

3.

Previsão de Curto Prazo da Produção Eólica

Os modelos para previsão pontual da velocidade do vento ou da geração de energia eólica possuem uma alta referência na literatura técnica, isto porque a maioria das pesquisas tem-se focalizado basicamente na previsão pontual de energia eólica para distintos horizontes de tempo e na sua precisão. Neste capítulo será realizada uma análise mais detalhada sobre previsão de curto prazo, assim como dos diversos métodos que têm sido usados para gerar previsões de energia eólica e/ou velocidade do vento. Além disso, é apresentada uma comparação entre a previsão pontual e a previsão probabilística indicando quais são as vantagens do uso da previsão pontual. Ao longo das Seções se irão expondo estes tópicos que servem de suporte junto com a motivação do referencial teórico contido neste trabalho.

3.1.

Previsão de Energia Eólica

Atualmente a geração de energia eólica no mundo possui uma posição privilegiada dentro das matrizes energéticas. A produção desta energia está aumentando de forma vertiginosa, e devido a estes incrementos, a geração de previsões deste tipo de recurso renovável torna-se imprescindível para um adequado aproveitamento.

Previsões exatas de energia eólica (e/ou previsão da velocidade do vento) reduzem o risco de incerteza e permitem melhor planejamento da rede e integração do vento dentro do sistema de energia. No entanto, uma conclusão comum é que como os níveis de inserção de energia eólica estão incrementando a um ritmo acelerado, o balanço do sistema se torna cada vez mais necessário.

Embora existam grandes vantagens no aproveitamento da energia eólica, a natureza aleatória do vento faz com que a sua previsão seja uma tarefa muito complexa. Isto afeta diretamente as operações de planejamento, manutenção e despacho; pois, uma vez que o parque eólico entrou em funcionamento e foi conectado ao sistema elétrico, é preciso que os operadores obtenham previsões precisas com a finalidade de minimizar os riscos técnicos e financeiros.

Dentro da literatura de modelos de previsão, uma vasta quantidade de modelos de curto prazo tem sido proposta, no entanto, a quantidade de modelos de longo prazo é muito inferior. Uma das principais problemáticas que deve ser enfrentada na construção

de modelos de previsão da geração de energia eólica é a *volatilidade do vento*, já que comparado com outras fontes de energia convencionais, o recurso possui características aleatórias que fazem com que modelos que incorporam conhecimento físico e estatístico possuam melhores desempenhos.

Não obstante, apesar da existência de uma vasta quantidade de técnicas e modelos para previsão da geração de energia eólica, a área de pesquisa para previsão pode ser estendida significativamente, pois a energia eólica usada como fonte de energia renovável é muito recente. Os trabalhos de Giebel et al. (2003), Kariniotakis et al. (2006a), Kariniotakis et al. (2006b), Costa et al. (2008), Lange & Focken (2008), Lei et al. (2009), Monteiro et al. (2009), Soman et al. (2010), Giebel et al. (2011), Wang et al. (2011), Zhao et al. (2011), Zheng et al. (2011), Foley et al. (2012), realizam uma análise do estado da arte dos diversos métodos e modelos empregados para previsão da geração de energia usando diferentes enfoques. Desta forma, estabelecem-se classificações em termos de complexidade, eficiência e aplicação. Uma visão muito mais detalhada dos métodos e técnicas associadas ou não, a projetos de escala industrial, encontra-se em Giebel et al. (2011).

Com base na revisão desta literatura, estabelece-se que os métodos de *previsão da velocidade* do vento podem ser agrupados em duas categorias: modelos baseados na análise de séries históricas da velocidade (e/ou direção) do vento e aqueles que usam valores previstos de modelos numéricos de previsão climatológica (NWP - *Numerical Weather Prediction*) e posteriormente empregam uma conversão em energia eólica. Porém, a *previsão da geração* de energia eólica é geralmente descrita em termos de métodos físicos ou NWP, métodos estatísticos (Box & Jenkins, Filtro de Kalman, Wavelet, Singular Spectral Analysis, entre outras) e os denominados modelos baseados em Inteligência Computacional (Redes Neurais, Lógica Fuzzy, etc.). A combinação de qualquer dois ou mais modelos dos descritos acima geram os modelos denominados híbridos (Foley et al., 2012).

