses, tendo em vista que a quantidade encontrada nas estações originais são maiores, a grande quantidade de resultados aleatórios dificulta a construção de um modelo aproveitável.

Tabela 3.4 – Somatório dos períodos encontrados para diversas configurações.

ESTAÇÃO	ORIGINAL	VALIDAÇÃO	RAZÃO	DISTÂNCIA (km)
Est. 1	23448	2727	8,6	14
Est. 2	7592	5104	1,5	51
Est. 3	7284	6101	1,2	68
Est. 4	5294	5068	1,0	95
Est. 5	6960	5684	1,2	119
Est. 6	8483	6686	1,3	176
Est. 7	3807	2803	1,4	42
Est. 9	3763	5182	0,7	148
Est. 10	21121	6060	3,5	38

(A estação 8 foi omitida por estar muito próxima a estação 7)

Como os resultados não foram de acordo com o esperado seria importante analisar mais detalhadamente as hipóteses assumidas de forma a verificar suas validades e suas limitações. Nas próximas seções são apresentadas variações desta ferramenta de forma a restringir o escopo do experimento, permitindo testar cada hipótese separadamente.

3.1.2.1 Teste da hipótese da trajetória

Para testar a hipótese da trajetória aplicou-se um filtro nos períodos selecionados buscando eliminar a necessidade da hipótese da frente de ação do vento. Através de um pré-processamento são rejeitados todos os casos em que a direção do vento não está alinhada com a reta que liga as duas estações (Figura 3.16), permitindo uma análise direta da hipótese da trajetória. A hipótese da frente de ação do vento não é necessária, pois, mantida a direção constante, o “mesmo ar” que passar na estação de referência seguirá em direção a estação auxiliar. Para cada estação será calculada a direção principal e serão permitidos os casos que estiverem dentro de uma pequena faixa de variação em torno desta direção. A Figura 3.16 ilustra o caso analisado pela ferramenta.

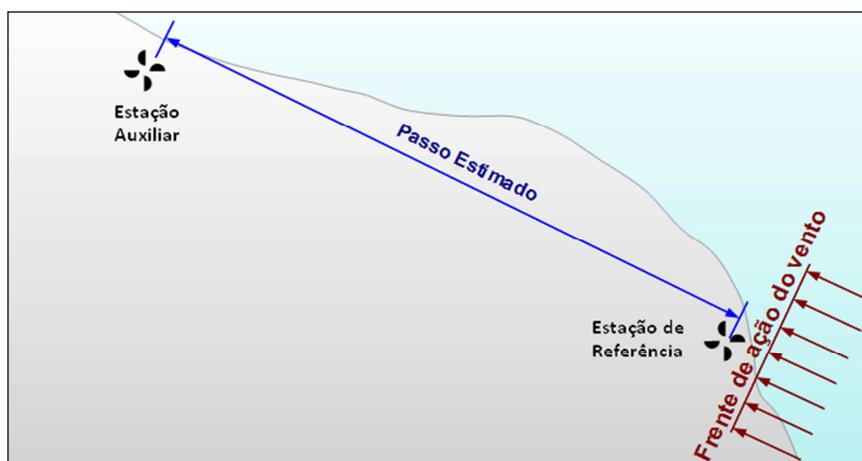


Figura 3.16 – Caso em que a direção do vento está alinhada com a reta que liga as estações.

A tabela a seguir mostra a quantidade de períodos com direção constante que obtiveram boa correlação com a estação auxiliar. Como no caso anterior, para verificar quantos destes resultados podem ser fruto do acaso, foram utilizadas as estações de validação cujos resultados também podem ser vistos na Tabela 3.5. A coluna “razão” apresenta a relação entre o número de períodos originais e os que podem ter sido encontrados aleatoriamente. Naturalmente o caso ideal é que não seja encontrado nenhum período com boa correlação na estação de validação.

Como pode ser visto a seguir, os resultados com esta ferramenta apresentam diferenças significativamente menores que no caso anterior, quando eram utilizadas todas as direções. Como era de se esperar, a restrição imposta reduziu consideravelmente as quantidades de períodos encontrados. No entanto, comparando-se a Tabela 3.4 com a Tabela 3.5, é interessante notar que a quantidade de períodos na estação de validação reduziu ainda mais. Desta forma, é possível concluir que a hipótese é válida principalmente para os casos em que as estações estão próximas. Entretanto, há também uma considerável quantidade de períodos encontrados aleatoriamente que dificultam a identificação de padrões bem definidos.

Tabela 3.5 - Somatório dos períodos encontrados para diversas configurações.

ESTAÇÃO	ORIGINAL	VALIDAÇÃO	RAZÃO	DISTÂNCIA (km)
Est. 1	104	0	Infinito	14
Est. 2	591	49	12,1	51
Est. 3	852	72	11,8	68
Est. 4	430	186	2,3	95
Est. 5	431	86	5,0	119
Est. 6	658	239	2,8	176
Est. 7	182	40	4,6	42
Est. 9	2002	1763	1,1	148
Est. 10	20907	6052	3,5	38

(A estação 8 foi omitida por estar muito próxima a estação 7)

3.1.2.2 Teste da hipótese da frente de ação

Complementando a ferramenta anterior, neste caso busca-se testar a hipótese da frente de ação diretamente, analisando-se apenas os casos em que a direção do vento é tal que o vento chega em ambas as estações ao mesmo tempo. São os casos em que o passo estimado é igual a zero. A Figura 3.17 ilustra este caso em que o vento chega às duas estações no mesmo momento, sem que haja um caminho a ser percorrido.

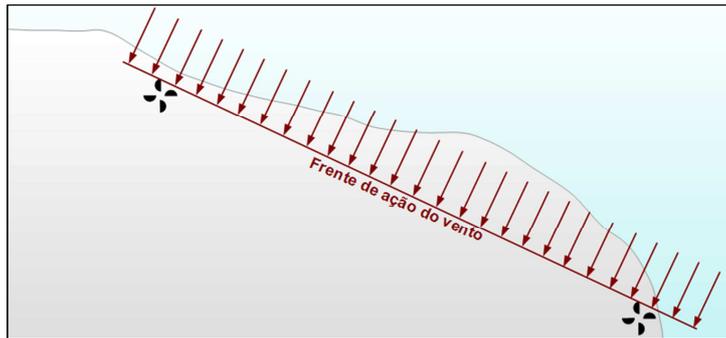


Figura 3.17 - Caso em que a direção do vento é tal que o vento chega ao mesmo tempo em ambas as estações.

Cada restrição imposta reduz a quantidade de períodos encontrados. Por este motivo, nesta ferramenta foram extraídas informações de etapas intermediárias, que ajudam a ilustrar a evolução dos processos.

Estes resultados são apresentados na Tabela 3.6, onde cada coluna deve ser entendida da seguinte forma:

Estação

São apresentados os resultados para a estação original e para a estação de validação.

Períodos com direção constante na Estação de Referência

Da mesma forma que nas ferramentas anteriores a primeira etapa é selecionar períodos na estação de referência com direção constante. Esta coluna apresenta a quantidade de períodos com direção constante que foram encontrados.

Períodos com passo igual a zero

Cada período encontrado anteriormente tem seu “passo estimado” calculado. Aqueles que possuem valores próximos de zero são selecionados. Nesta coluna são apresentados tanto a quantidade de períodos com passo zero quanto o percentual destes com respeito à etapa anterior. Esses percentuais ajudam a contextualizar a representatividade dos casos analisados.

Períodos com passo igual a zero e com correlação maior que 0.7

Neste momento é feita a busca por correlações altas. Sempre que for encontrada correlação acima de 0.7 o período é selecionado. Esta coluna apresenta a quantidade encontrada assim como o percentual com relação ao item anterior. No caso ideal, se a hipótese da frente de ação fosse válida para as distâncias estudadas, era de se esperar que todos os casos com passo estimado igual a zero tivessem uma correlação boa. Isto por que o vento estaria chegando em ambas as estações ao mesmo tempo. Além disso, é de se esperar que nas estações de validação não haja casos de correlação alta, a não ser os que ocorrerem aleatoriamente, tendo em vista que os dados nestas estações foram deslocados em 3 meses.

Tabela 3.6 – Resultados para o teste da “frente de ação”, com etapas intermediárias.

ESTAÇÃO		Períodos com direção constante na Est. Ref.	Períodos com passo próximos a zero		Períodos com passo próximos a zero e Correl. > 0.7	
Est. 1	Original	35050	210	0,6%	40	19,0%
	Validação	35050	210	0,6%	3	1,4%
Est. 2	Original	35050	179	0,5%	16	8,9%
	Validação	35050	179	0,5%	22	12,3%
Est. 3	Original	35050	297	0,8%	38	12,8%
	Validação	35050	297	0,8%	32	10,8%
Est. 4	Original	35050	775	2,2%	66	8,5%
	Validação	35050	775	2,2%	74	9,5%
Est. 5	Original	35050	663	1,9%	61	9,2%
	Validação	35050	663	1,9%	70	10,6%
Est. 6	Original	35050	459	1,3%	53	11,5%
	Validação	35050	459	1,3%	42	9,2%
Est. 7	Original	35050	455	1,3%	28	6,2%
	Validação	35050	455	1,3%	19	4,2%
Est. 9	Original	35050	1249	3,6%	46	3,7%
	Validação	35050	1249	3,6%	58	4,6%
Est. 10	Original	35050	103	0,3%	11	10,7%
	Validação	35050	103	0,3%	0	0,0%

(A estação 8 foi omitida por estar muito próxima a estação 7)

Conforme pode ser analisado, na Tabela 3.6 foram encontrados 35050 períodos com direção constante. Deste total em torno de 1%, dependendo da estação, apresentou *passo estimado* próximo de zero. A Estação 9, em função da sua localização relativa à direção predominante do vento, foi a que apresentou maior ocorrência desses casos (ver Figura 2.7). A partir daqui, espera-se que estes períodos tenham boa correlação, principalmente as estações mais próximas.

No entanto, dos períodos com passo próximos de zero apenas ao redor de 10% tiveram correlação acima de 0.7. Além disso, analisando os resultados nas estações de validação, é possível verificar que, na maioria dos casos, os resultados foram similares às estações originais, indicando que os períodos encontrados nos dados originais podem ser aleatórios.

Por outro lado, excepcionalmente na Estação 10 e na Estação 1 as diferenças entre os dados originais e os de validação foram bastante significativas. Indicando que as correlações encontradas não foram por acaso. Estas estações são as duas mais próximas da estação de referência, corroborando que estes resultados podem estar fundamentados nas hipóteses da *frente de ação*, que teriam, portanto, alguma validade dentro de uma extensão limitada. Note que a diferença na Estação 1, que está mais próxima, é ainda maior que a da estação 10.

A principal conclusão deste experimento é que a hipótese de frente de ação do vento é válida apenas para pequenas distâncias, até cerca de 40km. Este fato reforça a impressão de que grande parte dos resultados encontrados na primeira ferramenta é aleatória impossibilitando a identificação de padrões que seriam fundamentais para a criação de um modelo de correlação.

3.1.3 Ferramenta 2

As ferramentas anteriores possuem em comum a mesma metodologia para correlacionar duas estações. Elas tratam de fazer uma varredura na estação auxiliar em busca da correlação máxima com a estação de referência. Esse processo resulta num único valor de correlação vinculado a um único passo de defasagem. No entanto, conforme foi observado através dos resultados anteriores, existe um número considerável de correlações que ocorrem ao acaso. Desta forma, os casos de correlação que poderiam estar fundamentados pelas hipóteses podem estar sendo “nublados” pelas altas correlações aleatórias. O método que será exposto nesta seção visa dirimir a possibilidade de ocorrerem esses efeitos.

Ao invés de serem coletadas apenas as informações da correlação máxima a ferramenta armazena todas as correlações obtidas em cada passo de defasagem testado na varredura, tal como ocorre no correlograma. Desta forma, evita-se focar apenas no passo de correlação máxima, possibilitando verificar se outros passos também tiveram correlações altas. Além disso, para reforçar os resultados, o processo será repetido para vários casos em que os *passos estimados* forem similares.

Em outras palavras, os períodos selecionados na estação de referência serão filtrados de forma que os passos estimados estejam todos dentro de uma determinada faixa. Em seguida, cada período será correlacionado com a estação auxiliar através de uma varredura de passos. Os resultados da correlação para cada passo será armazenado. O processo é realizado para cada período selecionado. Finalmente é calculada a média das correlações obtidas em cada passo.

O filtro aplicado seleciona os períodos cuja direção está alinhada com a estação auxiliar, tal como aplicado no teste da hipótese da trajetória, desta forma evitasse os casos em que a hipótese da frente de ação do vento é necessária. A Tabela 3.7 apresenta as faixas utilizadas para cada estação auxiliar.

Tabela 3.7 – Faixas de seleção para os períodos encontrados na estação de referência.

Estação	Intervalo Vel.(m/s)	Intervalo Dir.(Graus)	Períodos Seleccionados
1	6 - 9	136 - 156	1218
2	6 - 9	111 - 131	3458
3	6 - 9	106 - 126	2569
4	6 - 9	91 - 111	744
5	6 - 9	92 - 112	803
6	6 - 9	93 - 113	874
7	6 - 9	71 - 91	134
8	6 - 9	70 - 90	120
9	6 - 9	48 - 68	10
10	6 - 9	125 - 145	3501

Os gráficos que seguem mostram as médias das correlações em cada passo de defasagem e quais foram os passos estimados para os períodos. Também são apresentadas as médias para a estação de validação. Naturalmente, os passos estimados servem apenas como uma referência, tendo em vista que são resultados de equações simplificadas.

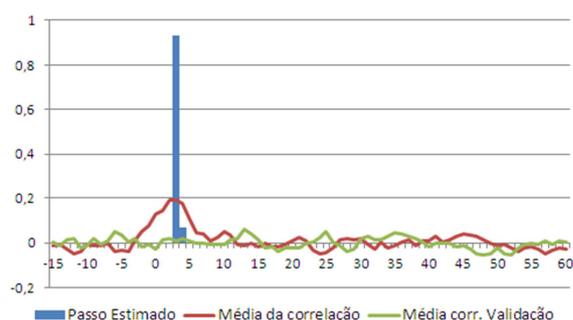


Figura 3.18 – Médias das correlações para a Est. 1.

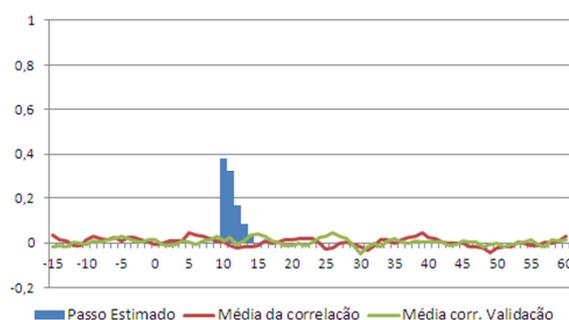


Figura 3.19 – Médias das correlações para a Est. 2.

A estação 1 é a estação mais próxima da estação de referência e como pode ser visto na Figura 3.18 as médias para a estação original são maiores justamente ao redor dos passos estimados. Neste caso, as hipóteses, e mesmo as equações para o passo estimado, parecem funcionar bem. Já na estação 2 não foi possível detectar qualquer relação de correlação em função do passo estimado.

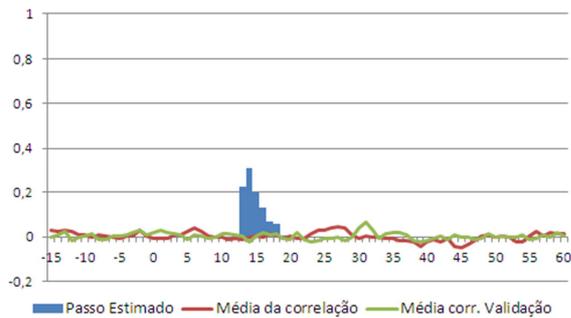


Figura 3.20 – Médias das correlações para a Est.3.

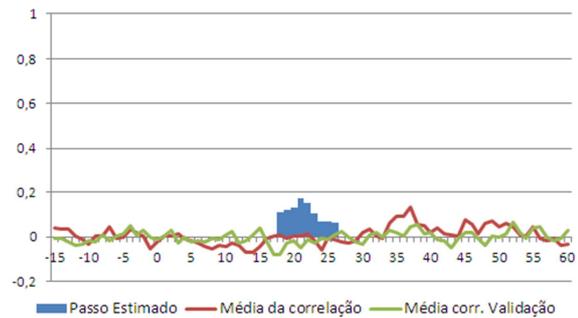


Figura 3.21 – Médias das correlações para a Est.4.

Tanto a estação 3 quanto a 4 apresentaram um leve aumento nas correlações próximo aos passos 25 e 35, respectivamente.

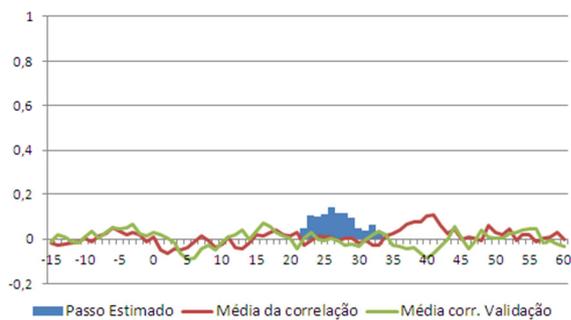


Figura 3.22 – Médias das correlações para a Est.5.

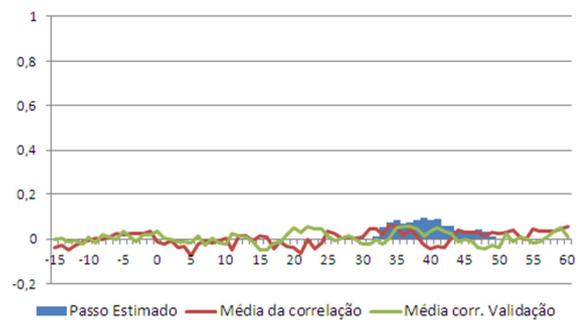


Figura 3.23 – Médias das correlações para a Est.6.

A estação 5 também apresentou um aumento em torno do passo 40. Na estação 6, não foi possível detectar nenhuma relação.

