

Um método para discriminação entre PSK e FSK utilizando estatísticas de ordem superior

Gustavo Kasper Facenda e Danilo Silva

Resumo—Este artigo apresenta um novo algoritmo para discriminação entre modulações digitais em fase e em frequência. Dado um sinal modulado em PSK (*Phase-Shift Keying*) ou FSK (*Frequency-Shift Keying*), com quaisquer números de níveis, o algoritmo é capaz de identificar a qual classe (PSK ou FSK) o sinal pertence. O método proposto consiste no uso de estatísticas de ordem superior da frequência instantânea do sinal recebido em banda base como atributos utilizados por um classificador SVM, apresentando um bom compromisso entre complexidade, conhecimento *a priori* e desempenho em comparação com os métodos existentes.

Palavras-Chave—Identificação de modulação digital, estatísticas de ordem superior, PSK, FSK, *support vector machine*.

Abstract—This paper presents a new method to discriminate between phase and frequency digital modulations. The algorithm is able to identify the class of an M -PSK or M -FSK modulated signal, for any modulation order M . The proposed method is based on machine learning, using higher-order statistics of the instantaneous frequency of the baseband received signal as features, presenting a good tradeoff between complexity, *a priori* knowledge and performance, compared to the existing methods.

Keywords—Digital modulation identification, higher-order statistics, PSK, FSK, *support vector machine*.

I. INTRODUÇÃO

A identificação de modulações é um tema importante no monitoramento espectral e em rádio cognitivo. Historicamente, esta identificação era feita através de interpretação humana [1]. Em rádio cognitivo, a identificação de modulações digitais remove a necessidade de envio do tipo de modulação no cabeçalho do bloco de dados. Com o crescente uso de diferentes tipos de modulações digitais, uma identificação completamente automática se tornou necessária, motivando o desenvolvimento de métodos eficientes para este fim.

Existem métodos que buscam modelar o sinal recebido e desenvolver cálculos de máxima verossimilhança. No entanto, quanto mais imperfeições são consideradas e menos informações são conhecidas, mais os modelos se tornam complexos. Com isso, algoritmos que buscam utilizar atributos (*features*) do sinal recebido foram desenvolvidos.

Um dos métodos propostos utilizando atributos do sinal se baseia em algoritmos genéticos e redes neurais [1–5]. Estes algoritmos apresentam bons resultados mesmo quando se tem pouco ou nenhum conhecimento *a priori* do sinal, a custo

Gustavo Kasper Facenda e Danilo Silva, Departamento de Engenharia Elétrica e Eletrônica, Universidade Federal de Santa Catarina, Florianópolis-SC, Brasil, E-mails: kasper@linse.ufsc.br, danilo@eel.ufsc.br. O trabalho foi realizado em parceria com o LINSE.

de uma complexidade elevada. Outra alternativa apresentada é a classificação hierárquica das modulações, que oferece uma complexidade inferior, favorecendo-os para implementações em tempo real. Nestes trabalhos, alguns algoritmos utilizados para a discriminação de PSK (*Phase Shift Keying*) e FSK (*Frequency Shift Keying*) são sequência de *zero-crossing* [6], o desvio padrão da frequência instantânea [7], [8] ou a curtose da amplitude [9]. Em [10], a curtose da frequência instantânea é utilizada para separação de níveis de FSK.

No presente trabalho, propõe-se a utilização de um classificador SVM (*Support Vector Machine*) [11] com três atributos em um dos módulos da classificação hierárquica. A utilização deste classificador apresenta uma complexidade computacional superior à regra de decisão tradicional utilizando apenas um atributo. No entanto, ainda utilizam-se poucos atributos e todos são relevantes para a separação, sendo possível obter resultados mais robustos, a um custo de pouca complexidade computacional adicional.

Os atributos utilizados são estatísticas de ordem superior da frequência instantânea. Tendo em vista que a frequência instantânea de um sinal FSK idealmente não assume valores nulos, enquanto para uma modulação PSK há uma concentração da frequência instantânea em torno de zero, suas respectivas distribuições de probabilidade adquirem características significativamente diferentes, as quais podem ser quantificadas através de estatísticas de ordem superior.