A maioria das publicações recentes dos *modelos de previsão de geração eólica* é feita em dois estágios; no primeiro estágio ajusta-se um modelo (seja ele estatístico, de inteligência computacional ou mesmo híbrido) para prever a velocidade do vento incidente nos aerogeradores, e em seguida, utilizando a curva de potência, gera-se a conversão da energia eólica (Madsen 1995; Nielsen & Madsen, 1996). Os modelos baseados na análise das séries históricas da velocidade do vento normalmente usam um enfoque estatístico para prever a velocidade, e posteriormente se prevê a produção de energia eólica. Segundo Giebel et al. (2003), este enfoque é um dos mais utilizados para construção de modelos de previsão de curto prazo.

As previsões da produção eólica podem ser classificadas em: previsões diretas ou em previsões indiretas. As previsões diretas, como seu nome diz, são obtidas diretamente da modelagem da série de geração eólica; enquanto que as previsões indiretas são aquelas obtidas a partir da modelagem da série de velocidade de vento, e cujas previsões são transformadas em previsões de geração eólica por meio da curva de potência (Zheng et al., 2011). Na maioria dos casos, estes modelos proporcionam bons resultados na estimação da média mensal da velocidade do vento ou até mesmo escalas em temporais superiores (trimestral, anual). No entanto, no curto prazo, para previsões da média diária ou horária da velocidade do vento, a influência da dinâmica atmosférica torna-se mais importante; de modo que a utilização de modelos de previsão da geração de energia que fazem uso de variáveis explicativas (principalmente velocidade média horária do vento e direção) chega a ser essencial (Landberg, 2001). Uma comparação entre as duas abordagens (direta e indireta) mostrou que o uso da velocidade do vento como variável explicativa, em modelos auto-regressivos, teve melhores resultados em horizontes de previsão até 8-12 horas. Para maiores horizontes de previsão, o uso da velocidade do vento não ofereceu nenhuma vantagem sobre o uso direto da variável energia eólica (Giebel et al., 2011).

Até agora, o modelo em dois estágios inclui a etapa de conversão da velocidade do vento em energia, que na maioria das vezes é realizada através da curva de potência, e pode incluir também a soma das potências das diferentes turbinas de um parque eólico. Entretanto, quando há necessidade de se prever a energia de todos os parques eólicos da região, um terceiro estágio pode ser acrescentado. Na prática, algumas usinas representativas são escolhidas e seus dados são usados como base de cálculo e o resultado é inferido ao conjunto.

A previsão da velocidade do vento para a geração de energia eólica e o planejamento das operações dos sistemas de energia se focaliza principalmente na previsão de curto prazo, isso ocorre porque as operações do sistema de energia, tais como a regulação, atendimento da carga, balanceamento e programação do despacho das unidades geradoras, são realizadas dentro de prazos estabelecidos. Previsões de 1 até 72 h, são feitas para programação de operação de curto prazo e despacho, e para comercialização de energia elétrica. Por outra parte, previsões que variam de 3 até 7 dias são utilizadas para planejar a manutenção dos parques eólicos, comissionamento de gerador, interrupções para manutenção dos geradores térmicos e para programar a manutenção da rede e as operações de armazenamento de energia (Foley et al., 2012). A classificação dos métodos de previsão de vento considerando a escala de tempo não é completamente clara; segundo Soman et al. (2010), a previsão do vento pode ser separada nas seguintes categorias:

- Previsão de curtíssimo prazo: De alguns segundos até 30 minutos à frente.
- Previsão de curto prazo: De 30 minutos a 6 horas à frente.
- Previsão de médio prazo: A partir de 6 horas até 1 dia à frente.
- Previsão de longo prazo: A partir de 1 dia até 1 semana à frente.