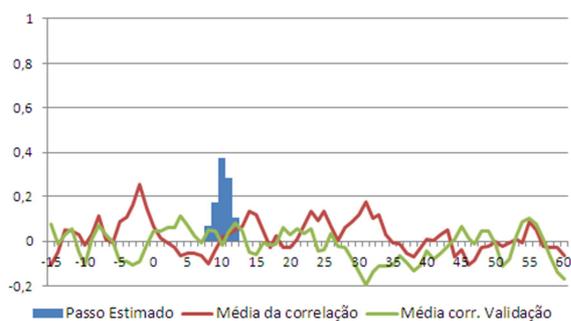


Figura 3.24 – Médias das correlações para a Est.7.

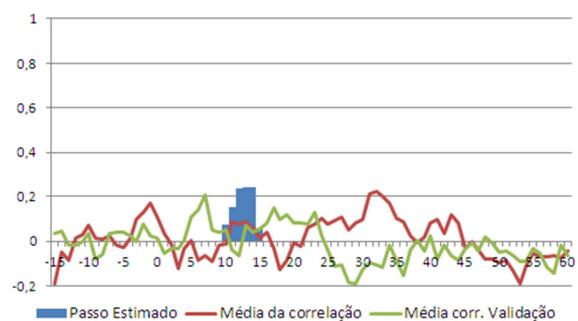


Figura 3.25 – Médias das correlações para a Est.8.

Para estações 7 e 8 foram obtidos pouco mais de 100 períodos (Tabela 3.7), por este motivo as médias ficam pouco representativas e mostram um comportamento bastante aleatório.

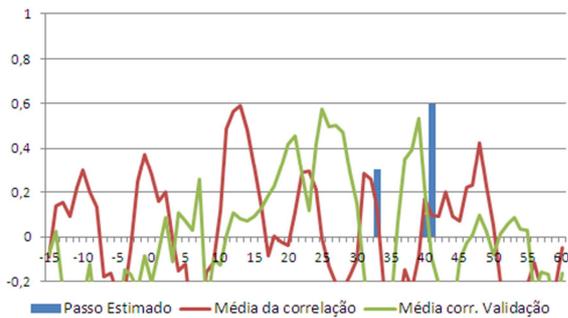


Figura 3.26 – Médias das correlações para a Est.9.

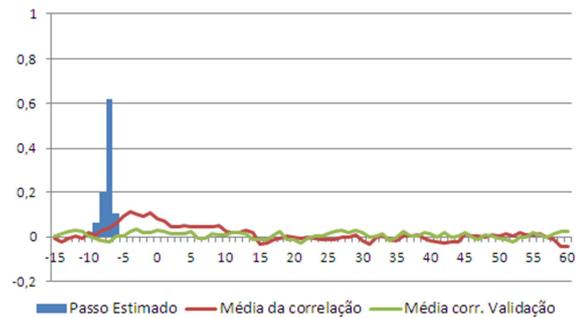


Figura 3.27 – Médias das correlações para a Est.10

A estação 9 foi a que apresentou menos períodos em função da sua posição relativa às direções predominantes na estação de referência. Portanto, os resultados são pouco representativos. No caso da estação 10, que é a segunda estação mais próxima da estação de referência, pode ser visto na Figura 3.27 um aumento das médias próximo ao passo -5. Como a estação está situada à frente da estação de referência, com relação ao vento predominante, o passo negativo vai ao encontro dos resultados esperados.

3.1.4 Conclusão (análise de resíduos)

Tendo em vista os resultados encontrados, é possível concluir que estações próximas poderiam se beneficiar de técnicas de correlação que levassem em conta modelos físicos do deslocamento do vento entre as estações, tais como o modelo “frente de ação do vento”. Para estações mais distantes não foi possível obter indícios de melhorias nas correlações com as ferramentas utilizadas.

Apesar desta limitação, em alguns casos seria possível se aproveitar deste tipo de ferramenta. Por exemplo, é muito comum se fazer ampliações em parques eólicos com a contratação de terrenos próximos ao parque já construído. Nestes casos, para os estudos de viabilidade ou se aproveita as medições do parque existente, e consideram-se as incertezas nas estimativas por não haver medições no próprio local, ou se instala novas estações e, ao final de um ou dois anos, se estima de forma mais adequada a geração. Em cada caso há desvantagens consideráveis e por estes motivos talvez fosse mais indicado instalar novas estações por períodos de poucos meses e através de ferramentas de correlações precisas aproveitar os dados das estações já existentes nas estimativas, implicando em menos incertezas sem a necessidade de ter que medir durante mais um ano completo.

Energia presente nos resíduos

Ao se retirar as sazonalidades passou-se a trabalhar apenas com uma parte residual dos dados. Esta parte representa a parcela com menor energia, tendo em vista que o vento possui um comportamento fortemente sazonal.

Para analisar a energia presente em cada parcela foram estimadas a geração de energia, considerando-se um aerogerador típico (Figura 3.28), com os dados originais e com os dados “sazonalizados”, sem a parcela residual conforme anexo A. A Tabela 3.8 indica que a diferença obtida na energia estimada variou de -7,7% até 3,1%, de forma que a parte residual representa em geral menos de 5% da energia do vento.

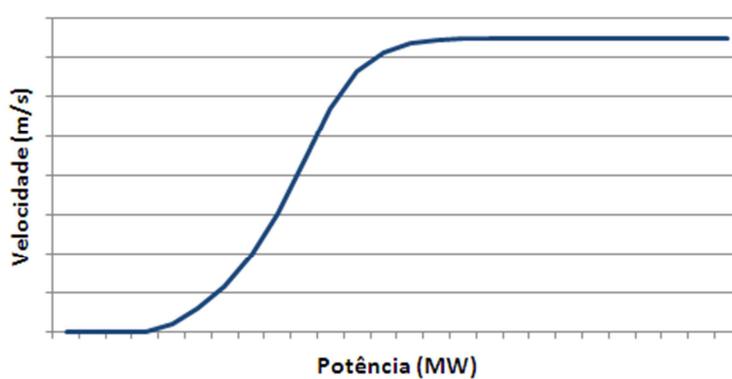


Figura 3.28 – Curva de potência típica de um aerogerador.

Tabela 3.8 – Diferença na estimativa de geração entre Sazonalidade Vs. Dados originais.

Estação	Energia Anual (KWh)			Velocidade (m/s)
	Sazonalidade	Dados Originais	Diferença	Diferença
ref	5379,5	5566,9	-3,4%	0,0%
1	5041,1	5218,4	-3,4%	0,1%
2	5356,0	5510,1	-2,8%	-0,2%
3	5593,8	5713,3	-2,1%	-0,2%
4	3541,6	3830,3	-7,5%	-0,2%
5	5173,0	5371,7	-3,7%	-0,3%
6	5009,3	5223,1	-4,1%	-0,1%
7	6588,6	6572,0	0,3%	0,2%
8	5133,6	5295,3	-3,1%	0,1%
9	8335,8	8082,4	3,1%	0,3%
10	4415,8	4736,8	-6,8%	-0,1%

Ainda que esta parcela seja pequena, erros nas estimativas de geração nesta ordem podem ser considerados significativos. Este é o caso, por exemplo, na previsão de curto prazo quando se deseja ajustar a oferta e a demanda de energia, implicando em despachar ou não usinas térmicas, principalmente em países onde há grande inserção da energia eólica no sistema.

Para este estudo tomou-se arbitrariamente uma estação como referência. O estudo deve ser expandido no futuro variando-se a estação de referência para generalizar melhor os resultados, especialmente se levássemos em conta que existem estações em situações geográficas bem diferentes.

3.2 Ferramentas para dados “sazonalizados”

Embora as hipóteses anteriores sejam estudos interessantes, na medida em que tentam representar fenômenos físicos, o comportamento extremamente complexo do vento limita bastante sua utilização. Nesta parte do trabalho, foram desenvolvidas ferramentas que buscam relacionar diretamente as sazonalidades das estações sem nenhuma fundamentação fenomenológica específica. Não são considerados as variações “instantâneas”, não sazonais, do vento, que foram estudadas na primeira parte deste trabalho.

Conforme discutido anteriormente, o vento possui sazonalidades diárias e anuais, em função dos ciclos solares. Uma boa forma de representar ambas as sazonalidades é através de uma matriz onde as colunas representam os dias e as linhas as horas do dia. Para o caso de dados medidos em intervalos de 10 minutos e durante 1 ano, a matriz seria composta por 365 colunas e 144 linhas. Uma das vantagens dessa representação é que ambas as sazonalidades podem ser visualizadas numa mesma figura possibilitando uma rápida e direta identificação de características importantes dos dados de vento. A Figura 3.29 apresenta esta forma de representação para a estação de referência. Através desta figura é possível identificar facilmente que a velocidade do vento é maior tanto no segundo semestre do ano quanto na parte da tarde.

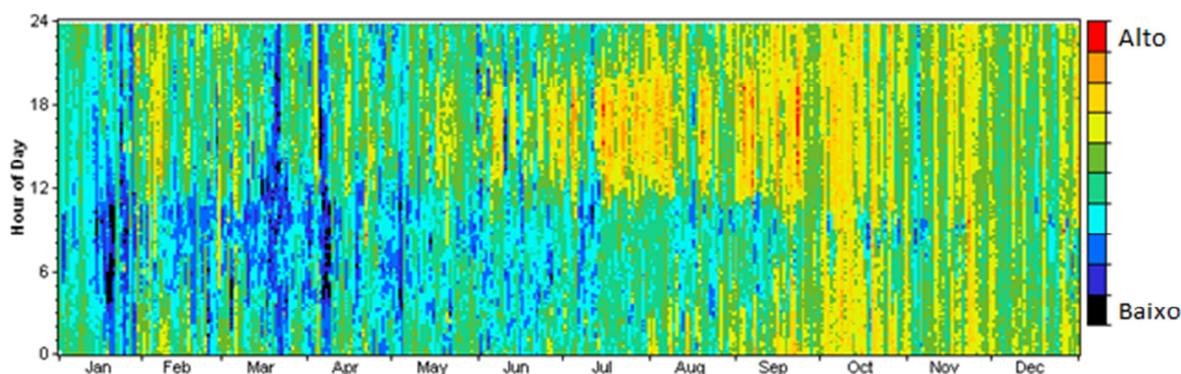


Figura 3.29 – Dados de vento da estação de referência.

As ferramentas apresentadas nesta seção abordam o problema de correlação baseando-se nesta forma de representação do vento. Portanto, o vento não mais será tratado como uma série temporal, mas sim como uma matriz sobre a qual serão aplicadas técnicas de correlação.

3.2.1 Ferramenta 3

3.2.1.1 Versão 1

A primeira versão da ferramenta 3 busca auxiliar numa análise preliminar do comportamento das correlações em base a forma matricial de representação dos dados de vento. Ao se comparar as

sazonalidades das estações pode-se perceber que em alguns casos elas são bastante similares entre si, mas que em outros apresentam diferenças significativas. Por exemplo, a Figura 3.30 apresenta os dados “sazonalizados” (Anexo A), da estação de referência e da estação 9. Como pode ser visto, enquanto na estação de referência o vento é maior durante a tarde, na estação 9 o oposto é verificado. No Anexo B são apresentadas as sazonalidades de todas as estações estudadas.

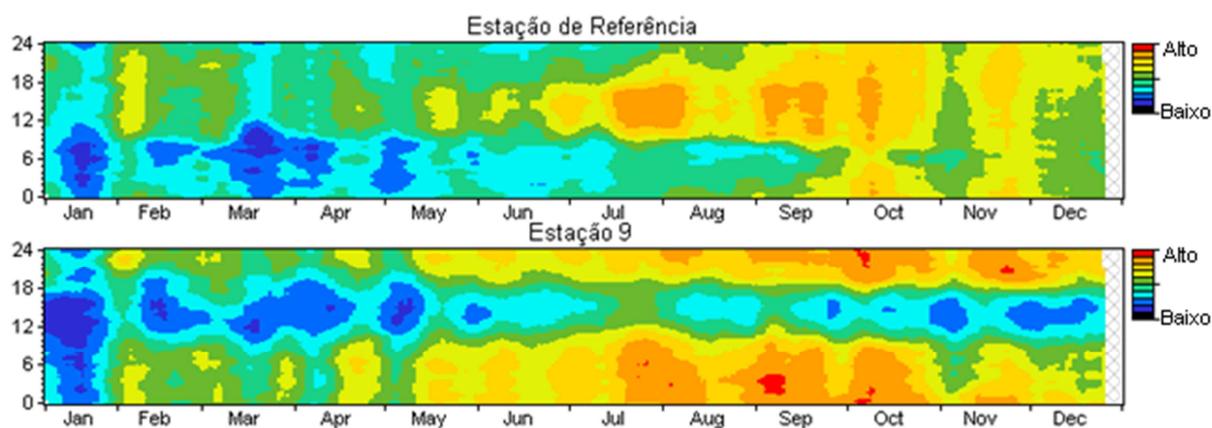


Figura 3.30 – Sazonalidades da estação de referência e da estação 9, evidenciando a diferenças significativas.

Da mesma forma que nas seções anteriores as correlações eram calculadas com passos de defasagem, com o intuito de se encontrar as correlações máximas, nestas seções serão utilizados passos nas duas dimensões. No caso ilustrado pela Figura 3.30, pode-se esperar que a correlação seja maior se houvesse um “deslocamento” de algumas horas no eixo das sazonalidades diárias. Da mesma forma, pode-se esperar que “deslocamentos” no eixo dos dias, eventualmente, aumente a correlação. O objetivo da ferramenta é possibilitar uma análise preliminar dessas possibilidades.

Mecanismo de Correlação

Inicialmente uma sub-matriz dos dados deve ser definida, em seguida, é feita a correlação desta sub-matriz com uma equivalente de mesmas dimensões na estação do projeto. Finalmente, é feita uma varredura nos dados de projeto nas duas dimensões, em busca da correlação máxima. A Figura 3.31 ilustra o processo.

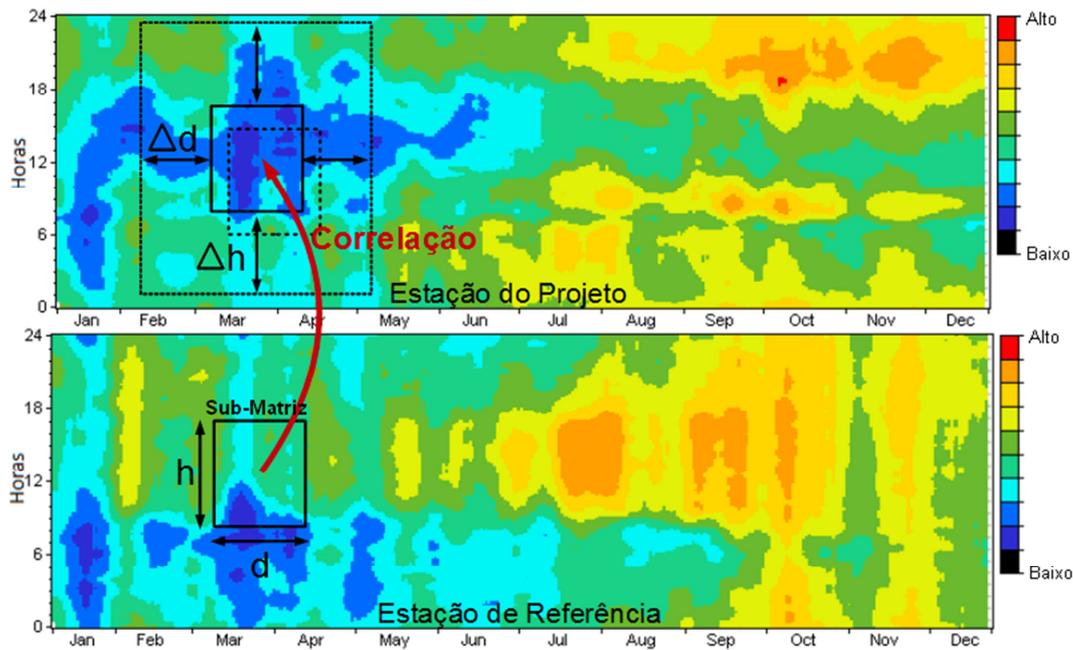


Figura 3.31 – Representação da ferramenta de correlação, a qual faz uma varredura de duas dimensões na estação de projeto em busca das correlações máximas.

Diversos parâmetros devem ser definidos tais como o tamanho da sub-matriz ($d \times h$), assim como o espaço de busca Δd (deslocamentos no eixo dos dias) e Δh (deslocamentos no eixo das horas). O processo de varredura considera que há continuação entre as horas, fechando um ciclo entre 24 e 0h. Desta forma, a varredura pode ocorrer livremente inclusive no eixo das horas, conforme ilustrado na Figura 3.32.

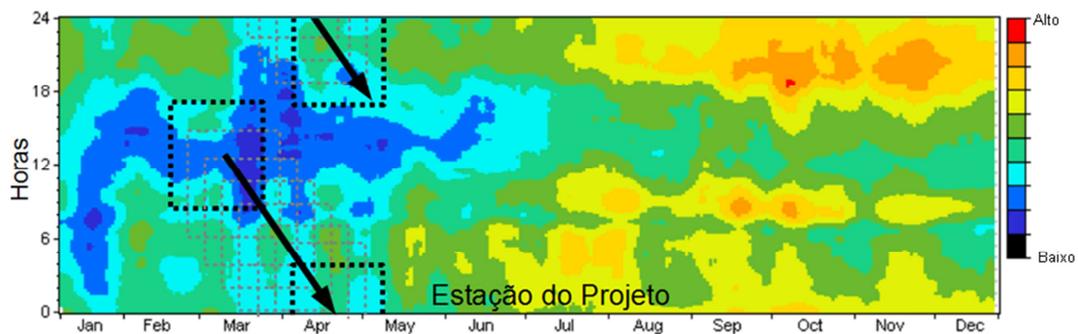


Figura 3.32 – A sub-matriz pode varrer livremente pelos dois eixos.

A correlação em cada iteração da varredura pode ser expressa por:

$$\rho = \frac{\sum_{i=1}^n \sum_{j=1}^m (x_{ij} - \bar{x})(y_{ij} - \bar{y})}{\sqrt{\sum_{i=1}^n \sum_{j=1}^m (x_{ij} - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n \sum_{j=1}^m (y_{ij} - \bar{y})^2}} \quad (11)$$

Onde x_{ij} e y_{ij} são os dados de vento que compõem as sub-matrizes de cada estação e \bar{x} e \bar{y} são as médias aritméticas dessas sub-matrizes.