II. DEFINIÇÃO DO PROBLEMA

Seja $s(t)$ a representação complexa em banda base de um sinal modulado em banda passante, tal que $S(f) \in [-\frac{B}{2}, \frac{B}{2}]$, em que B é a largura de banda do sinal original em banda passante. O sistema recebe como entrada o sinal

$$r[n] = (s[n] + z[n]) e^{j(2\pi n f_{\Delta,d} + \Delta\phi)}, \quad (1)$$

em que $s[n] = s(n/f_s)$, f_s é a taxa de amostragem, $z[n]$ são amostras de ruído branco gaussiano filtrado em $f_s/2$, e $f_{\Delta,d}$ e $\Delta\phi$ são, respectivamente, o desvio de frequência (em tempo discreto) (*carrier frequency offset*, CFO) e o desvio de fase (*constant phase offset*, CPO) entre as portadoras do transmissor e do receptor. Note que o desvio de frequência de tempo contínuo é dado por $f_{\Delta,c} = f_{\Delta,d} \cdot f_s$. A razão sinal-ruído é definida como $\text{SNR} = \frac{P_s}{P_z}$, onde $P_s = \mathbf{E}[|s[n]|^2]$, $P_z = \mathbf{E}[|z[n]|^2]$ e $\mathbf{E}[X]$ denota o valor esperado da variável aleatória X .

Seja $\theta_r[n] = \angle r[n]$ a fase instantânea do sinal $r[n]$. Neste artigo, define-se a frequência instantânea (de tempo discreto)

como

$$f_r[n] = \left(\frac{1}{2\pi} (\theta_r[n] - \theta_r[n-1]) \right) \bmod 1 \quad (2)$$

onde a redução modular é definida tal que $x \bmod 1 \in [-\frac{1}{2}, \frac{1}{2}]$. Note que a frequência instantânea de tempo contínuo pode ser aproximada por $f_{\text{cont}}(t) \approx f[n] \cdot f_s$.

Seja $N_s = f_s/R_s$ o número de amostras por símbolo, em que R_s é a taxa de símbolos. No presente trabalho, as modulações consideradas são PSK e FSK. Para uma modulação M -PSK, tem-se [12]

$$s[n] = \sum_{k=-\infty}^{\infty} g[n - kN_s] e^{jm[k]}, \quad (3)$$

em que $g[n]$ é o pulso de formatação amostrado, $m[k] \in \{\phi_i, i = 0, 1, 2, \dots, M-1\}$ e ϕ_i são as possíveis fases da modulação. Para uma modulação M -FSK,

$$s[n] = \sum_{k=-\infty}^{\infty} g[n - kN_s] e^{j2\pi m[k]n}, \quad (4)$$

em que $g[n]$ é um pulso retangular amostrado, $m[k] \in \{f_i, i = 0, 1, 2, \dots, M-1\}$ e f_i são as possíveis frequências da modulação (em banda base), correspondendo às frequências de tempo contínuo $f_{i,\text{cont}} = f_i f_s$. Define-se $\beta = (f_1 - f_0)/R_s$.

A partir de N amostras do sinal $r[n]$, deseja-se decidir se a modulação utilizada é FSK ou PSK, sem necessariamente estimar o número de níveis. Assume-se que a única informação sobre o sinal $s(t)$ conhecida *a priori* é a sua largura de banda B . Assume-se, também, que $|f_{\Delta,c}| \leq B/2$. Em especial, assume-se $f_{\Delta,c}$, SNR e R_s desconhecidos.

III. MÉTODO PROPOSTO

Esta seção descreve o método proposto de obtenção de atributos de classificação.

A. Estimação da SNR

De posse de $r[n]$ e B , inicialmente deseja-se estimar a SNR do sinal recebido. Para isto, considerando o modelo de um ruído branco filtrado, portanto aproximadamente constante no espectro, a potência do ruído pode ser estimada através do teorema de Parseval como

$$\hat{P}_z = K \left(\int_{B/2+f_{\Delta,c}}^{f_s/2} |R(f)|^2 df + \int_{-f_s/2}^{-B/2+f_{\Delta,c}} |R(f)|^2 df \right) \quad (5)$$

onde $K = \frac{f_s}{f_s - B - 2f_{\Delta,c}}$ e $R(f)$ é a DTFT de $r[n]$ avaliada em $\omega = 2\pi f/f_s$. No entanto, $f_{\Delta,c}$ é desconhecido, então, tomando o pior caso considerado em que $|f_{\Delta,c}| = B/2$, obtém-se

$$\hat{P}_z = \frac{f_s}{f_s - 2B} \left(\int_B^{f_s/2} |R(f)|^2 df + \int_{-f_s/2}^{-B} |R(f)|^2 df \right). \quad (6)$$