No obstante, uma consolidação das aplicações de cada um dos horizontes de tempo baseadas nas no funcionamento da rede de eletricidade foi construída (ver Tabela 3.1), levando em consideração as revisões feitas por Soman et al. (2010), Wang et al. (2011), Zhao et al. (2011) e Foley et al. (2012).

Tabela 3.1 – Classificação horizonte de previsão da geração de energia eólica.

Escala de tempo	Limite de Variação	Aplicações
Curtíssimo Prazo	30 minutos	- Ações de Regulação - Compensação do mercado de eletricidade - Planejamento econômico de despacho de carga
Curto Prazo	8 horas à frente	- Decisões razoáveis de carga (incremento / diminuição)
Médio Prazo	1 dia à frente	- Operações da rede em tempo real - Segurança operacional no mercado da eletricidade - Gestão da operação - Programação do despacho das unidades geradoras
Longo Prazo	Vários dias à frente	- Decisões de unidades de reserva - Planejamento de manutenção e obtenção do custo operacional ótimo

3.2. Previsão Pontual e Previsão Probabilística

No caso da previsão da velocidade do vento existem duas principais abordagens: previsão pontual e previsão probabilística. A previsão pontual dá um valor único como previsão futura da velocidade do vento, enquanto que os modelos de previsão probabilística da velocidade do vento proporcionam a previsão de uma função de densidade de probabilidade para a velocidade do vento futuro. Embora a previsão pontual

seja o interesse principal da previsão da velocidade do vento ela possui uma variabilidade devido ao erro de previsão, além de não fornecer nenhuma informação sobre como o verdadeiro valor seria distribuído em torno da previsão, o que é muito importante para os operadores do sistema de energia para tomar decisões de forma acertada. No entanto, a previsão probabilística ajuda a contornar esta situação porque não só proporciona previsões pontuais como a média ou quantis da distribuição, mas também fornece informações sobre a incerteza. Além disso, a partir da densidade de probabilidade, os intervalos de confiança de uma previsão pontual podem ser calculados e isso auxilia os operadores do sistema de energia a tomar decisões mais confiáveis. Uma valiosa revisão das distribuições de probabilidade da velocidade do vento usadas em análises de energia pode ser encontrada em Carta et al. (2009).

Na previsão probabilística da velocidade do vento, a escolha das funções de densidade deve ser consistente com os padrões do vento. As velocidades do vento são valores não negativos e, geralmente viesados à direita (assimetria positiva) devido à baixa probabilidade de valores altos. Alguns regimes do vento podem ser bimodais ao invés de ser unimodais, e também podem ter altas porcentagens de nenhuma velocidade do vento ou de alta velocidade do vento.

Conseqüentemente, densidades que estão viesadas à direita com domínio não negativo, geralmente são escolhidas para ajustar a distribuição da velocidade do vento. Funções de distribuição como a Gama, Weibull, Rayleigh, Lognormal, GEV, as distribuições Beta, têm sido usadas para ajustar a densidade de probabilidade e a distribuição acumulada da velocidade do vento (Morgan et al., 2011; Al-Buhairi & Al-Haydari, 2012); além de misturas de distribuições de probabilidades (Carta & Ramirez, 2007; Kollu et al., 2012). Entre essas distribuições, a distribuição Weibull é considerada a mais aceita para a energia eólica: é flexível, com uma forma fechada, só tem dois parâmetros que são fáceis de estimar e tem testes de qualidade de ajuste (*goodness-of-fit tests*) específicos como discutido por Ramirez & Carta (2005). Apesar disso, a distribuição Weibull não pode representar porcentagens de velocidades do vento elevadas, nulas ou bimodais. A distribuição normal truncada foi considerada útil para descrever os ventos com altas porcentagens de velocidade do vento nulo (Carta et al., 2008). A mistura de distribuições com uma distribuição Weibull e uma distribuição normal truncada foram ajustadas em velocidades do vento bimodal, levando também em consideração as velocidades do vento nulas (Carta & Ramirez, 2007).