Os resultados desta busca serão representados através de uma matriz das correlações, onde cada elemento é o valor da correlação encontrado em cada passo da varredura. A Figura 3.33 ilustra a criação da matriz de resultados, exemplificando a obtenção do elemento central da Matriz de Correlações, quando não há deslocamentos entre as estações. Neste caso, a sub-matriz possui dimensão de 10 dias por 24h (144 vezes 10min). Conforme ilustrado, a varredura se dará com deslocamentos de 10 dias em ambos os sentidos, além do dia coincidente, totalizando 21 dias, e 12 horas para cada lado, totalizando 24 horas. A Matriz das Correlações, portanto, possui as dimensões definidas pela varredura.

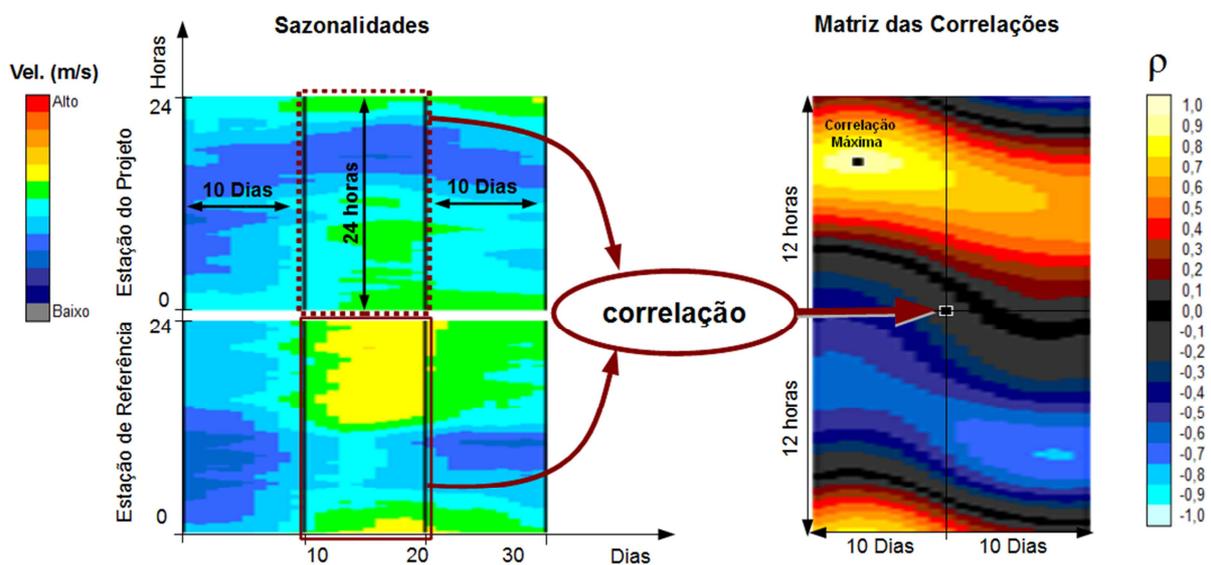


Figura 3.33 – Exemplo da criação da Matriz das Correlações.

A Matriz das Correlações possibilita rapidamente identificar quais os deslocamentos que maximizam as correlações. No caso da Figura 3.33 é possível verificar que a correlação máxima, indicada pelo ponto preto, ocorreu com deslocamentos de menos 7 dias e mais 8 horas (48 passos de 10min).

A seguir são apresentados 3 resultados completos para as estações 6, 9 e 10, com respeito a estação de referência. Em cada ilustração são apresentadas as figuras com os dados das duas estações analisadas assim como uma figura ilustrando as Matrizes das Correlações obtidas. É muito importante ressaltar que nas ilustrações seguintes as dimensões das figuras dos dados de vento são diferentes das dimensões da figura das correlações. Enquanto cada bloco nos dados vento representam 10 dias, na figura das correlações os blocos representam 21 dias, equivalentes a varredura executada. Além disso, pode-se notar que há um bloco a mais no início e no final dos dados de vento, justamente em função dos deslocamentos necessários para a varredura. A correlação máxima e a correlação sem nenhum deslocamento são indicadas pelos pontos pretos.

A seguinte figura apresenta os resultados encontrados para as correlações entre a estação 6 e a estação de referência. Pode-se ver que os deslocamentos mais expressivos ocorrem no eixo das horas, além do que, é possível identificar um determinado padrão nos deslocamentos. No caso dos deslocamentos encontrados no eixo dos dias, além de serem menores, em geral de poucos dias, não é possível identificar um padrão, pois ora ocorrem num sentido ora no outro. Também é possível notar que no final do ano as correlações são menores, evidenciado pelas cores mais escuras.

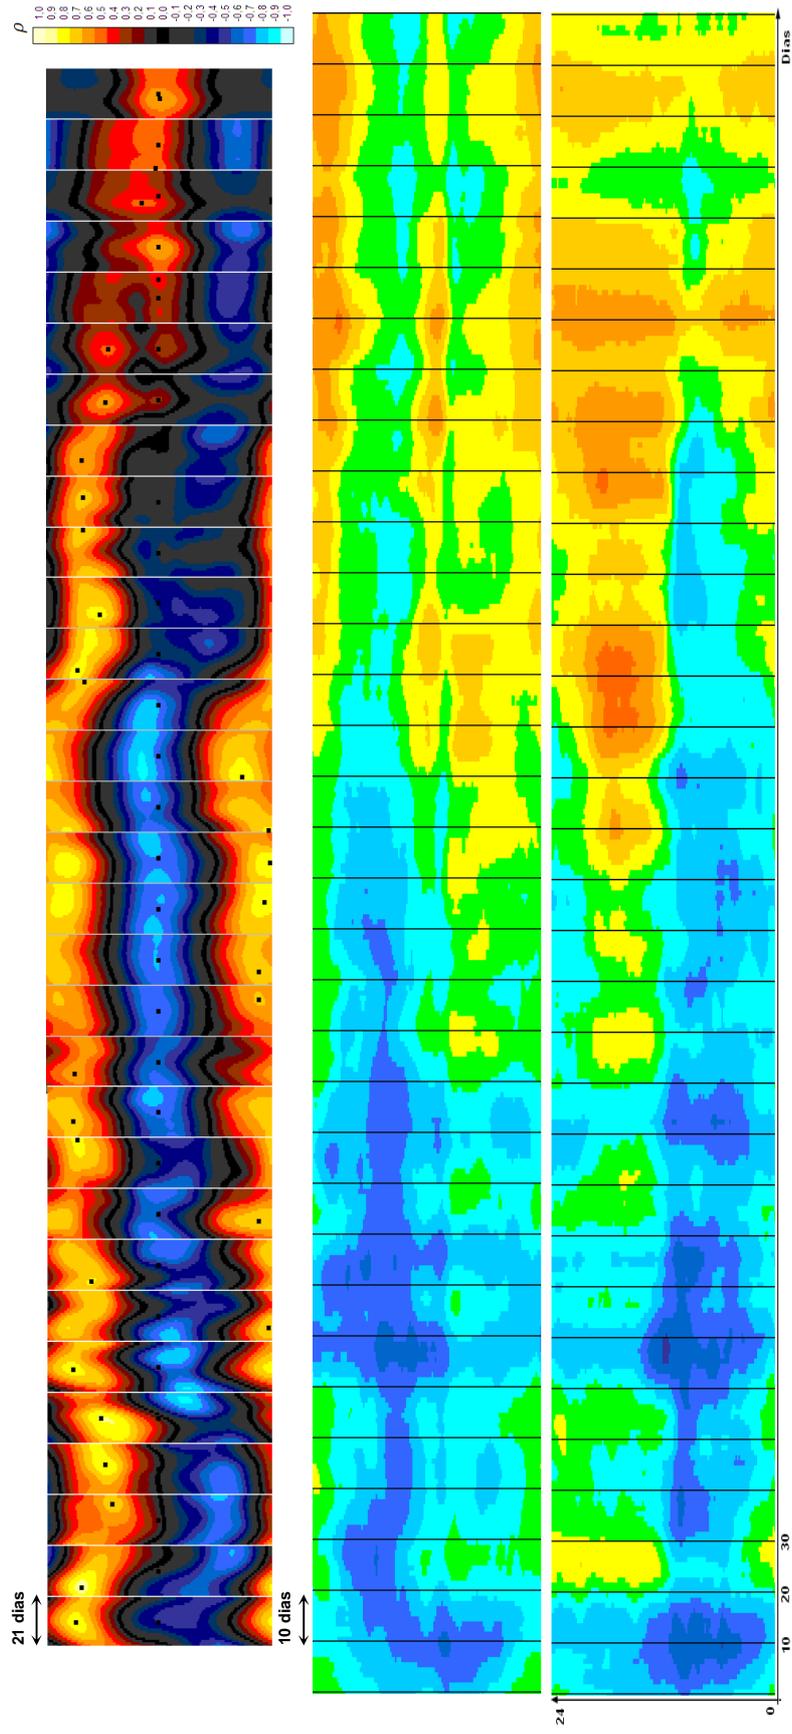


Figura 3.34 – Matrizes de dados e matriz das Correlações para a estação 6.

A figura a seguir apresenta resultados similares ao anterior. Enquanto os deslocamentos no eixo dos dias foram pequenos e sem um padrão definido no eixo das horas é possível identificar um padrão bastante evidente com grandes deslocamentos. Como na estação 6, no final do ano as correlações foram menores, mas menos acentuadamente que no caso anterior.

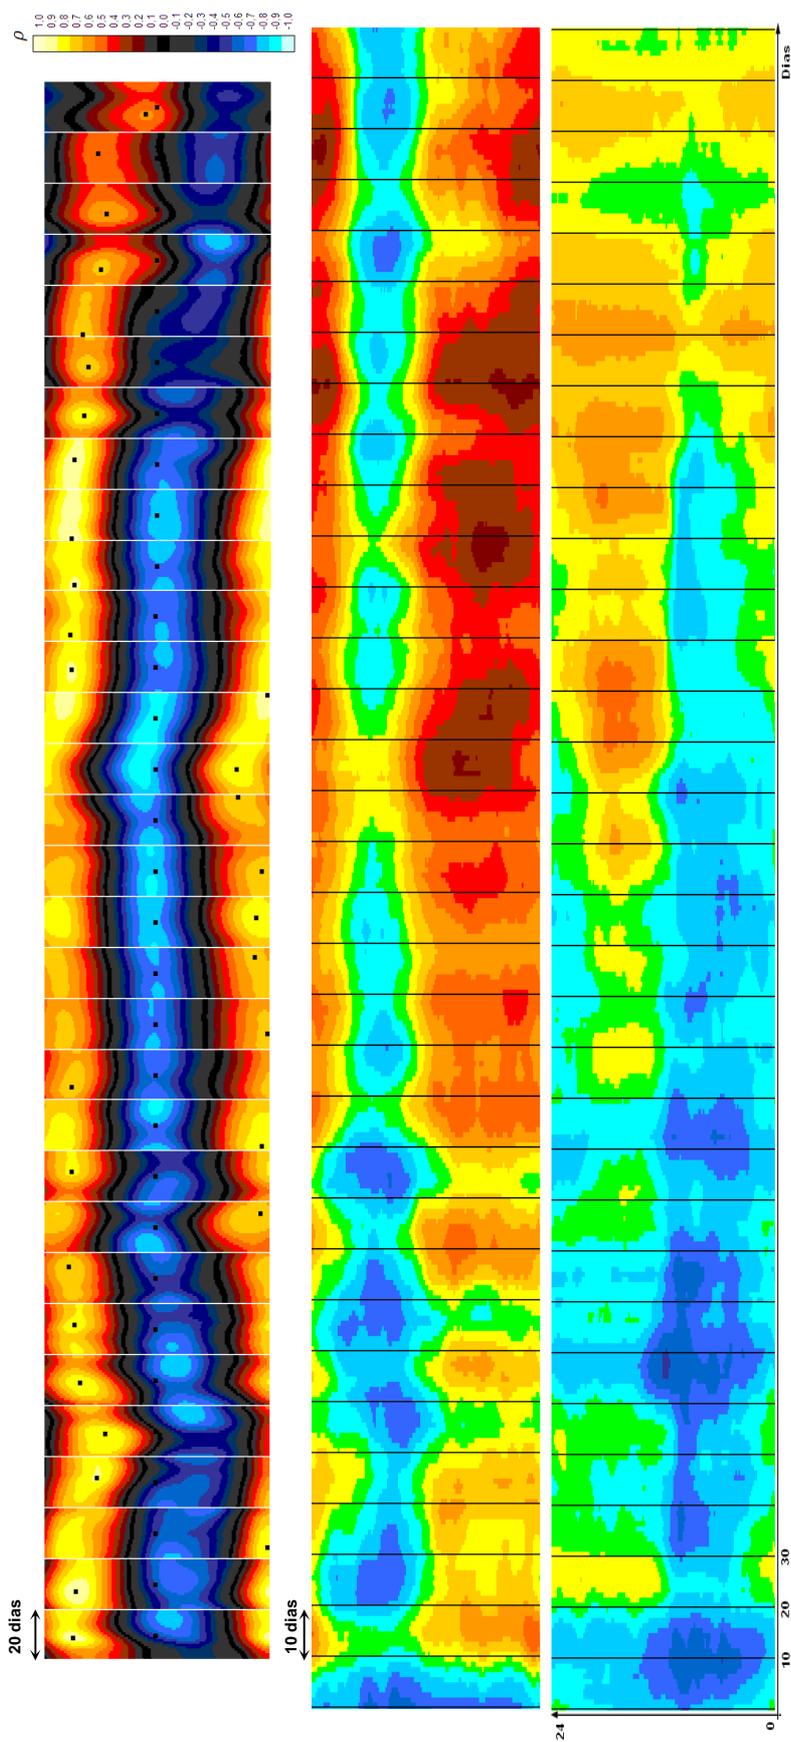
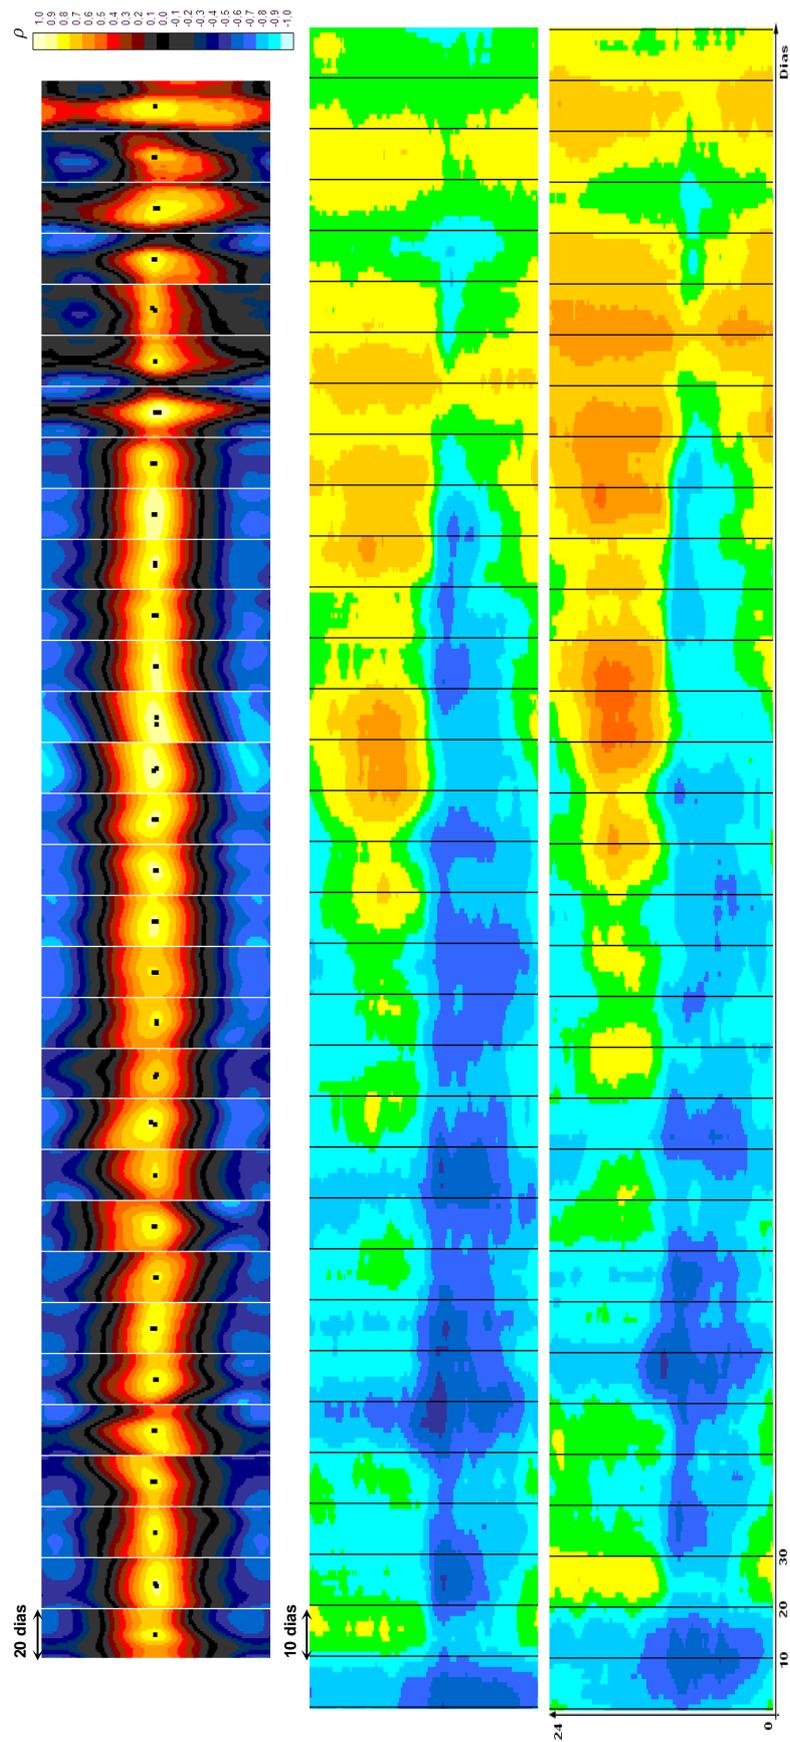


Figura 3.35 – Matrizes de dados e matriz das Correlações para a estação 9.

A Figura 3.36 apresenta os resultados para a estação 10, a segunda mais próxima dentro as estações estudadas. É possível notar que não houve grandes deslocamentos em nenhum dos eixos.