Deve-se observar que para que esta estimação seja possível é necessário que $f_s > 2B$, o que já é necessário para que não haja perda de informação do sinal na situação $f_{\Delta,c} = B/2$. Nota-se uma relação de compromisso entre a banda disponível




Fig. 1. Histograma não normalizado da frequência instantânea $f_r[n]$ (antes do filtro) a uma SNR=0 dB.

de ruído e a qualidade da estimação da potência do ruído, visto que caso o ruído esteja limitado próximo a $2B$ haverá pouca informação sobre o ruído. Em sequência, estima-se a potência total do sinal $r[n]$, dada por

$$P_r = \int_{-f_s/2}^{f_s/2} |R(f)|^2 df \approx \frac{1}{N} \sum_1^N |r[n]|^2. \quad (7)$$

Após a estimação destas potências, o sinal recebido é filtrado em $[-B, B]$, de maneira a filtrar o ruído fora da banda do sinal e considerando o máximo desvio de frequência. Isto altera a SNR, visto que a nova potência do ruído é multiplicada por $\frac{2B}{f_s}$. Com isso, é possível obter uma estimativa da SNR através de

$$\hat{\text{SNR}} = (P_r - \hat{P}_z) / \left(\frac{2B}{f_s} \hat{P}_z \right). \quad (8)$$

B. Estimação da frequência instantânea e suas estatísticas

Inicialmente, extrai-se a frequência instantânea $f_r[n]$ através de (2). Em seguida, a sequência $f_r[n]$ é filtrada na banda $[-B/2, B/2]$, gerando $f[n]$. É interessante notar que, para sinais FSK, a banda do sinal $f[n]$ é estritamente menor do que $B/2$. Já para sinais PSK, os impulsos responsáveis pela troca instantânea de fase geram componentes de alta frequência no sinal $f[n]$, porém observamos que esta informação é desprezível do ponto de vista de discriminação entre as modulações PSK e FSK. Outro ponto a se notar é que, após o cálculo da frequência instantânea, parte da potência do ruído se concentra em frequências fora da banda do sinal de interesse, então o filtro reduz o efeito do ruído na estimação da frequência instantânea.

A Fig. 1 apresenta o histograma não normalizado para f_r , com SNR igual a 0 dB. Observa-se que as curvas não são facilmente distinguíveis, com a modulação 2-FSK sendo apenas um pouco mais espalhada que a QPSK. No entanto, na Fig. 2, que apresenta as mesmas curvas após o efeito do filtro, observa-se que os histogramas são distinguíveis com mais facilidade, podendo, inclusive, ser observado o número de níveis da modulação 2-FSK através do número de picos.




Fig. 2. Histograma não normalizado da frequência instantânea $f[n]$ (após o filtro) a uma SNR=0 dB.

Observa-se que uma característica ressaltada é que, para sinais PSK, a frequência instantânea é concentrada em torno da média, enquanto para sinais FSK a frequência instantânea se concentra em torno das frequências de modulação somadas à média. Em especial, é possível demonstrar que, na ausência de ruído ou limitação de banda, a função massa de probabilidade da frequência instantânea para a modulação FSK é dada por

$$P(x) = \begin{cases} \frac{1}{M}, & x = (f_{\Delta,d} + f_i \text{ mod } 1) \\ 0, & x \neq (f_{\Delta,d} + f_i \text{ mod } 1) \end{cases} \quad (9)$$

Também é possível demonstrar que, para uma modulação PSK, a função massa de probabilidade é dada por:

$$P(x) = \begin{cases} \frac{N_s-1}{N_s} + \frac{1}{MN_s}, & x = (f_{\Delta,d} \text{ mod } 1) \\ \frac{1}{MN_s}, & x = (f_{\Delta,d} + d\phi_i \text{ mod } 1), i \neq 0 \\ 0, & x \neq (f_{\Delta,d} + d\phi_i \text{ mod } 1) \end{cases} \quad (10)$$

em que $d\phi_i = \frac{\phi_0 - \phi_i}{2\pi}$.

Em presença de ruído ou limitação de banda, devido à interferência intersimbólica e à não linearidade envolvida no cálculo da fase, o cálculo teórico da distribuição se torna muito complexo e as distribuições foram determinadas experimentalmente. Apesar disso, pode-se observar, na Fig. 2, que a presença de ruído e limitação de banda não alterou as características citadas.