Em Lau & McSharry (2010), aplicou-se uma transformação logística para dados de energia eólica normalizados, e ajustou-se um modelo para dados transformados. Eles produziram previsões probabilísticas de 15 min a 24 h à frente que superaram as previsões com base em uma distribuição normal truncada com um método de alisamento

exponencial. O último modelo ainda foi considerado ser uma alternativa útil em problemas de previsão probabilística, devido à sua robustez e eficiência computacional.

Recentemente, a distribuição assimétrica bivariada t (Azzalini & Genton, 2008) tem sido usada por Hering & Genton (2010) em problemas de previsão de velocidade do vento, após a conversão da velocidade e a direção do vento em componentes cartesianas. A modelagem t multivariada da velocidade e da direção do vento é de interesse para os regimes de vento com uma elevada percentagem de velocidades altas ou extremas.

3.3.

Numerical Weather Prediction (NWP)

A categoria dos modelos físicos abrange métodos numéricos para previsão climática NWP, estes são modelos físicos que estimam pontualmente a velocidade do vento com base na avaliação das condições físicas e meteorológicas da região, considerando aspectos tais como: terreno, obstáculos, rugosidade local, a resolução (espacial e temporal), a pressão e temperatura. Às vezes, eles são apenas o primeiro passo para prever o vento, que é fornecido como entrada auxiliar de outros modelos estatísticos e de Inteligência Computacional, os quais têm uma boa precisão apenas nas primeiras horas previstas. Outros critérios importantes considerados no momento da seleção do modelo são: o horizonte de previsão, a precisão requerida assim como o tempo computacional e número de vezes em que é executado o método numérico. Os modelos NWP demandam um grande esforço computacional e, por este motivo, a sua utilização na previsão de curto prazo é bastante limitada. Os NWP são sensíveis às condições iniciais, visto que pequenos erros na previsão crescem rapidamente, e afetam a previsibilidade. Isso pode ser contornado usando diferentes combinações de modelos que possuam múltiplos modelos NWP, ou outros modelos físicos com condições iniciais diferenciadas.

O desenvolvimento dos modelos NWP é feito pelos meteorologistas para previsão do clima de áreas de grande escala. Os modelos não têm resultados muito precisos para a previsão no curto prazo. Para alcançar melhores resultados, o modelo NWP resolve equações de conservação da massa (ρ), energia e momento de forma numérica, no sítio dado. Ao mesmo tempo, para representar a topografia, os modelos digitais de elevação têm que ser utilizados no modelo NWP, de modo a atingir os resultados mais precisos (Negnevitsky et al., 2006).

3.4.

Modelos Estatísticos de Previsão de Energia Eólica

Tradicionalmente o modelo mais usado para previsão tem sido o modelo ARIMA de Box & Jenkins (1970), embora tivessem existido outras tentativas para prever a velocidade do vento anteriormente. O primeiro trabalho considerando as previsões de energia eólica veio de Brown et al. (1984); trabalho que ajusta um processo *auto-regressivo* (AR) nos dados transformados da velocidade do vento, para fazer a sua distribuição aproximadamente gaussiana e padronizada para remover a estacionariedade diurna. Apesar das séries temporais da velocidade do vento e da energia eólica apresentarem uma dinâmica altamente não-linear, os trabalhos de Blanchard & Desrochers (1984), Balouktsis et al. (1986), Daniel & Chen (1991), Tantareanu (1992), Huang & Chabali (1995), Kamal & Jafri (1997), Schwartz & Milligan (2002), Kennedy & Rogers (2003), Poggi et al. (2003), Torres et al. (2005), Philippoulos & Deligiorgi (2009) e Erdem & Shi (2011) têm optado por esta abordagem linear.