Conclusão da ferramenta3, versão 1

Através dos resultados encontrados é possível verificar que os principais deslocamentos ocorrem no eixo das horas. Outras configurações também foram testadas e os resultados foram semelhantes. A importância destes resultados está nas evidências de que deslocamentos entre os dias não são muito significativos para o aumento da correlação. Os gráficos dos dados de vento mostram que as sazonalidades diárias possuem um comportamento típico, mas que se modificam ao longo do ano. Possivelmente, uma forma eficaz de correlacionar duas estações seria aplicando passos apenas no eixo das horas de forma a ajustar os ciclos diários que possam estar descasados. No próximo item é apresentada uma versão da ferramenta que utiliza deslocamentos apenas no eixo das horas.

3.2.1.2 Versão 2

A ferramenta desta seção é um caso especial da anterior, onde a sub-matriz possui dimensões de 1X144, ou seja, apenas um 1 dia e 24 horas (ou 144 vezes 10 minutos). Além disso, a varredura não é realizada no eixo dos dias, mas apenas no eixo das horas. Desta maneira, em cada dia busca-se encontrar a defasagem que maximiza a correlação. Cada dia é correlacionado através de várias defasagens de forma que as sazonalidades diárias das duas estações fiquem melhor “acopladas” ou “entrem em fase”. A Figura 3.37 apresenta apenas os dados na estação de projeto indicando como se dá a varredura. Nesta figura, os dados de vento foram replicados em cima e embaixo para ilustrar a continuidade no eixo das horas durante o processo de varredura.

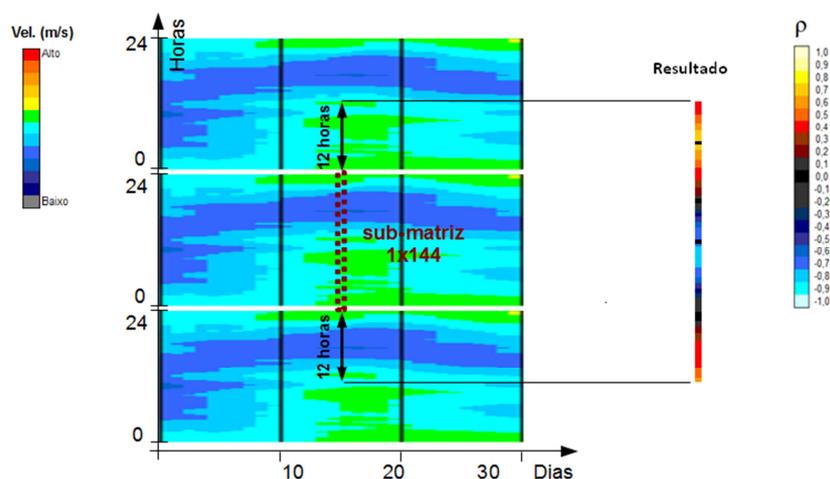


Figura 3.37 – Representação da sub-matriz e espaço de varredura apenas no eixo das horas.

As figuras que seguem mostram os resultados para cada uma das estações. Em alguns casos é possível observar que as correlações sem aplicar nenhum passo é bastante baixa, indicado pelas cores escuras e azuis.

Todas as figuras devem ser entendidas pela da seguinte legenda:



- **Estação 1**

Pode-se ver que a correlação é muito boa mesmo sem nenhum deslocamento. As correlações máximas situam-se principalmente ao longo do eixo. Esse resultado era esperado, tendo em vista que esta é a estações mais próxima.

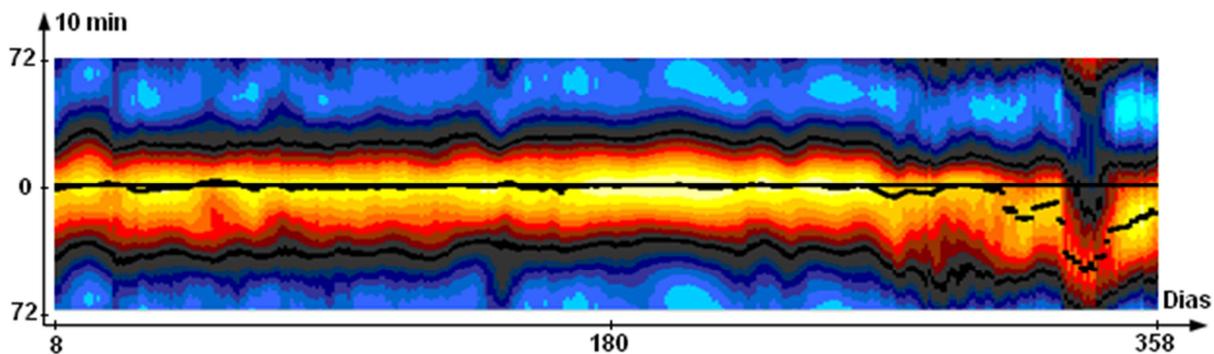


Figura 3.38 – Matriz das Correlações para a Estação 1.

- **Estação 2**

Nesta estação os resultados são similares ao anterior, apresentando diferenças no meio do ano com leves deslocamentos. Além disso, é possível notar uma pequeno descolamento do eixo.

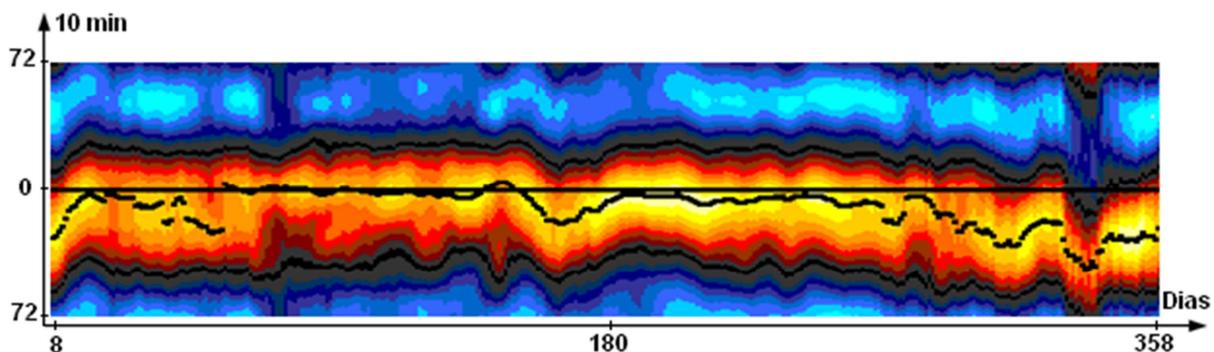


Figura 3.39 – Matriz das Correlações para a Estação 2.

- **Estação 3**

Os resultados para esta estação são praticamente os mesmos que o da Estação 2.

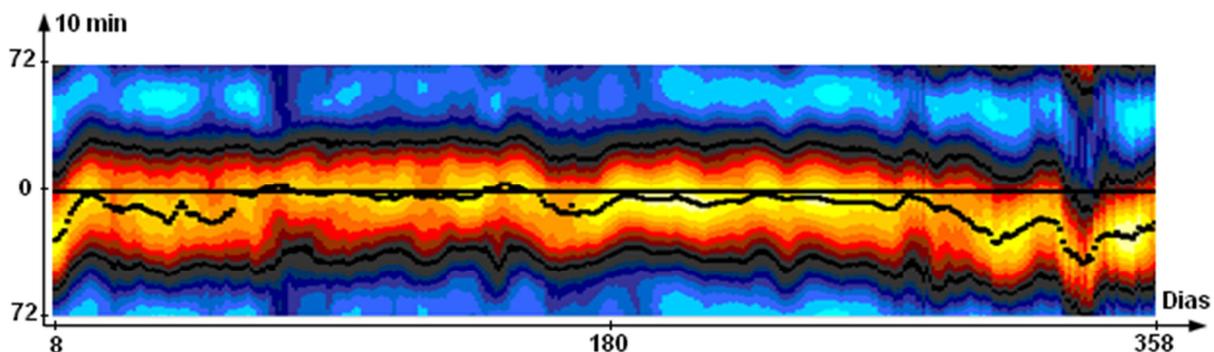


Figura 3.40 – Matriz das Correlações para a Estação 3.

- **Estação 4**

Neste caso é possível notar que algumas regiões não apresentaram boas correlações mesmo aplicando deslocamentos.

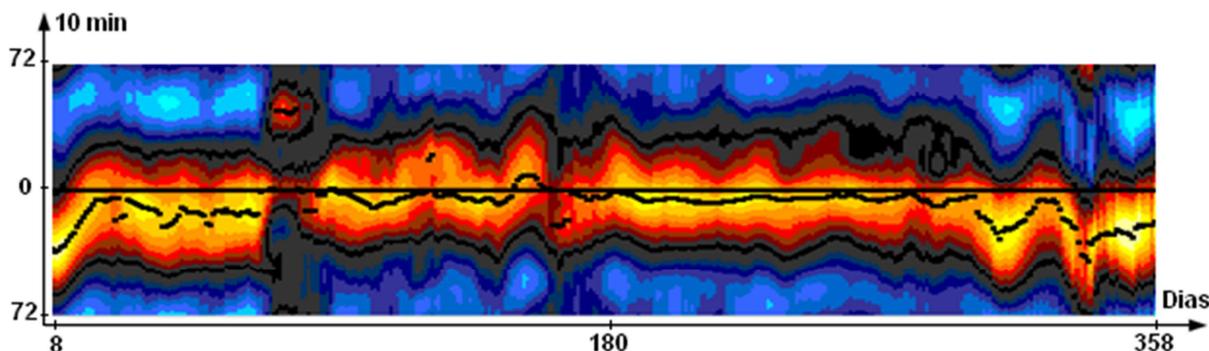


Figura 3.41 – Matriz das Correlações para a Estação 4.

- **Estação 5**

É interessante notar que no início e no final do ano os deslocamentos são positivos, enquanto que no meio do ano os deslocamentos são negativos.

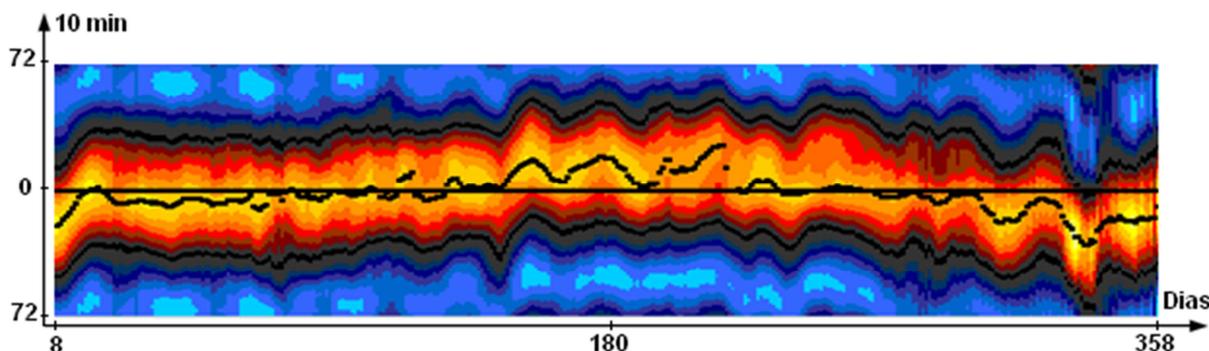


Figura 3.42 – Matriz das Correlações para a Estação 5.

- **Estação 6**

Na estação 6 é possível observar grandes deslocamentos ao longo de todo o ano. Por outro lado, enquanto as estações anteriores em sua maioria apresentavam deslocamentos no início do ano, nesta estação, durante este período, os deslocamentos encontrados são muito pequenos. Nota-se também comportamentos bastante cíclicos.

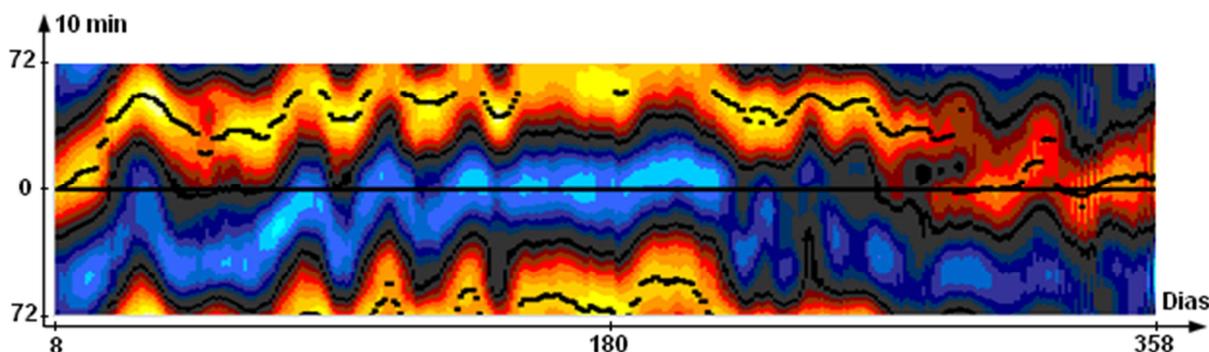


Figura 3.43 – Matriz das Correlações para a Estação 6.

- Estação 7

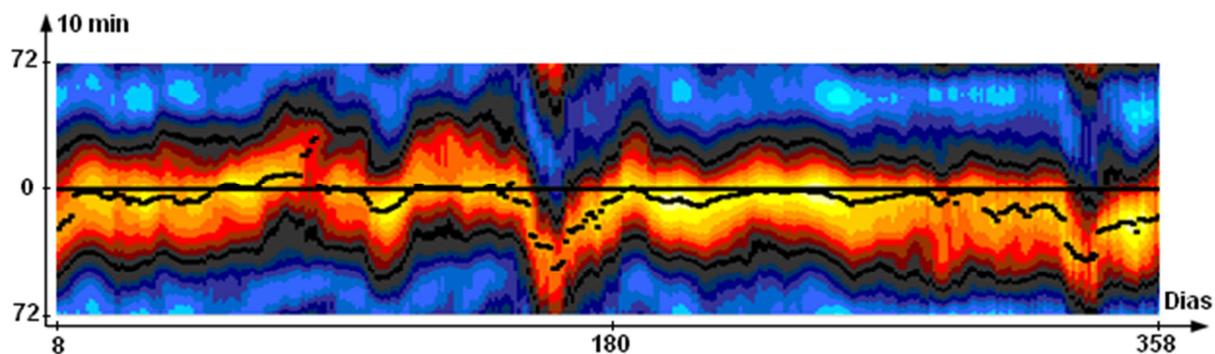


Figura 3.44 – Matriz das Correlações para a Estação 7.

- Estação 8

Os resultados para esta estação são bastante confusos onde no início do ano deslocamentos pequenos, mas com baixas correlações, enquanto que no meio do ano deslocamentos mais significativos.

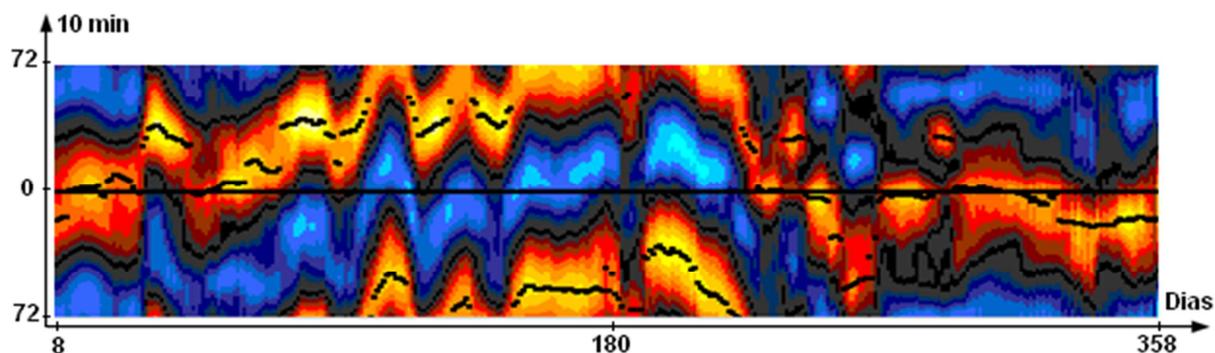


Figura 3.45 – Matriz das Correlações para a Estação 8.

- Estação 9

A estação 9 apresenta deslocamentos bem definidos com altas correlações.

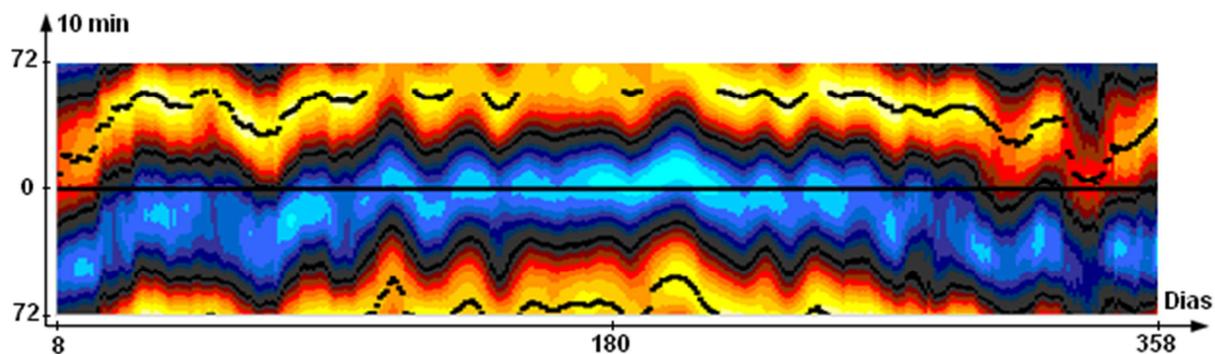


Figura 3.46 – Matriz das Correlações para a Estação 9.

- **Estação 10**

A estação 10 é a segunda mais próxima da estação de referência embora tenha sido a que menos deslocamentos apresentou.