Ambas as modulações apresentam uma densidade de probabilidade de $f[n]$ simétrica em torno da média, portanto, momentos de ordens ímpares são nulos nos dois casos. A variância, por si só, não é capaz de distinguir as modulações para todas as situações, visto que a variação da frequência de separação altera os valores dos momentos centrais. Devido a isto, a utilização da curtose é interessante, visto que esta estatística é robusta a escalonamentos e translações da variável aleatória e depende apenas da forma desta. Além disso, observou-se experimentalmente que, em baixas SNRs, o quarto momento apresenta uma distinção maior do que a curtose ou a variância para os diferentes tipos de modulação.

Com isso, após a filtragem, estima-se o quarto momento central da variável aleatória $f[n]$, bem como sua curtose. A

estimação destas estatísticas, no entanto, é realizada utilizando apenas amostras com valor absoluto menor que 3 desvios-padrão de $f[n]$. Isto é feito de maneira a reduzir o impacto de *outliers*, visto que estas estatísticas, por serem de ordem elevada, são sensíveis a valores muito maiores do que o esperado. Desta forma, a fim de estimar estas estatísticas, estima-se inicialmente o desvio padrão

$$\hat{\sigma} = \sqrt{\frac{1}{N-2} \sum_{i=2}^N (f[i] - \bar{f})^2} \quad (11)$$

onde \bar{f} é a média estimada de $f[n]$ e aproximadamente igual a $f_{\Delta,c}/f_s$. Em sequência, estima-se o quarto momento central

$$\mu_4^f = \frac{1}{N'} \sum_{i=2}^N (f[i] - \bar{f})^4 \quad (12)$$

calculado apenas para i tal que $|f[i] - \bar{f}| \leq 3\hat{\sigma}$, onde N' é o número total de amostras de $f[n]$ que atendem a esta condição. Em sequência, a variância é calculada utilizando o mesmo procedimento

$$\mu_2^f = \frac{1}{N'} \sum_{i=2}^N (f[i] - \bar{f})^2 \quad (13)$$

e utilizada na estimação da curtose

$$\kappa = \mu_4^f / (\mu_2^f)^2. \quad (14)$$

A SNR estimada e as estatísticas κ e μ_4^f são utilizadas como parâmetros de entrada em um classificador SVM a fim de realizar a decisão entre PSK e FSK. O treinamento do classificador é descrito a seguir.

IV. TREINAMENTO

Neste trabalho utiliza-se uma base de dados gerada em simulação, dado que os modelos das modulações e do canal são conhecidos, desejando-se utilizar o treinamento apenas para determinar a regra de decisão. Isto é vantajoso pois a aquisição de dados reais é custosa e toma mais tempo que a geração através de simulações.

Devido ao pequeno número de parâmetros de entrada utilizados no classificador e às regiões de decisão não serem lineares optou-se pela utilização de um núcleo RBF (*radial basis function*) [11]. Este núcleo tem um parâmetro γ , que define a região de influência das amostras no espaço de maior dimensão. Além disso, o treinamento tem um parâmetro de custo C , que define o peso do erro na etapa de treinamento, ou seja, um C maior significa que o classificador tenderá a um erro menor no treinamento, aumentando a chance de *overfitting*. Os parâmetros C e γ foram obtidos através de *grid-search*. Este método consiste em varrer uma faixa de valores para C e γ , treinando e testando para cada par de parâmetros. O modelo final é treinado utilizando C e γ que obtiveram o melhor resultado na etapa de teste.

O modelo depende do valor de N e da razão B/f_s , e a alteração destes valores implica na necessidade de treinar um novo modelo. Como supõe-se B conhecido e tanto f_s quanto N são definidos pelo sistema, esta restrição não afeta o




Fig. 3. Quarto momento central e curtose da frequência instantânea para SNR = 10 dB.

desempenho do sistema. No entanto, o método não é flexível para alteração destes parâmetros em tempo real, exceto em casos para os quais um modelo já foi treinado.

A fim de obter um modelo abrangente, os dados de treinamento utilizam sinais PSK utilizando pulso retangular e $R_s = B/2$, pulso raiz de cosseno levantado com $R_s = B/2$ e roll-off unitário e pulso sinc com $R_s = B$, bem como sinais FSK com diferentes relações de $\Delta f/R_s$ múltiplas de 0.5. A relação $\Delta f/R_s$ deve ser múltipla de 0.5 a fim de manter a ortogonalidade das frequências. O valor de SNR vai de 0 dB a 20 dB, visto que para valores acima deste limite as estatísticas variam pouco e abaixo deste limite a separação entre as classes se torna excessivamente complexa.