De forma similar, para previsão da velocidade do vento pode-se usar modelos AR ou ARMA para os quais os parâmetros são estimados através de Filtro de Kalman, como indicado nos artigos de Geerts (1984), Bossanyi (1985), Huang & Chabali (1995), Giebel (2001), Crochet (2004), Louka et al. (2008), Liu et al. (2012). Para o controle da variável velocidade de um aerogerador, Vihriälä et al. (1999) e Bourslis & Bleijs (2010), utilizam um filtro de Kalman. Usou-se também modelo de espaço de estado que inclui correlações espaciais que têm sido desenvolvidas e combinadas com ideias de redução de dimensão proposto por Wikle & Cressie (1999) para a previsão espacial dos ventos próximos à superfície sobre o oceano Pacífico. Malmberg et al. (2005) também utilizaram um modelo de espaço de estados para ser otimizado com um Filtro de Kalman, para prever a velocidade do vento futura sobre o Norte do oceano Atlântico.

Lojowska et al. (2010), Liu et al. (2011) e Jiang et al. (2012) empregaram o modelo ARMA-GARCH. Neste modelo, a variância condicional de uma observação depende da variância condicional das observações anteriores e os erros passados de previsão. De forma análoga, em Lau & McSharry (2010) usou-se uma transformação logística para normalizar os dados de energia eólica e assim construir um modelo ARIMA-GARCH para descrever a média condicional e a variância condicional.

Por outro lado, Kavasseri & Seetharaman (2009), utilizam o modelo ARFIMA para o qual consideraram horizontes de tempo significativamente maiores, para prever a velocidade do vento para 1 dia e 2 dias à frente. Os resultados obtidos indicam que há melhorias significativas nas previsões com o modelo proposto em comparação como o método de previsão Naive. Trabalhos prévios baseados neste tipo de modelo foram feitos

por Hussain et al. (2004). Uma abordagem que usa modelos ARFIMA e modelos FIGARCH é proposta por Caporin & Prés (2012), esta inovadora estratégia adapta o modelo ARFIMA-FIGARCH para os logaritmos das intensidades da velocidade do vento, adicionando componentes determinísticas periódicas para capturar o ciclo sazonal anual; com a finalidade de avaliar os riscos associados ao vento, já que segundo Caporin & Prés (2012) poucos autores tem considerado ainda o ponto de vista econômico e financeiro do vento.

Outra estratégia empregada por De Luna & Genton (2005) foi proporcionar previsões com modelos vetoriais auto-regressivos (VAR) com base em médias diárias de velocidade do vento de 11 estações meteorológicas na Irlanda. E mais recentemente, em Ewing et al. (2007) usou-se o modelo vetorial autorregressivo (VAR) para a técnica generalizada de impulso resposta. É importante destacar que o VAR é um tipo de modelo que permite combinar a velocidade e direção do vento, inclusive outras variáveis, considerando a correlação entre os atributos.

No trabalho desenvolvido em ELSAM (1993), modelos bilineares e alisamento de modelos limiares auto-regressivos são aplicados para a previsão de energia eólica em uma central de despacho. Dentro dos modelos limiares encontra-se os modelos: STAR (*Smooth transition autoregressive model*) e SETAR (*Self-exciting threshold autoregressive model*), para os quais apresenta-se as suas particularidades, além das características do modelo MSAR (*Markov-switching autoregressive model*) no estudo adiantado por Pinson et al. (2008) e Ailliot & Monbet (2012). Neste estudo, são avaliadas previsões um passo à frente para séries de produção média de energia eólica, com dados medidos a cada 1, 5 e 10 minutos, em dois parques eólicos *offshore* da Dinamarca. Enquanto que em Gneiting et al. (2006) foi proposto um modelo de mudança de regime chamado: "*Regime-switching space-time diurnal*" (RSTD), que leva em consideração tanto as correlações espaciais quanto as correlações temporais para previsão da velocidade do vento no centro Stateline de Energia Eólica, em Oregon, EUA. Por sua vez, Hering & Genton (2010) generalizaram o modelo RSTD através da inclusão da direção do vento diretamente dentro do modelo. Em Reikard (2010), estuda-se dos tipos de modelos: O primeiro com múltiplos fatores causais, pode ser estimado usando regressões ou técnicas não-paramétricas, como redes neurais. A segunda abordagem é a transição de estado, e a classe estreitamente relacionada de modelos de mudança de regime, aplicando ambas as metodologias em três bases de dados obtendo bons resultados para o modelo de mudança de regime em comparação com a regressão multivariada e a previsão Naive.