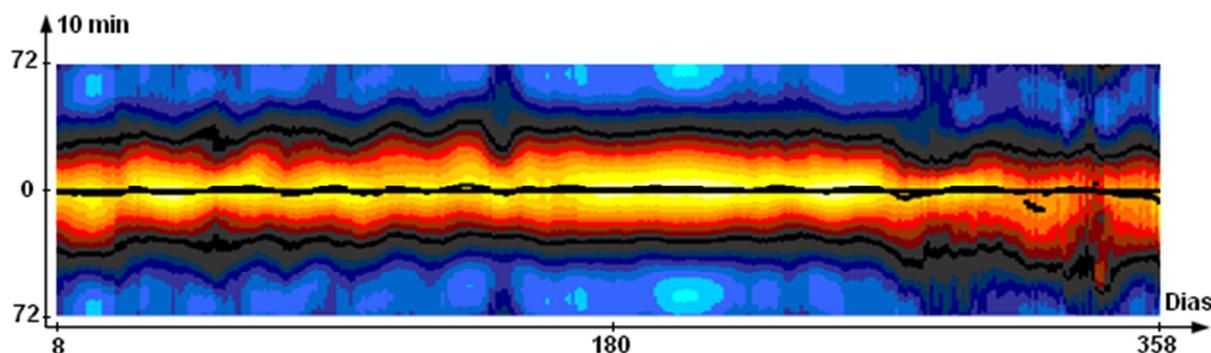


Figura 3.47 – Matriz das Correlações para a Estação 10.

Como já havia sido evidenciado na ferramenta anterior, algumas estações apresentaram deslocamentos grandes enquanto outras os deslocamentos oscilavam levemente em torno do eixo central. Esta ferramenta proporciona informações importantes para entender, principalmente, as baixas correlações encontradas entre algumas estações. O próximo passo seria aplicar os deslocamentos mapeados na tentativa de se obter melhores correlações.

3.2.1.3 Aplicação da ferramenta

Uma das principais vantagens da abordagem anterior é que permite que os resultados sejam aplicados diretamente. Em outras palavras, depois de mapeados os deslocamentos que maximizam as correlações pode-se calcular a correlação entre as estações utilizando-se os passos encontrados.

Nas seções anteriores a busca por altas correlações era realizada apenas em pequenos trechos dos dados de vento. Enquanto nas primeiras ferramentas apenas períodos com direção constante eram correlacionados, na segunda parte os métodos de correlação eram aplicados apenas nas sub-matrizes. Nesta seção, ao contrário, o método será aplicado nos dados como um todo, de forma que o resultado é representado por apenas um único valor de correlação.

Cada dia do ano estará vinculado ao passo de defasagem encontrado na seção anterior, o que implica dizer que os dados das estações não estarão sincronizados, na medida em que os passos sejam diferentes de zero. Além disso, em decorrência de que os passos variam ao longo do ano alguns dados serão contabilizados mais de uma vez, enquanto outros não serão contabilizados. A Figura 3.48 ilustra esta situação. Desta forma, para determinar o valor da correlação entre estações é fundamental que no cálculo das médias e desvios padrão sejam considerados apenas os dados contabilizados, garantindo assim a consistência do resultado.



Figura 3.48 – Exemplo de situação onde alguns dados são contabilizados mais de uma vez enquanto outros não são contabilizados.

Também é importante ressaltar que os passos foram encontrados através dos dados “sazonalizados”, que são consideravelmente mais bem comportados que os dados originais. A vantagem desta abordagem é que facilita a caracterização do comportamento dos passos ao longo do ano e, talvez permitindo que sua variação seja modelada.

Resultados

Para cada estação auxiliar foi calculada a correlação com relação à estação de referência, tanto para os dados “sazonalizados” assim como para os dados originais. Além disso, para comparar o método proposto com a correlação simples, foram realizadas correlações considerando-se os passos e sem considerá-los. A Tabela 3.9 apresenta os resultados para todos os casos.

Tabela 3.9 – Resultado das correlações utilizando-se os passos encontrados.

Estação	Dados “sazonalizados”		Diferença	Dados originais		Diferença
	sem passos	com passos		sem passos	com passos	
Est. 1	0,950	0,955	0,5%	0,861	0,852	-1,0%
Est. 2	0,691	0,733	6,1%	0,530	0,550	3,7%
Est. 3	0,705	0,744	5,6%	0,521	0,544	4,3%
Est. 4	0,723	0,768	6,3%	0,502	0,524	4,4%
Est. 5	0,738	0,765	3,6%	0,516	0,538	4,2%
Est. 6	0,483	0,857	77,6%	0,369	0,570	54,5%
Est. 7	0,804	0,828	2,9%	0,660	0,668	1,2%
Est. 8	0,626	0,784	25,3%	0,540	0,600	11,2%
Est. 9	0,162	0,780	382,5%	0,252	0,565	124,2%
Est. 10	0,977	0,979	0,2%	0,852	0,850	-0,2%

Como pode ser visto na Tabela 3.9, tanto nos dados “sazonalizados” quanto nos dados originais, o fato de se aplicar os passos aumentou significativamente as correlações. Estações como a 2, 3, 4 e 5 obtiveram melhoras da ordem de 4%, considerando os dados originais.

Por outro lado, o motivo pelo qual tanto a estação 1 quanto a 10 apresentaram uma leve diminuição nos valores de correlação, para os dados originais, se deve ao fato de os passos terem sido maximizados para os dados “sazonalizados”. Ambas as estações, por estarem muito próximas da

estação de referência, já apresentavam valores altos de correlação e, desta forma, naturalmente, o método não contribuiu muito para a melhora dos valores.

No entanto, os resultados mais expressivos foram justamente os das estações mais afastadas que são as estações 6 e 9. Para estas estações as correlações sem considerar passos de defasagem indicam valores de 0.369 e 0.252 enquanto que aplicando os passos passou para 0.57 e 0.565, respectivamente. Esta diferença significa um aumento de 54% para a estação 6 e 124% para a estação 9.

4 Conclusões e trabalhos futuros

Na busca por encontrar métodos que pudessem melhorar as correlações entre estações de medição do vento foram desenvolvidas diferentes ferramentas, cada qual com uma abordagem própria. As primeiras ferramentas tentaram incorporar nos seus métodos alguns aspectos da dinâmica dos ventos, de forma a considerar as distâncias entre as estações, além da direção e velocidade dos ventos. Na segunda parte, as ferramentas correlacionavam diretamente o comportamento sazonal de cada estação, sem levar em conta nenhuma hipótese física específica.

Primeira abordagem

De acordo com os resultados encontrados nas primeiras ferramentas, pôde-se observar que estações próximas, poderiam se beneficiar de métodos que levassem em conta aspectos da fenomenologia do vento. A estação 1, que dista 14 km da estação de referência, apresentou fortes indícios de que estas aplicações seriam válidas, como ilustrado na Figura 3.18. Além desta, a estação 10, a 40 km, também apresentou resultados interessantes (Figura 3.27). Não obstante, devido a grande complexidade do comportamento do vento, na medida em que as estações se distanciam as características captadas numa estação ficaram cada vez menos evidentes nas outras. Ainda assim, pode-se verificar que em algumas estações com mais de 100km de distância ainda havia indícios de alguns comportamentos resultantes das hipóteses assumidas, como foi o caso da estação 5 ilustrado na figura Figura 3.22. Sendo assim, pode-se concluir que uma abordagem de correlação fenomenológica teria sua aplicação, principalmente, para estações próximas.

No caso desta pesquisa as estações estavam demasiadamente longe para que se pudesse chegar a uma ferramenta aplicável. Para dar continuidade a estas pesquisas seria interessante estudar estações mais próximas, talvez, a menos de 40 km de distância entre si, com a intenção de modelar a influência das distâncias entre estações e das trajetórias do vento no cálculo da correlação.

Segunda abordagem

Na segunda abordagem não foi assumida nenhuma hipótese fenomenológica que pudesse justificar altas correlações e não foram levadas em consideração as distâncias entre as estações. Neste caso, buscou-se apenas “acoplar” as sazonalidades através de passos de defasagens visando maximizar as correlações. Ao contrário das primeiras ferramentas, o método das sazonalidades proporciona uma forma de aplicar os resultados encontrados diretamente nos dados de vento. Desta forma, pôde-se desenvolver uma ferramenta de correlação que pode ser comparada as demais ferramentas existentes. Os resultados mostraram que ele pode melhorar consideravelmente as correlações, principalmente nos casos em que as correlações preliminares são baixas. Em geral as melhoras

foram da ordem de 4%, sendo que nas estações com baixas correlações o aumento chegou a 54% na estação 6 e 124% na estação 9, o que é bastante considerável.

Trabalhos futuros

O trabalho apresentado nesta dissertação pode ser continuado em vários aspectos. Por um lado podem ser mais desenvolvidas ou aprimoradas as ferramentas apresentadas e, por outro lado, podem ser criadas metodologias para testar os resultados comparando-os com as demais técnicas existentes.

No caso da primeira abordagem, seria interessante analisar os resultados para estações com menor distância. A proposta seria estudar grupos de estações próximas na tentativa de criar ferramentas de correlação que pudessem aprimorar o estudo levando em conta a trajetória percorrida entre as estações.

Além disso, seria muito interessante implementar métodos para testar as ferramentas desenvolvidas de forma mais apropriada, permitindo a comparação com os demais métodos de MCP. Seria possível implementar os métodos desenvolvidos por ROGERS ET AL (2005b) que estimam as incertezas nos métodos de MCP.

Outra proposta de continuidade de pesquisa seria expandir o conceito da correlação matricial da velocidade para a correlação matricial da direção e verificar como se comportam as direções ao longo do ano e ao longo do dia.

Além disso, o estudo pode ser mais bem generalizado variando a estação de referência, assim como considerando outro conjunto de estações em condições geográficas diferentes.

Anexo A – Sazonalidade

O vento possui sazonalidades diárias e anuais em função dos ciclos solares. O gráfico do dia típico apresenta o comportamento médio do vento ao longo do dia durante um determinado período. No entanto este comportamento varia no decorrer do ano e não poderia ser generalizado por uma média aritmética simples do período. A Figura A 1 apresenta o dia típico anual e mensal da estação de referência e, como pode ser visto, a variação no comportamento do dia típico ocorre tanto na intensidade quanto na forma.

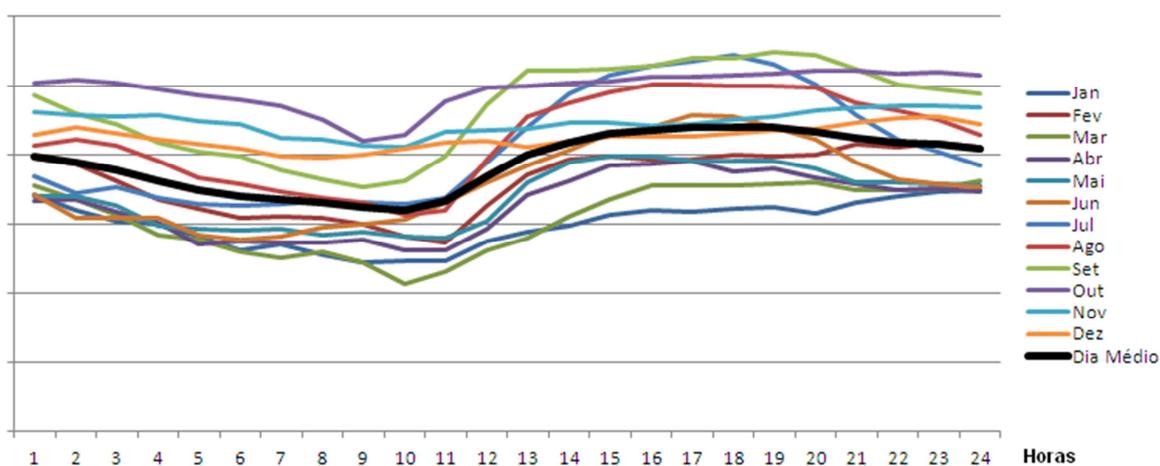


Figura A 1 - Dia típico anual e mensal da estação de referência.

Além do comportamento diário, a sazonalidade anual normalmente é bastante acentuada e pode ser observada nos gráficos das médias mensais. No entanto, representar a sazonalidade por médias mensais significaria assumir que períodos de 30 dias são adequados para caracterizar este comportamento, o que nem sempre procede. Para ilustrar esta questão a Figura A 2 apresenta os dados em médias de 5 dias assim como as médias mensais para a estação de referência. Neste sentido, faz-se necessário analisar qual seria a melhor forma de representar a sazonalidade anual.

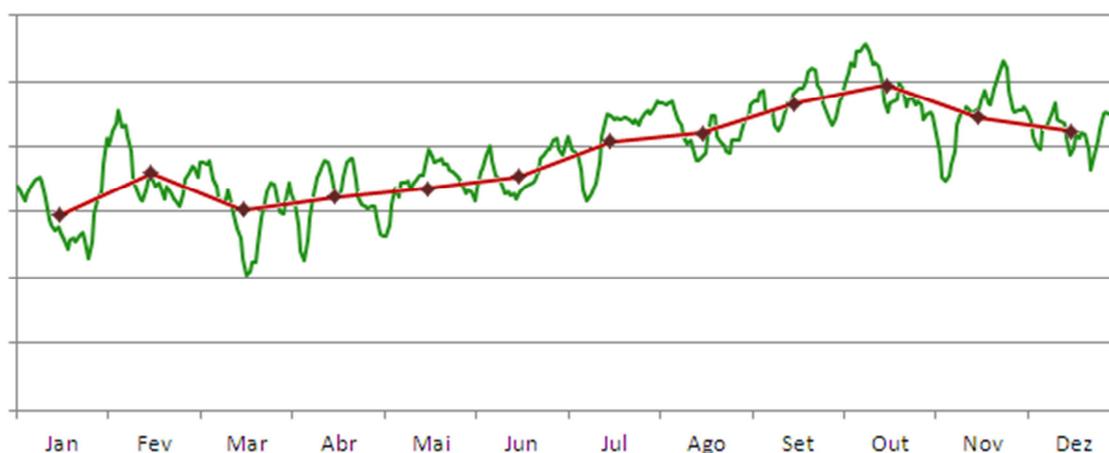


Figura A 2 - Médias mensais e médias de 5 dias da estação de referência.

Uma forma de ilustrar os dados de vento de forma a explicitar ambas as sazonalidades é através de um gráfico onde no eixo das abscissas são apresentados os dias e no eixo das ordenadas as horas, ou melhor, os valores de 10 minutos.

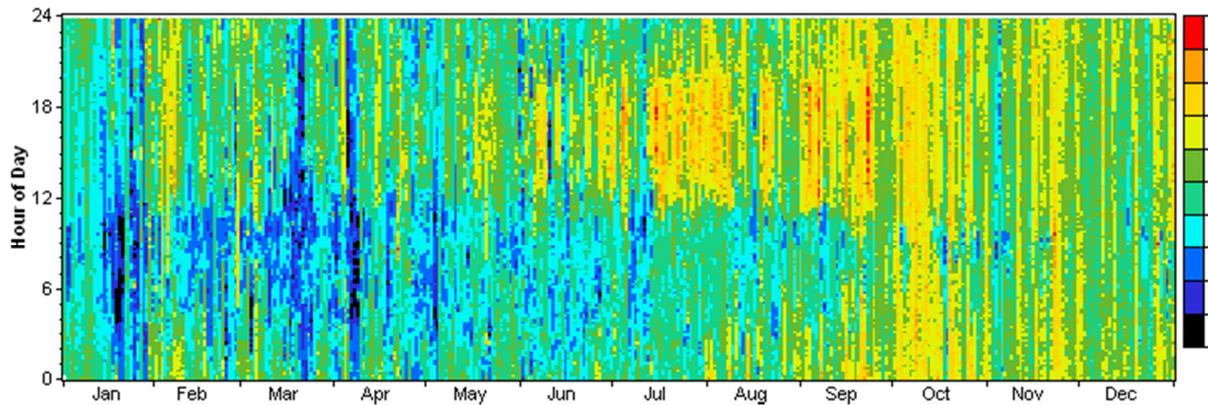


Figura A 3 – Dados estação estação de referência.

Para caracterizar ambos os comportamentos optou-se por fazer médias móveis exponencialmente ponderadas entre os dias e entre as horas. Desta forma, pode-se captar ambas as sazonalidades e suas variações ao longo do ano. A Figura A 4 ilustra a média sendo pondera exponencialmente em ambas as dimensões.

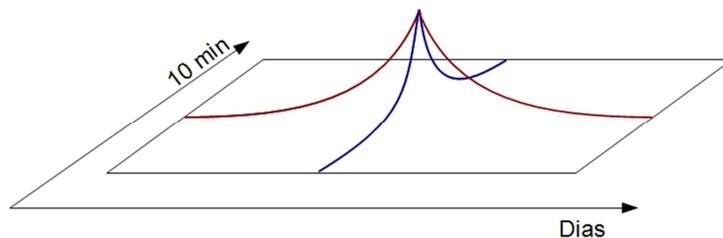


Figura A 4 – Média exponencialmente ponderada no eixo dos dias e no eixo das horas.

A expressão que representa essa média ponderada é definida por:

$$\bar{x}_{ij} = \frac{\sum_{d=-D}^D \sum_{m=-M}^M x_{dm} e^{-\lambda_m m} e^{-\lambda_d d}}{\sum_{d=-D}^D \sum_{m=-M}^M e^{-\lambda_m m} e^{-\lambda_d d}} \quad (12)$$

Onde \bar{x}_{ij} é a média ponderada, D é o número de dias considerados na média, M é o numero de registros de 10 minutos considerados, λ_d e λ_m são as constantes de decaimento para os dias e para os 10 minutos, respectivamente.

Diversas constantes de decaimento foram analisadas na tentativa de encontrar uma configuração que pudesse representar apropriadamente as sazonalidades. A Tabela 10 apresenta os parâmetros

analisados e os pesos que esses parâmetros representam. Apenas são apresentados os pesos acima de 10% para facilitar a visualização da extensão de influencia de cada parâmetro.

Tabela 10 – Constantes de decaimento utilizadas na análise das sazonalidades.

Dias/ 10 minutos	Constante de decaimento exponencial									
	2,0	1,5	1,0	0,8	0,5	0,3	0,18	0,12	0,10	0,08
0	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
± 1	14%	22%	37%	45%	61%	74%	84%	89%	90%	92%
± 2			14%	20%	37%	55%	70%	79%	82%	85%
± 3					22%	41%	58%	70%	74%	79%
± 4					14%	30%	49%	62%	67%	73%
± 5						22%	41%	55%	61%	67%
± 6						17%	34%	49%	55%	62%
± 7						12%	28%	43%	50%	57%
± 8							24%	38%	45%	53%
± 9							20%	34%	41%	49%
± 10							17%	30%	37%	45%
± 11							14%	27%	33%	41%
± 12							12%	24%	30%	38%
± 13								21%	27%	35%
± 14								19%	25%	33%
± 15								17%	22%	30%

A Figura A 5 ilustra como é estimado um valor no dado “sazonalizado” através de um conjunto dos dados originais.