A Fig. 3 apresenta as estatísticas consideradas para uma SNR de 10 dB para as modulações consideradas, indicando o tipo de pulso, fator de roll-off α e razão β . Observa-se que, em altas SNRs, a região de decisão permanece simples ao se considerar diferentes pulsos e parâmetros.

Observou-se que o modelo treinado nesta faixa de SNRs não é capaz de prever corretamente o comportamento dos atributos para SNRs extremamente elevadas, mas, como já citado, os atributos variam pouco acima de 20 dB. Desta forma, na prática, SNRs estimadas superiores a 20 dB são truncadas.

V. SIMULAÇÕES E RESULTADOS

A fim de validar o algoritmo, foram realizados testes de simulação para o estimador de SNR e para o classificador. Além disso, o classificador foi validado experimentalmente utilizando plataformas de rádio definido por *software*.

Todos os testes foram realizados utilizando os parâmetros $B/f_s = 1/8$ e $N = 100 \cdot 10^3$.

A. Resultados do estimador de SNR

Para realizar os testes com o estimador de SNR, utilizaram-se modulações PSK com pulso RRC e $\alpha = 1$ e modulações




Fig. 4. Taxa de erro aproximada em função da SNR.

FSK com $\beta = 2$. Observou-se que o resultado independia da modulação, então este é apresentado apenas para sinais BPSK. O estimador apresentou resultados adequados na faixa de SNR considerada, de 0 dB a 20 dB. O erro aumenta conforme a SNR diminui, com o pior caso em 0 dB apresentando 98% dos valores da SNR estimada entre -0.6 e 0.3. Para todas as SNRs, o valor esperado da SNR estimada é inferior ao valor real da SNR. Além disso, as distribuições da SNR estimada são assimétricas, havendo uma probabilidade maior de valores abaixo da média do que acima da média.

Ao se avaliar os resultados em função de $f_{\Delta,c}$, observou-se que o desempenho se manteve constante enquanto $\frac{f_{\Delta,c}}{B} \leq 0.5$ e decaiu rapidamente a partir de $\frac{f_{\Delta,c}}{B} = 0.7$.

B. Resultados em função da SNR

Neste teste, para cada SNR foram geradas $450 \cdot 10^3$ classificações por modulação. A Fig. 4 apresenta a taxa de erro média para as modulações PSK e FSK em função da SNR. Os resultados são apresentados de acordo com a classe (PSK ou FSK) a fim de simplificar a figura. Observa-se que é possível obter resultados adequados mesmo em baixas SNRs e sem necessidade de estimação de R_s . Acima de 4 dB, não foram observados erros para este número de realizações.

É interessante notar, no entanto, que a estimação ou o conhecimento *a priori* da taxa de símbolos R_s melhoraria o desempenho do sistema em baixas SNRs. Por exemplo, para uma SNR de 0 dB, há sobreposição de regiões para modulações com taxas de símbolos distintas, como apresentado na Fig. 5. Note que há duas situações em que há modulações próximas. A primeira é com sinais 4-FSK e 8-FSK com $\beta = 2$ próximos de sinais QPSK e 8-PSK com $\alpha = 0$, quando a taxa de símbolos dos FSK é cinco vezes menor que a taxa de símbolos dos PSKs. A segunda situação é a modulação 2-FSK com $\beta = 1$ e QPSK com $\alpha = 1$, em que a taxa de símbolos do QPSK é 1.5 vezes maior que a do 2-FSK.




Fig. 5. Quarto momento e curtose da frequência instantânea para SNR = 0 dB.

Além disso, o problema é heterogêneo, visto que em baixas SNRs a região de decisão é mais complexa do que para altas SNRs, como pode ser observado comparando a Fig. 3 com a Fig. 5. Desta forma, o mesmo par de parâmetros C e γ que gera uma região adequada para baixas SNRs causa *overfitting* em altas SNRs. Do contrário, um par de parâmetros que gere uma região adequada para altas SNRs resulta numa região com *underfitting* em SNRs mais baixas. Uma solução possível é o treinamento de um modelo diferente para diferentes faixas de SNR, no entanto, esta solução implica em uma maior complexidade do sistema e foi evitada neste trabalho.