Entretanto, um modelo Markov-switching auto-regressivo foi proposto por Ailliot et al. (2006) para descrever a evolução espaço-temporal dos parques eólicos. Para isso, em primeiro lugar, introduziu-se um processo não observável, a fim de modelar o movimento

das estruturas meteorológicas. Em seguida, condicionado a este processo, é descrita a evolução dos campos de vento usando modelos auto-regressivos com coeficientes variando no tempo. O modelo proposto é calibrado e validado com dados do Norte do Atlântico. Similarmente, em Aillot & Monbet (2012) modelos Markov-Switching Auto-Regressivos não homogêneos (MSAR) são propostos para descrever séries temporais de vento. Neste trabalho, vários modelos auto-regressivos são usados para descrever a evolução no tempo da velocidade do vento e a mudança entre os diferentes modelos, o qual é controlado por uma cadeia de Markov oculta. Outros estudos que envolvem cadeias de Markov e modelos auto-regressivos discretos e bivariados tem sido usados para modelar e simular a velocidade e a direção do vento (Castino et al., 1998).

Recentemente, técnicas de Inteligência Computacional têm sido propostas. Elas incluem Redes Neurais Artificiais (RNA – ANN), Fuzzy Logic, ANFIS, máquina de vetor de suporte entre outras. No caso das Redes Neurais Artificiais, estas utilizam dados de medições on-line como entrada. Esta ferramenta da Inteligência Computacional tem sido amplamente usada e tem sido empregados modelos como o Perceptron Multicamada (MLP) para desenvolver trabalhos de previsão de curto prazo para previsão de energia eólica e a previsão da velocidade do vento (Beyer et al., 1994; Lin et al., 1996; Kariniotakis et al., 1996a; Mohandes et al., 1998; Alexiadis et al., 1998, 1999; Methaprayoon et al., 2007). O MLP é a principal técnica usada por Ramirez-Rosado et al. (2009), por trás de outros métodos de previsão tais como os modelos ARMA e vários tipos de RNAs. Neste trabalho, dois dos principais sistemas de previsão são apresentados com base não só em dados históricos reais, mas também em previsões meteorológicas usando *Numerical Weather Prediction* (NWP), obtendo um erro médio RMS de aproximadamente 14% no horizonte de 12-24 h.

Do mesmo modo, em Kretzschmar et al. (2004) usou-se classificações de redes neurais para as previsões de ventos fortes e rajadas de vento em Genebra e Sion, Suíça. Também em Cadenas & Rivera (2009), compara-se diferentes configurações de redes neurais e acha-se que a mais simples das configurações (duas camadas, dois neurônios de entrada, um neurônio de saída) superou as configurações mais complexas, para as previsões de dados de vento horários em La Venta, México. No trabalho desenvolvido por More & Deo (2003), os modelos ARIMA são superados utilizando redes neurais para previsões da velocidades do vento 1 passo à frente para dados de médias diárias, semanais e mensais. De formar similar, Redes de Funções de Base Radial (Beyer et al., 1994; Silva et al., 2006; Sideratos & Hatzigiorgiou, 2012) e Redes Recorrentes (Kariniotakis et al., 1996a, 1996b; Barbounis et al., 2006) são aplicadas para previsão da velocidade do vento e na previsão da geração de energia eólica. Para auxiliar na previsão

da geração de energia eólica e obter melhores resultados, em Catalão et al. (2011) adotou-se transformadas wavelet em modelos de redes neurais.