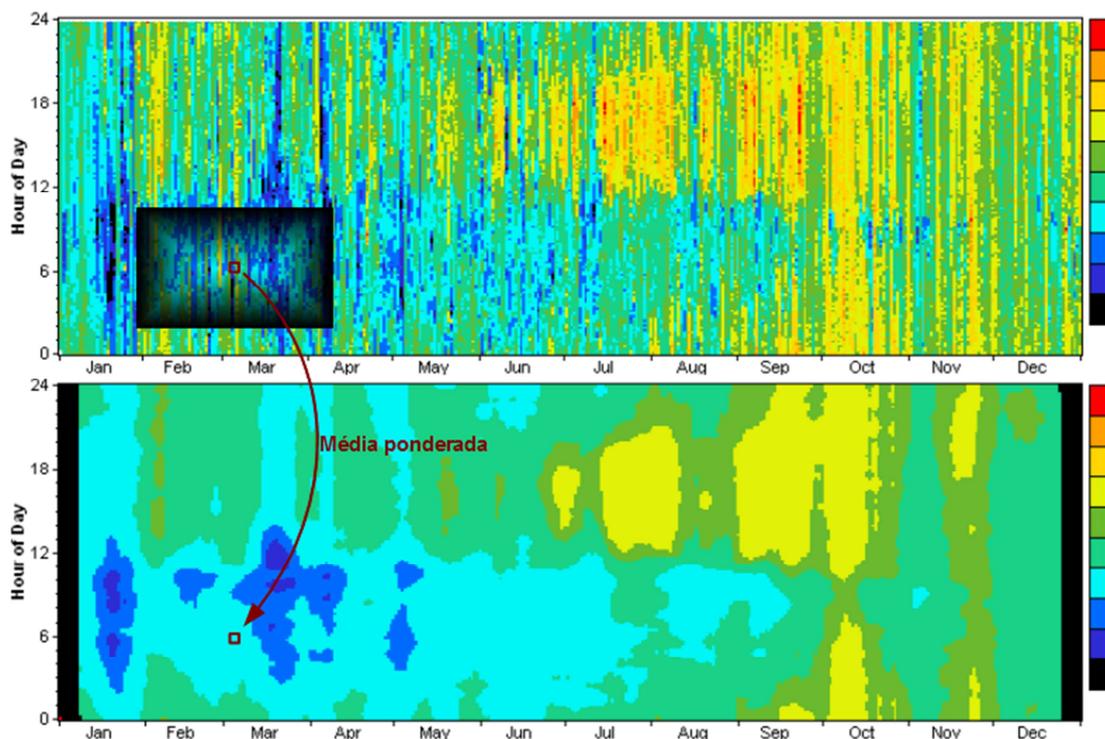


Figura A 5 – Ilustração da média ponderada sendo aplicada.

Para ilustrar a diferença nos dados sazonalizados em função dos ajustes nos parâmetros serão apresentadas a seguir diversas configurações para λ_d e D , mantendo-se os parâmetros λ_m e M fixos em 0.3 e 5 respectivamente.

A Figura A 6 apresenta os dados originais da estação de referência.

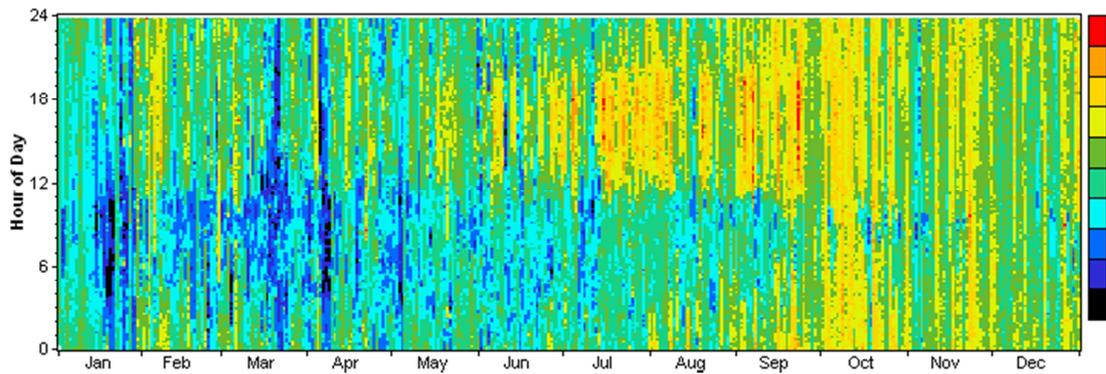


Figura A 6 – Dado original da estação de referência.

A Figura A 7 apresenta os dados “sazonalizados” com $D = 3$ e $\lambda_d = 0.3$.

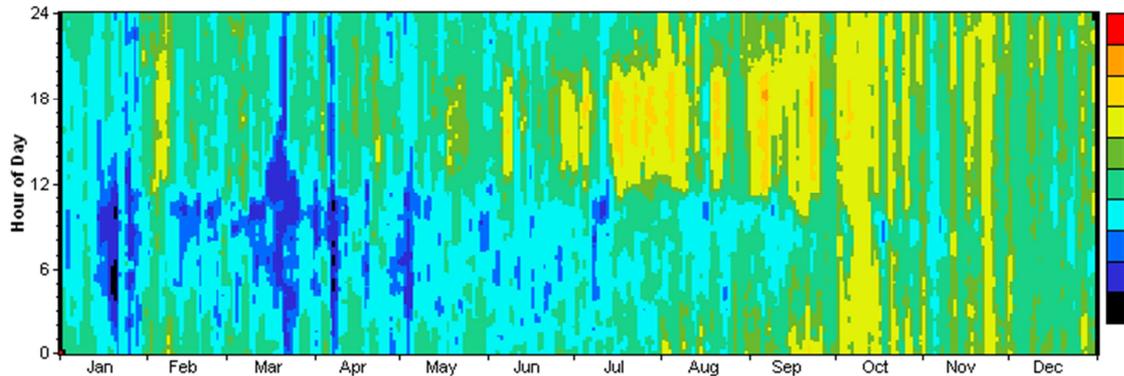


Figura A 7 – Dado “sazonalizado” com $D = 3$ e $\lambda_d = 0.3$.

A Figura A 8 apresenta os dados “sazonalizados” com $D = 5$ e $\lambda_d = 0.3$.

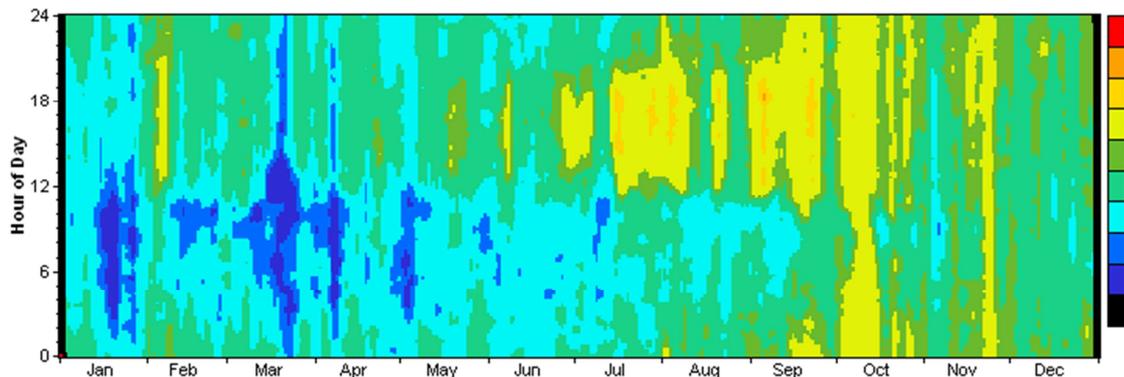


Figura A 8 – Dado “sazonalizado” com $D = 5$ e $\lambda_d = 0.3$.

A Figura A 9 apresenta os dados “sazonalizados” com $D = 9$ e $\lambda_d = 0.2$.

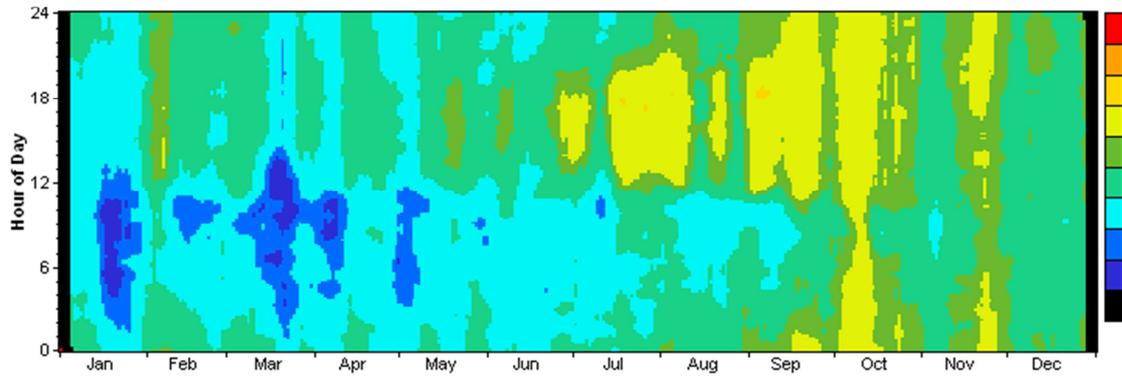


Figura A 9 – Dado “sazonalizado” com $D = 9$ e $\lambda_d = 0.2$.

A Figura A 10 apresenta os dados “sazonalizados” com $D = 15$ e $\lambda_d = 0.18$.

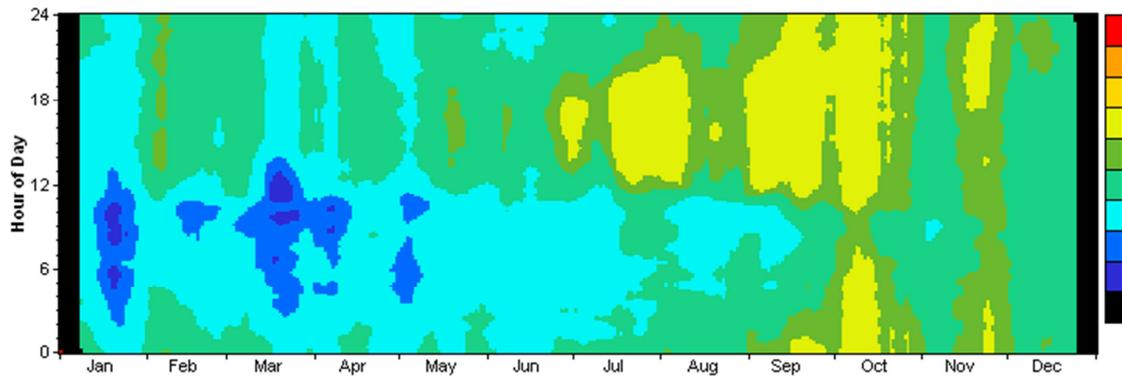


Figura A 10 – Dado “sazonalizado” com $D = 15$ e $\lambda_d = 0.18$.

A Figura A 11 apresenta os dados “sazonalizados” com $D = 21$ e $\lambda_d = 0.12$.

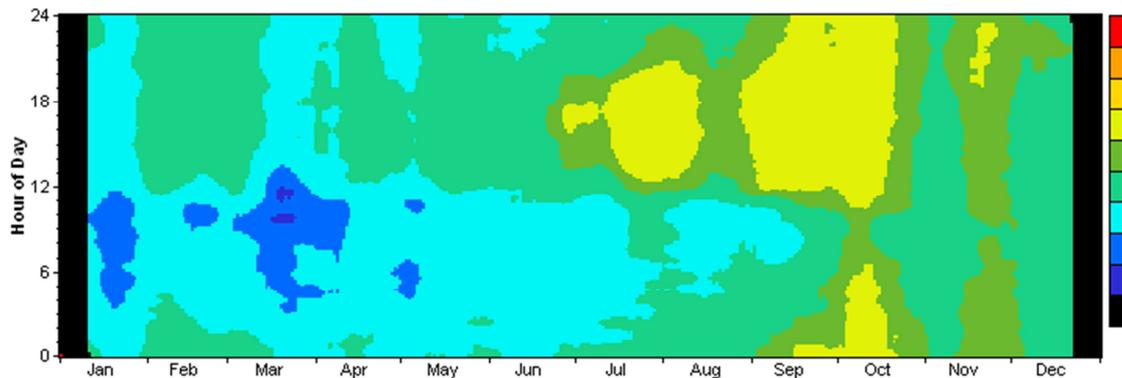


Figura A 11 – Dado “sazonalizado” com $D = 21$ e $\lambda_d = 0.12$.

Anexo B – Dados originais e sazonalidades

Neste anexo são apresentados os dados originais e as sazonalidades para todas as estações utilizadas na pesquisa. Os dados “sazonalizados” foram estimados através dos seguintes parâmetros: $D = 15$, $\lambda_d = 0.18$, $M = 5$ e $\lambda_m = 0.3$.

- Estação de Referência

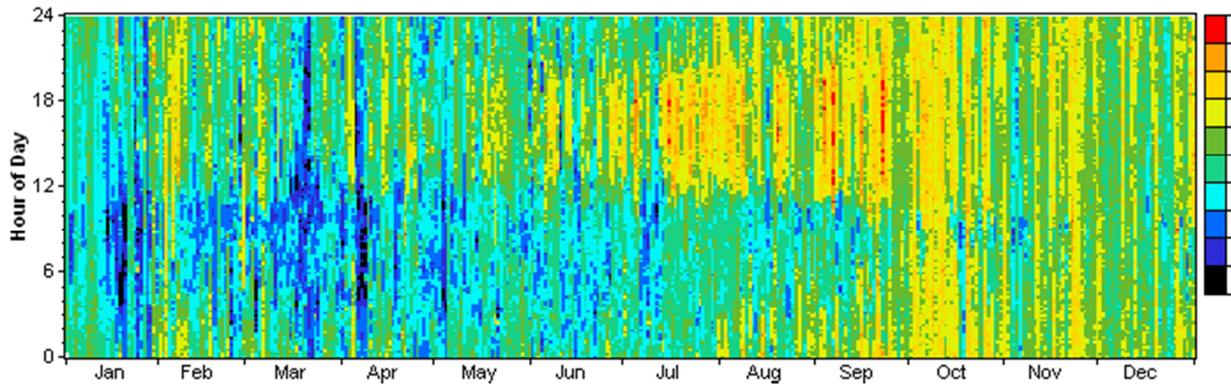


Figura B 1 – Dados originais da estação de referência.

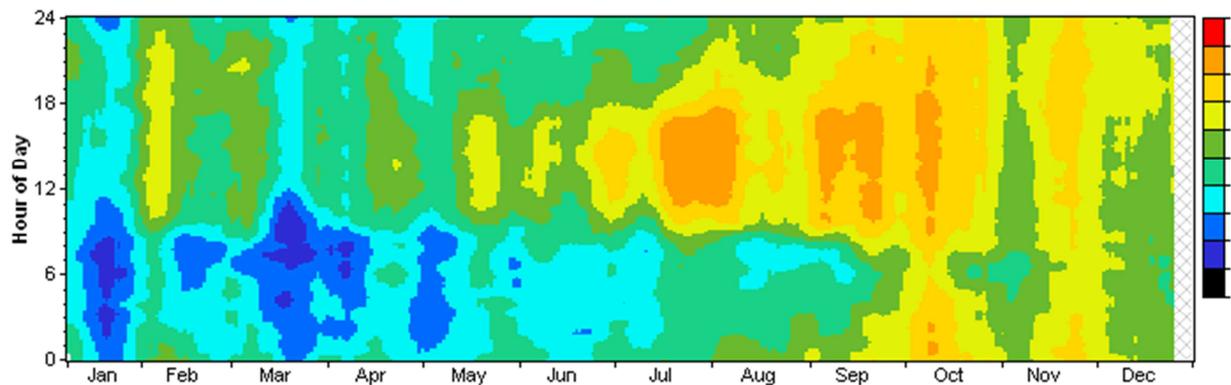


Figura B 2 – Dados “sazonalizados” da estação de referência.

- Estação 1

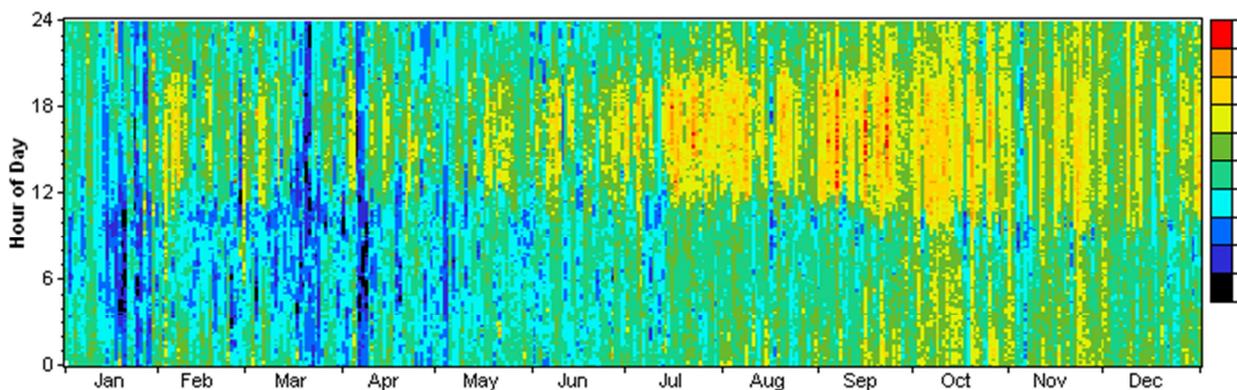


Figura B 3 – Dados originais da estação1.