C. Robustez do sistema a $f_{\Delta,c}$

Dado que as estatísticas utilizadas são em relação a média e o desvio de frequência de portadora é uma adição de média à distribuição da frequência instantânea, espera-se que este desvio não afete o resultado enquanto seu valor estiver dentro do limite considerado. Para verificar esta hipótese, foram realizados testes com o desvio de frequência igual a $B/4$ e igual a $B/2$. Para ambos os casos, foram realizadas $450 \cdot 10^3$ classificações para cada classe. Para $B/4$, o desempenho se manteve igual à situação sem desvio de frequência, confirmando a robustez do método. Por outro lado, para $B/2$, o desempenho para sinais FSK deteriorou-se consideravelmente, com apenas 50% de taxa de acerto. Embora para sinais PSK a taxa de acerto tenha sido de 100%. Analisando o comportamento dos sinais nesta situação, observou-se que parte considerável da informação dos sinais FSK está presente próxima à frequência de corte do filtro, distorcendo o sinal e causando a taxa de erro elevada.

D. Resultados práticos

Para testes práticos, utilizou-se uma USRP como transmissor e um RTL-SDR como receptor. A fim de validar de forma

não exaustiva, utilizou-se um QPSK com $\alpha = 0$ e um 2-FSK com $\beta = 1$, sinais que em baixas SNRs estão mais próximos da fronteira de decisão, próximos ao 8-FSK $\beta = 2$ e QPSK com $\alpha = 1$, respectivamente. Foram transmitidos um total de 400 quadros de $100 \cdot 10^3$ amostras. Durante a transmissão, o ganho do transmissor foi alterado a cada 100 quadros transmitidos. As SNRs estimadas variaram de 0 dB a 20 dB, com concentração em torno de 10 dB. Foi observada interferência na recepção, devido a imperfeições do sistema, além de variação do canal no tempo. Ainda assim, para a modulação 2-FSK, a taxa de acerto foi de 99.25%, enquanto para a QPSK a taxa de acerto foi de 99.5%.

VI. CONCLUSÕES

Este trabalho apresentou um método de classificação que separa modulações PSK de modulações FSK, utilizando a diferença entre as distribuições de frequência instantânea destas modulações, quantificando esta diferença através de estatísticas de ordem superior. Mesmo treinando um modelo genérico, sem estimar parâmetros da modulação, e usando uma base de dados gerada em simulação para o treinamento, o classificador ainda obteve resultados adequados em situações reais.

Trabalhos futuros podem explorar a utilização destes parâmetros junto à estimação da taxa de símbolos e a classificação utilizando um chaveamento entre modelos dependendo da SNR.

AGRADECIMENTOS

Os autores agradecem a Gabriel Rosa e Eduardo H. Arnold pelo auxílio na implementação de algoritmos de aprendizado de máquina.

REFERÊNCIAS

- [1] M. Wong and A. Nandi, "Automatic digital modulation recognition using artificial neural network and genetic algorithm," *Signal Processing*, vol. 84, no. 2, pp. 351–365, 2003.
- [2] A. Kubankova and D. Kubanek, "Digital modulation recognition based on feature, spectrum and phase analysis and its testing with disturbed signals," in *34th International Conference on TSP*, 2011, pp. 448–451.
- [3] A. K. Nandi and E. E. Azzouz, "Algorithms for automatic modulation recognition of communication signals," *IEEE Trans. Commun.*, vol. 46, no. 4, pp. 431–436, 1998.
- [4] K. Farrell and R. Mammone, "Modulation classification using a neural tree network," in *Proc. MILCOM*, vol. 3, 1993, pp. 1028–1032.
- [5] C.-S. Park and J.-H. Choi, "Automatic modulation recognition of digital signals using wavelet features and SVM," in *10th ICACT*, vol. 1, 2008, pp. 387–390.
- [6] D. Grimald, S. Rapuano, and L. D. Vito, "An automatic digital modulation classifier for measurement on telecommunication networks," *IEEE Trans. Instrum. Meas.*, vol. 56, no. 5, pp. 1711–1720, 2007.
- [7] M. V. Subbarao, N. S. Khasim, T. Jagadeesh, and M. H. H. Sastry, "A novel technique for automatic modulation classification and time-frequency analysis of digitally modulated signals," *IJSIP*, vol. 6, no. 2, pp. 1–14, 2013.
- [8] S. M. Baarrij, F. Nasir, and S. Masood, "A robust hierarchical digital modulation classification technique: using linear approximations," *ISSPIT*, 2006.
- [9] P. K. H.L and L. Shrinivasan, "Automatic digital modulation recognition using minimum feature extraction," in *2nd INDIACOM*, 2015, pp. 772–775.
- [10] A.-V. Rosti, "Statistical methods in modulation classification," Master's thesis, Tampere University of Technology, 12 1998.
- [11] C. M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006.
- [12] J. Proakis, *Digital Communications 5th Edition*. McGraw Hill, 2007.