Os modelos de Lógica Fuzzy são outra técnica de Inteligência Computacional que são aplicados para a previsão da geração de energia eólica ou da variável velocidade do vento (Kariniotakis et al., 1996b). No trabalho de Damousis & Dokopoulos (2001) e Damousis et al. (2004) a melhoria das previsões variou de 9% a 28%, dependendo do horizonte de previsão, em comparação com as previsões Naive; considerando-se em ambos estudos que a energia eólica é uma função da velocidade do vento. É importante destacar que em Damousis et al. (2004) utiliza-se um modelo fuzzy com duas variáveis: velocidade e direção do vento. Uma combinação de classificadores de Fuzzy Logic com Redes Neurais é apresentada em Wu et al. (1995). Em Kariniotakis et al. (1997, 1999), foram testados vários métodos de previsão na ilha de Creta na Grécia. Estes incluíram modelos lineares adaptativos, modelos de lógica fuzzy adaptativos e modelos baseados em wavelet. Os modelos baseados em lógica fuzzy adaptativos foram instalados para a operação on-line no marco do projeto Joule II CARE (JOR3-CT96-0119).

Outro algoritmo de redes neurais chamado de máquina de vetor de suporte (SVM em inglês) é usado em Mohandes et al. (2004) para prever a velocidade do vento e compará-la com uma rede MLP. Larson & Westrick (2006) usaram um classificador SVM para estimar o erro de previsão, obtendo um erro quadrático médio e um erro médio percentual absoluto menor do que o tradicional SVM. Do mesmo modo, resultados de diversas pesquisas indicam que SVM comparado com o modelo MLP tem um desempenho favorável baseado na raiz dos erros quadrados. Trabalhos adicionais em máquina de vetor de suporte têm sido desenvolvidos recentemente (Ji et al., 2007; Ortiz-García et al., 2011; Sangita & Deshmukh, 2011; Zhou et al., 2011; Mathaba et al., 2012; Xiaojuan et al., 2012; Liu et al., 2014).

Estudos comparativos entre modelos ARMA e RNA (Redes Neurais Artificiais) para previsão da velocidade do vento e da geração eólica foram feitos por Sfetsos (2000, 2002) e Cadenas & Rivera (2007). Além destes modelos, em Potter & Negnevitsky (2006), Johnsons et al. (2007) e em De Giorgi et al. (2011) para a geração de energia eólica, compara-se um modelo de Redes Neuro-Fuzzy (ANFIS - Adaptive Neuro-Fuzzy Inference System). Em Cadenas & Rivera (2010), apresenta-se um modelo ARIMA com um modelo híbrido ARIMA-ANN para a previsão da velocidade do vento em três diferentes regiões para dados horários. No caso de Sideratos & Hatziargyriou (2007) utiliza-se métodos estatístico avançados de previsão de energia eólica com base em técnicas de inteligência artificial, isto é, são usadas as últimas entradas de medições de potência e previsões meteorológicas de velocidade e direção do vento de um modelo NWP, interpolando todo no local do parque eólico, além das metodologias de conjuntos

fuzzy, redes de função de base radial, mapas auto-organizados com a finalidade de prever a geração de energia eólica.

Em resumo, este capítulo apresentou-se uma breve revisão bibliográfica dos modelos de previsão de energia eólica direta (potência gerada) e indireta (previsões da velocidade do vento para serem posteriormente transformadas usando a curva de potência). Um amplo número de modelos que exploram diversas técnicas para a previsão da velocidade do vento foram discutidos, e neles se evidenciam resultados razoavelmente bons para previsões no curto prazo. No entanto, mostrou claramente a limitada literatura técnica existente para propostas que vinculem as previsões probabilísticas da geração eólica com a velocidade do vento.

Por conseguinte, nos próximos dois capítulos serão apresentados os arcabouços teóricos para a previsão da velocidade do vento usando a técnica não para métrica de SSA (Capítulo 4) e, posteriormente, a conceptualização do estimador *kernel* para a previsão da densidade de condicional da geração eólica (Capítulo 5); cimentando estes dois capítulos as bases da estratégia de especificação metodológica proposta.