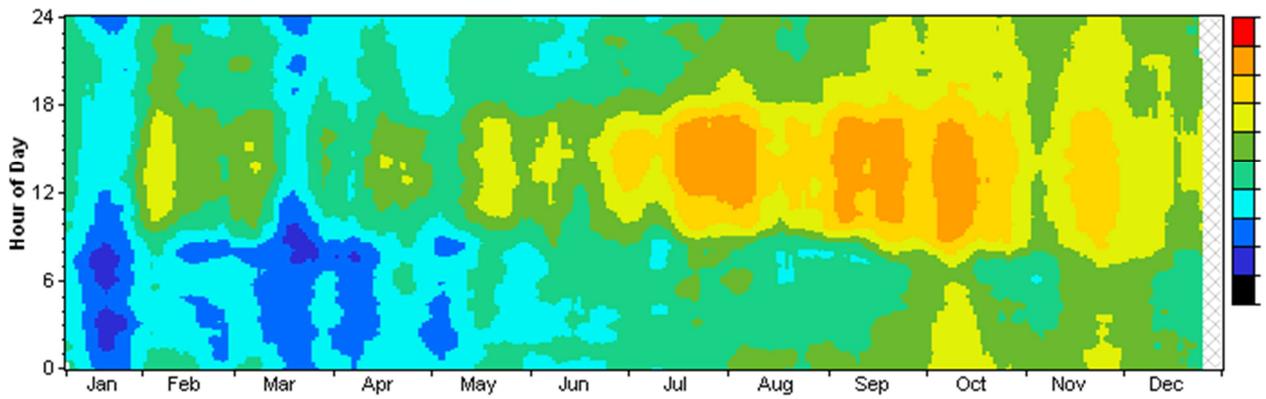


Figura B 4 – Dados “sazonalizados” da estação 1.

• Estação 2

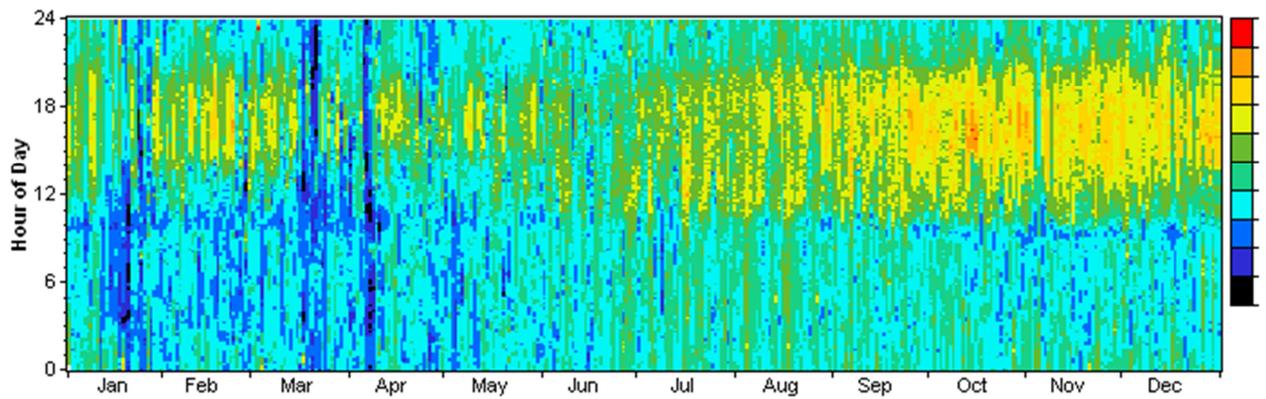


Figura B 5 – Dados originais da estação 2.

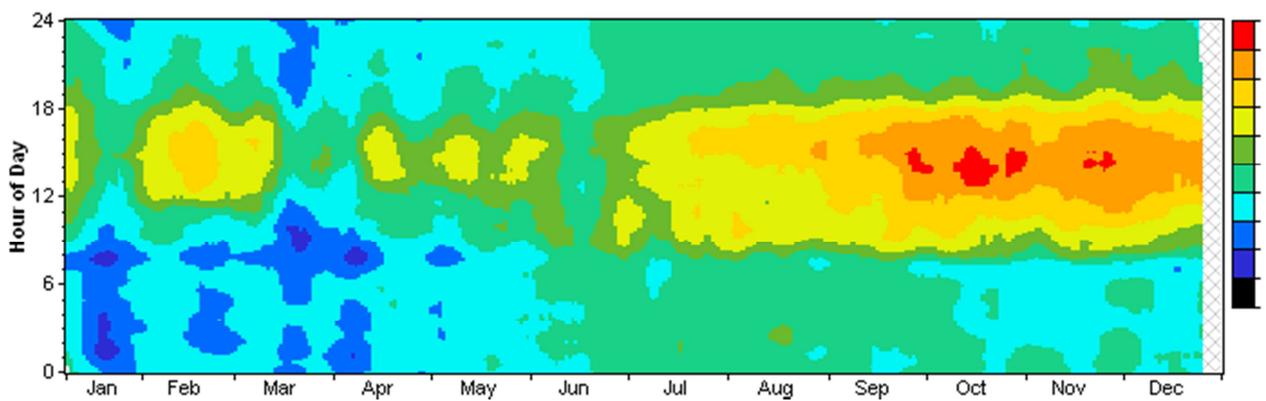


Figura B 6 – Dados “sazonalizados” da estação 2.

• Estação 3

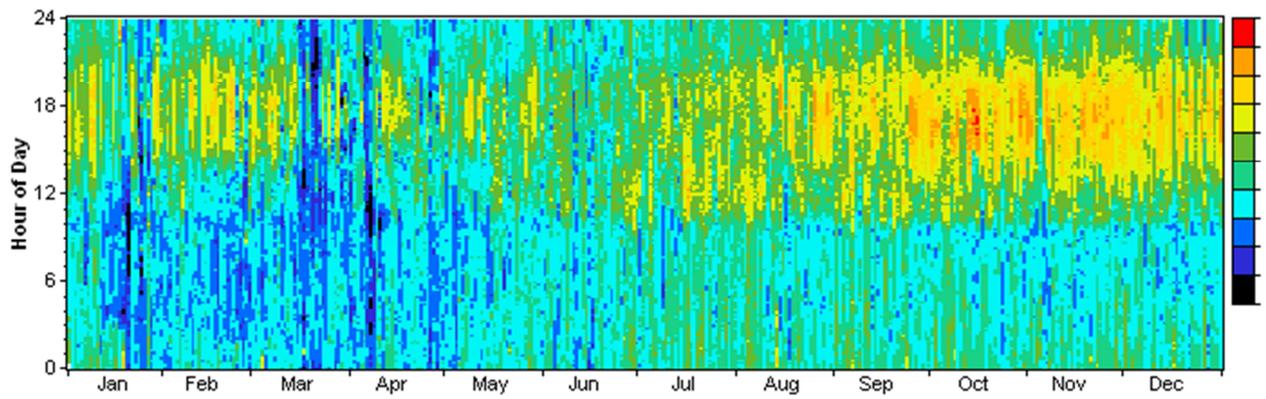


Figura B 7 – Dados originais da estação 3.

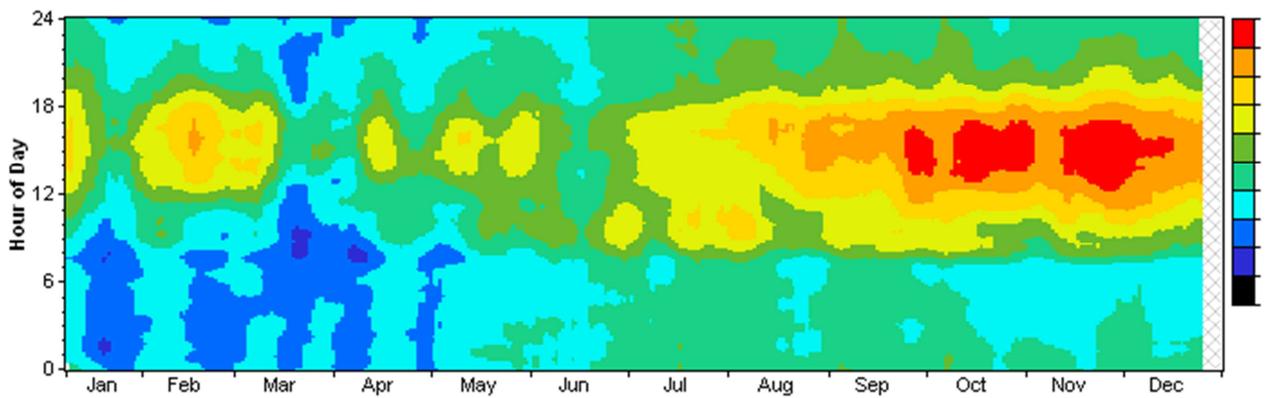


Figura B 8 – Dados "sazonalizados" da estação 3.

• Estação 4

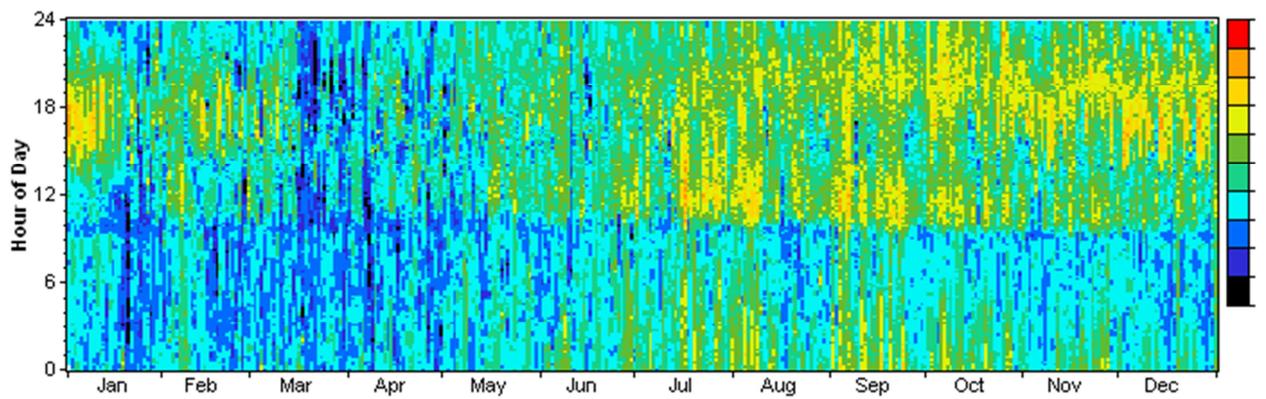


Figura B 9 – Dados originais da estação 4.

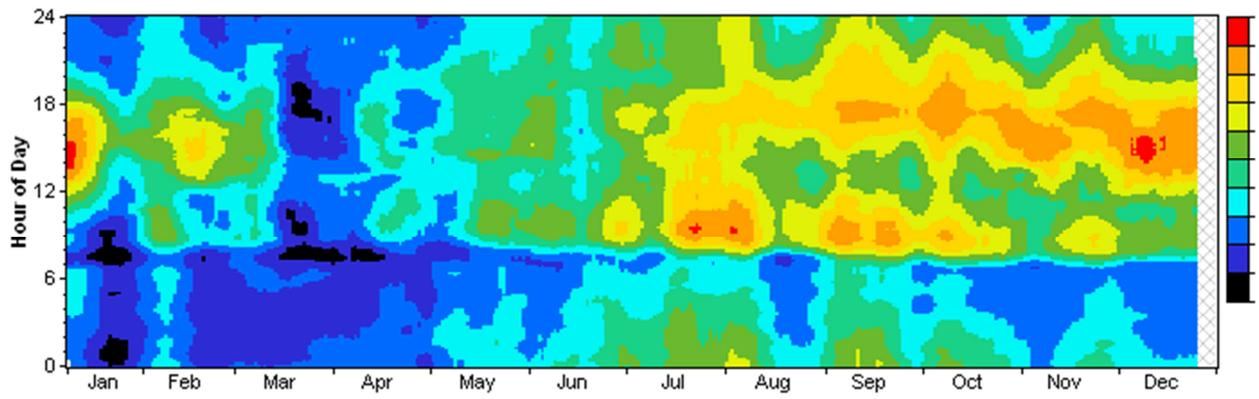


Figura B 10 – Dados “sazonalizados” da estação 4.

- Estação 5

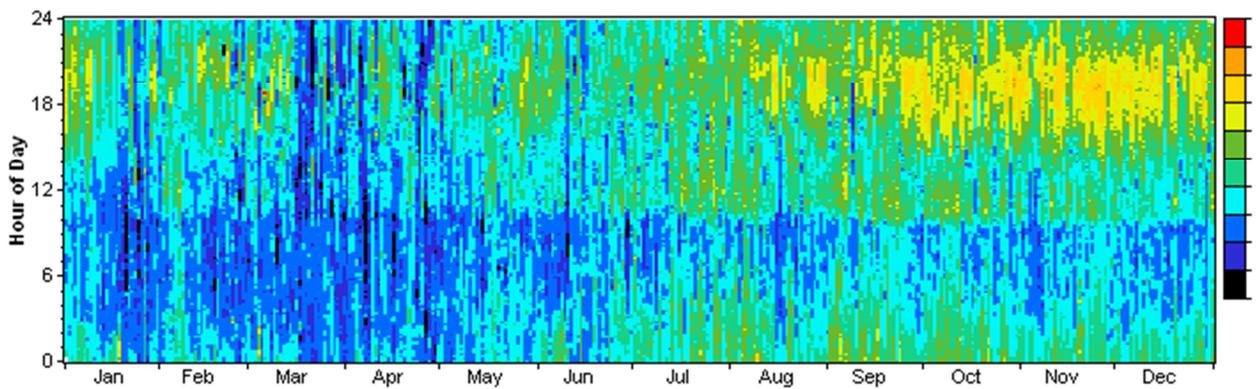


Figura B 11 – Dados originais da estação 5.

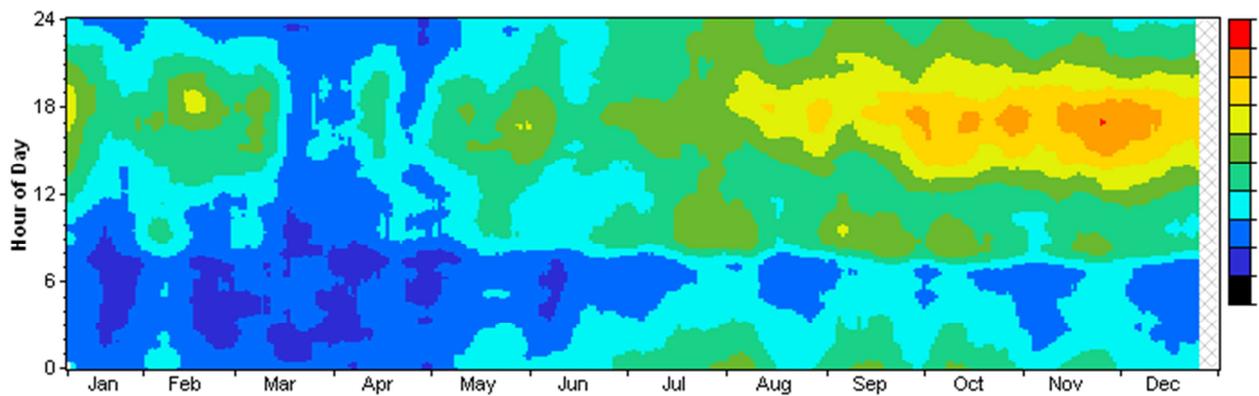


Figura B 12 – Dados “sazonalizados” da estação 5.

• Estação 6

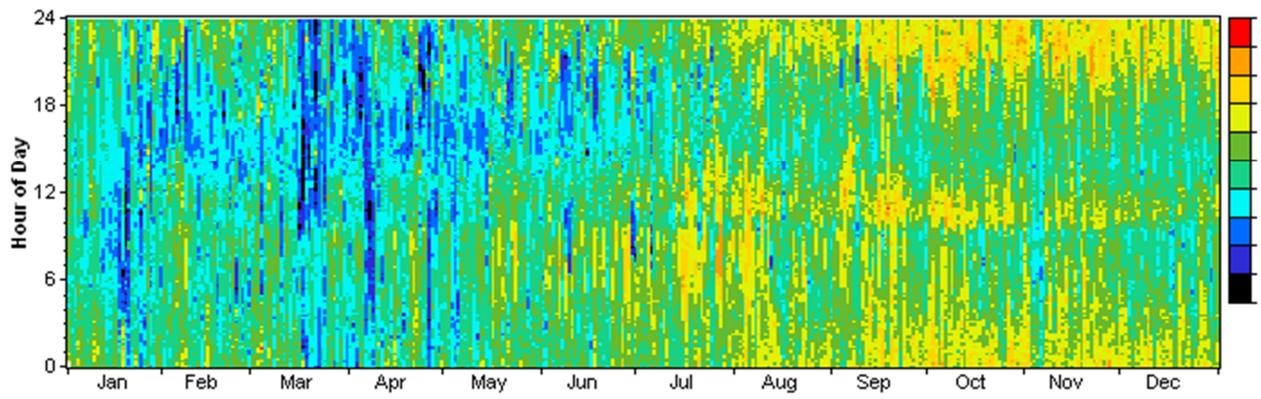


Figura B 13 – Dados originais da estação 6.

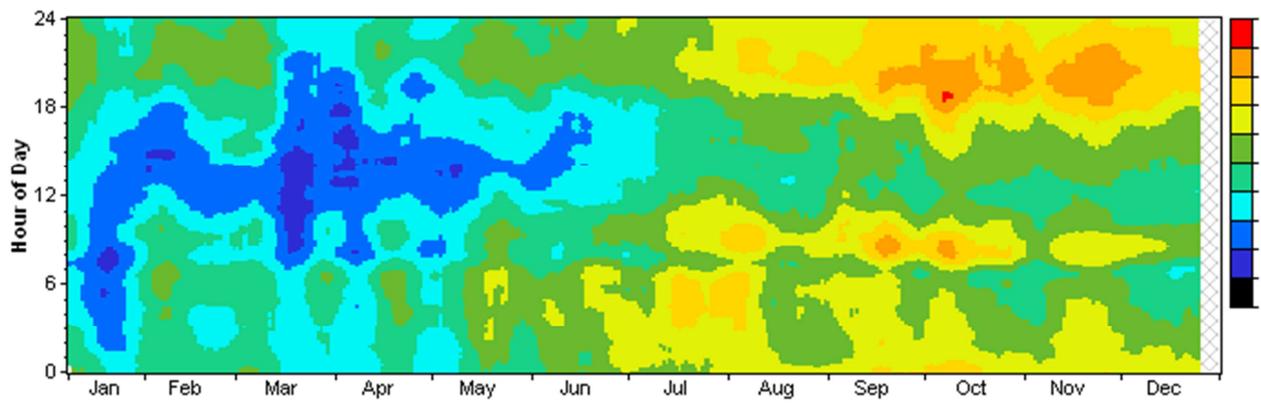


Figura B 14 – Dados “sazonalizados” da estação 6.

• Estação 7

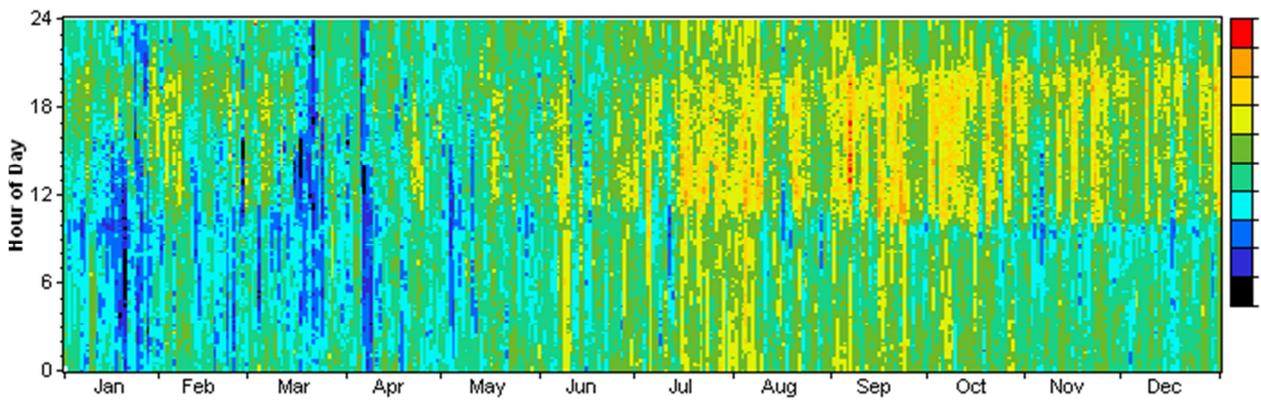


Figura B 15 – Dados originais da estação 7.

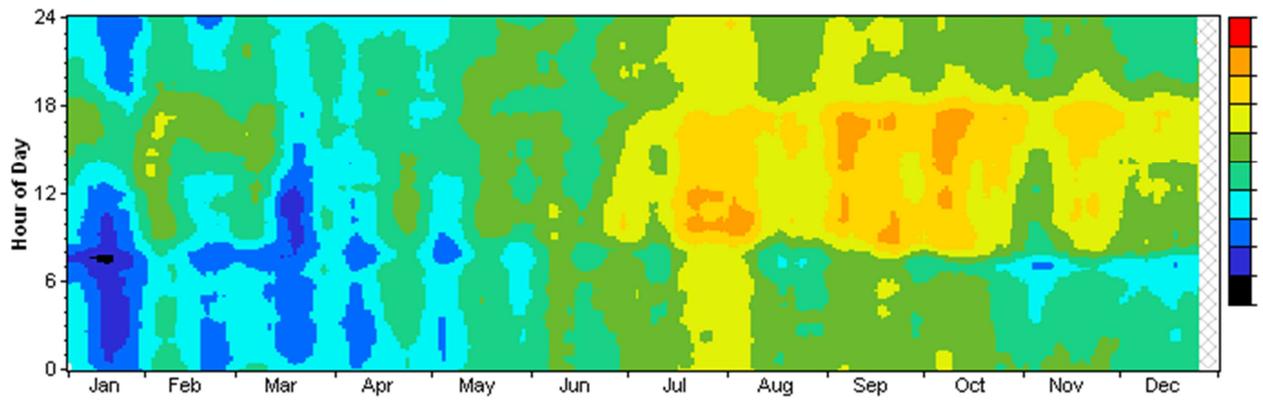


Figura B 16 – Dados “sazonalizados” da estação 7.

• Estação 8

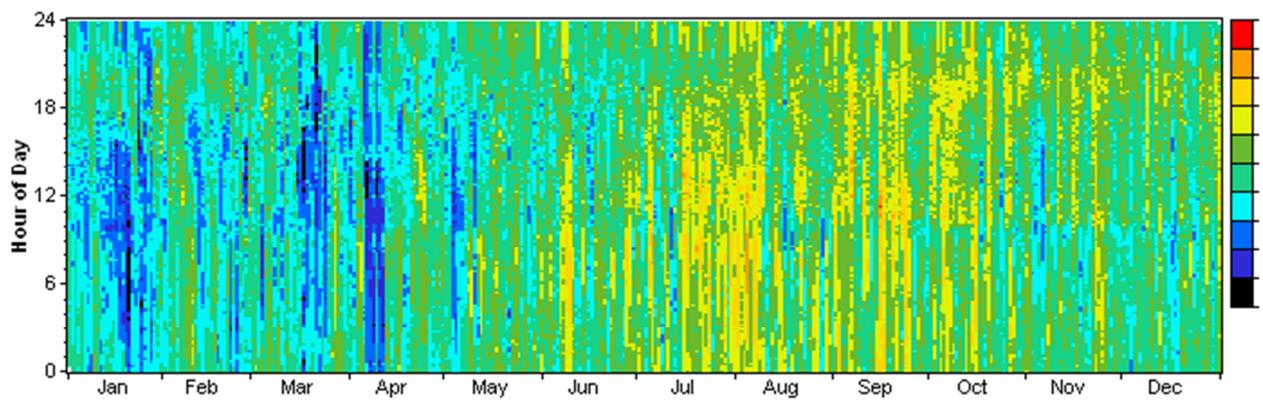


Figura B 17 – Dados originais da estação 8.

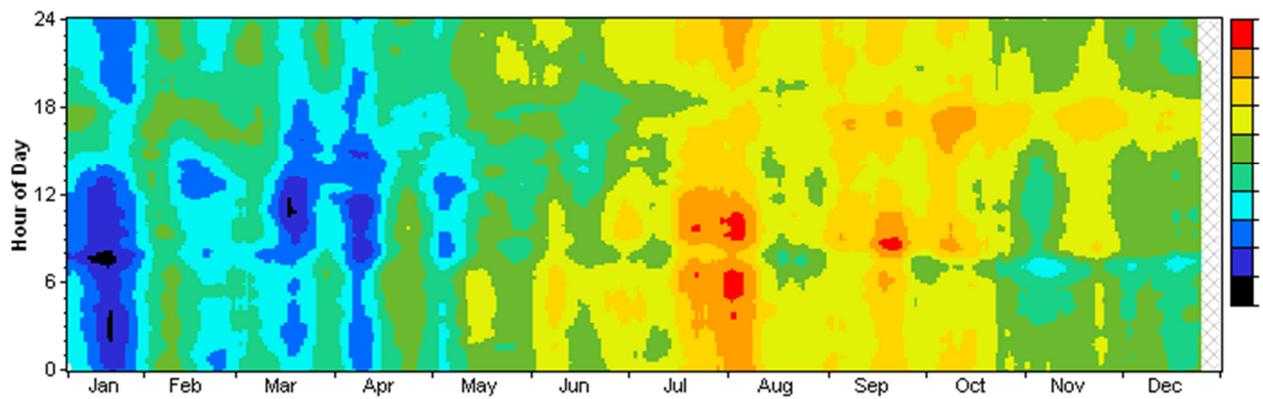


Figura B 18 – Dados “sazonalizados” da estação 8.

• Estação 9

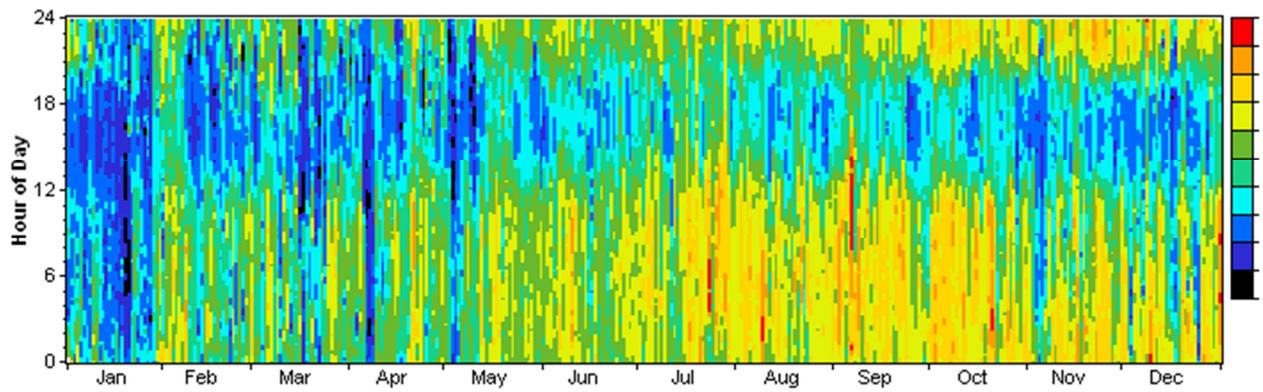


Figura B 19 – Dados originais da estação 9.

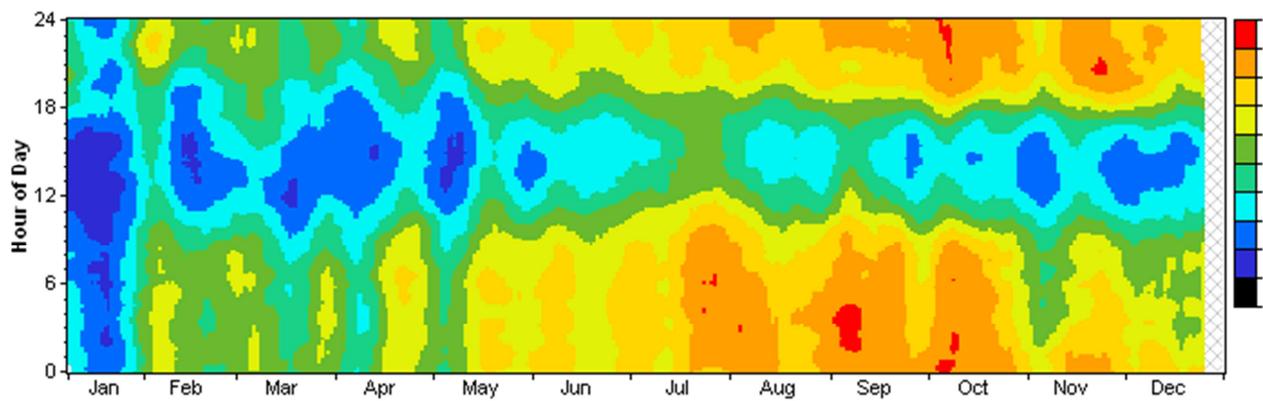


Figura B 20 – Dados “sazonalizados” da estação 9.

• Estação 10

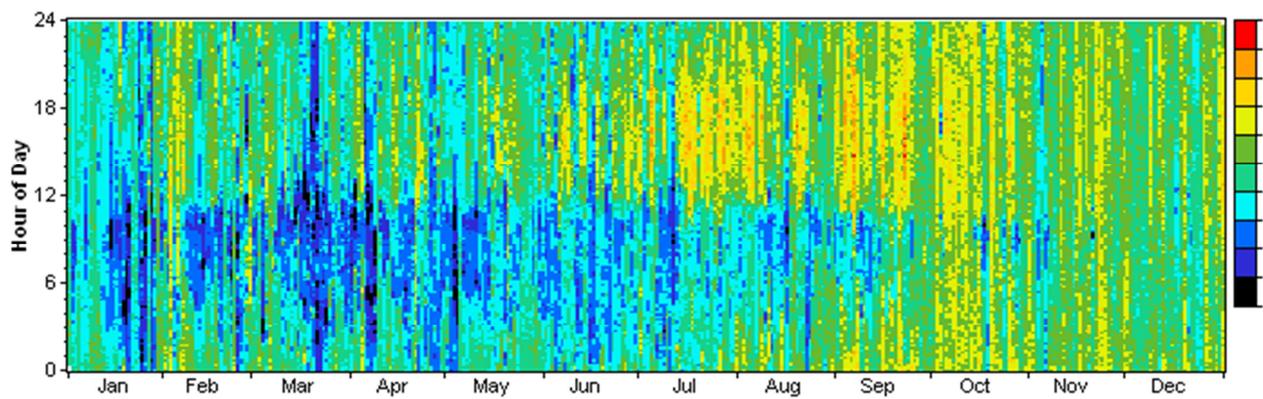


Figura B 21 – Dados originais da estação 10.

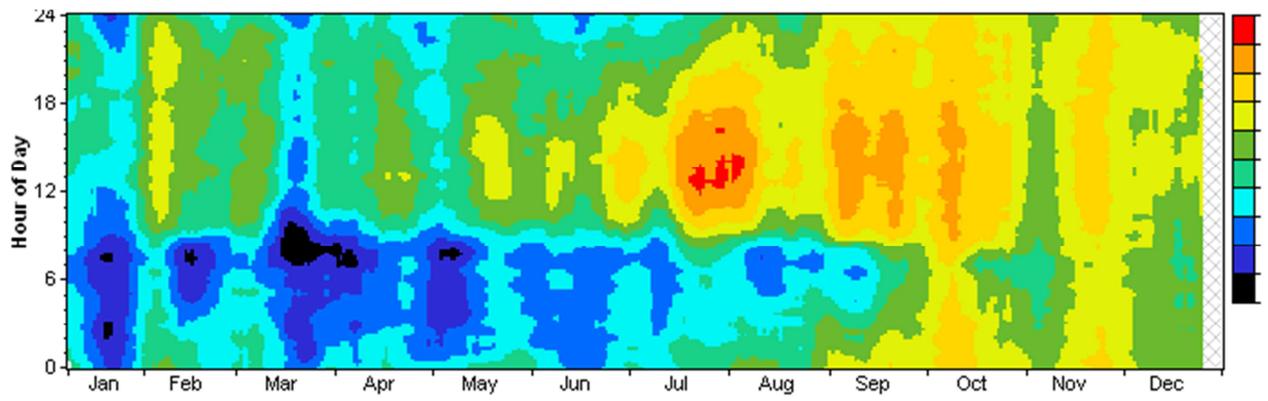


Figura B 22 – Dados “sazonalizados” da estação 10.

Referências Bibliografia

ADDISON J.F. DALE, HUNTER A., BASS J. AND REBBECK M. "A Neural Network Version of the Measure Correlate Predict Algorithm for Estimating Wind Energy Yield" *COMADEN 2000, 13th International Congress & Exhibition on Condition Monitoring & Diagnostic Engineering Management*. Houston, EUA, Dezembro 2000.

ALEXIADIS, M., P. DOKOPOULOS, H. SAHSAMANOGLU, AND I. MANOUSARIDIS, "Short-term forecasting of wind speed and related electrical power." *Solar Energy*, v. 63, n. 1, pp. 61–68, 1998.

ANTHONY L. ROGERS, JOHN W. ROGERS, JAMES F. MANWELL, "Comparison of the performance of four measure–correlate–predict algorithms", *Journal of Wind Engineering and Industrial Aerodynamics*, v. 93, n. 3, pp. 243-264, Março 2005.

ARCHER, C. L. AND M. Z. JACOBSON , "Evaluation of global wind power", *Journal of Geophysical Research - Atmospheres*, v. 110, 2005.

DEMETRI P. L., CORRADO F R., "The wind resource", *Modelling Of Atmospheric Flow Fields*, World Scientific Pub Co Inc., 1996.

DEVORE, J. L.. *Probability and Statistics for Engineering and the Sciences*. 6 ed. Thomson Learning, 2004.

DERRICK, A., "Development of the Measure Correlate Predict Strategy for Site Assessment" *Proceedings of European Community Wind Energy Conference*, pp. 681-685, Lübeck-Travemünde, Alemanha, Março 1993.

DIMITRIOS A. B., PANAGIOTIS D. S., "Correlation of Wind Speed Between Neighboring Measuring Stations" *IEEE Transactions On Energy Conversion*, v. 19, n. 2, pp. 400-406, junho 2004.

FERREIRA, R., LEITE, B. M. Disponível em:

<http://www.fem.unicamp.br/~em313/paginas/eolica/eolica.htm> Acesso em: 2 dez. 2010, 18:30:30.

EWEA, disponível em: <http://www.ewea.org/> , acesso em: 3 dez. 2010, 17:20:00.

GWEC, disponível em: <http://www.gwec.net/> , acesso em: 4 dez. 2010, 13:15:00.

GERDES G, STRACK M, "Long-term Correlation of Wind Measurement Data", *DEWI Magazin*, v.15, 1999.

JAMES R. SALMON, JOHN L. WALMSLEY, "A two-site correlation model for wind speed, direction and energy estimates", *Journal of Wind Engineering and Industrial Aerodynamics*, v. 79, n. 3, pp. 233-268, Fevereiro 1999.

JOENSEN A., LANDBERG L. AND MADSEN H., "A New Measure-Correlate-Predict Approach for Resource Assessment", *Proceedings of European Community Wind Energy Conference*, Nice, França, pp. 157-160, Março 1999.

ROGERS A.L., ROGERS J.W., MANWELL J.F., "Comparison of the Performance of Four Measure-Correlate-Predict Algorithms," *Journal of Wind Engineering and Industrial Aerodynamics*, v. 93, n.3, pp. 243-264, 2005a.

ROGERS A.L., ROGERS J.W., MANWELL J.F. "Uncertainties in results of measure-correlate-predict analyses." Renewable Energy Research Laboratory, American Wind Energy Association, Denver, EUA, CO. 2005b.

RAMÓN G. R., "Algorithm for the Estimation of the Long-term Wind Climate at a Meteorological Mast Using a Joint Probabilistic Approach" *Wind Engineering* , v. 28, n. 2, pp. 213–224, 2004.

TAYLOR, M., MACKIEWICZ P., BROWER M. C., MARKUS M., "An analysis of wind resource uncertainty in energy production estimates." AWS Truewind, LLC, European Wind Energy Association. 2004.

TONY B., DAVID S., NICK J., ERVIN B., - Chapter 10 Wind Statistics - John Wiley Wind Energy handbook ed. Wiley - Inglaterra 2004.

TOPNEWS, disponível em:

<http://www.topnews.in/wind-patterns-might-mask-effects-global-warming-ocean-219760>

acesso em: 4 jun. 2010, 22:25:00.

WOODS, J.C.; WATSON, S.J. "A new matrix method for predicting long-term wind roses with MCP". *Journal of Wind Engineering and Industrial Aerodynamics*, v. 66, pp. 85–94, 1997.