

特徴点分布を基盤とした、Deep Learning を提唱してきましたが、ニューロコンピュータとはちょっと異なったものになっているのは、特徴点が記号オントロジーだけでなく、状態(値)を持つからなのです。単なるノードとして記述できないのです。たとえば、特徴点はその種類と相対的な位置関係、相対的な大きさ関係が重要な情報です。これらは、マップでしか表現できません。記号化しようとする、自然言語処理のように、near とか、far とか attach とかの記号表現になってしまいます。それは、ひるがえって言えば、どんな精度の Deep Learning システムを作るかという問題になります。もっとも粗いものは位置関係を自然言語のレベルに持つものでしょう。その上には、値の範囲というものを導入するものがあり得ます。たとえば、(2線のなす角度名；base 線名；reference 線名；値の単位名；開始角度値；終了角度値)をノードとして与える。

学習では、値の範囲を変化させることと、ノードの生成、削除を行うことと、その重み(投票の強さ)を変化させることです。ここで問題となるのは、線の名前が、学習を行う各時点で、どう一致させるかです。学習には雑音があります。1回目に無かった線が、2回目に現れることもあるでしょう。この困難を解決するには、画像認識では輪郭が重要ということです。輪郭を決定してから、内部の画素の名前を推定していく。もっとも、輪郭を構成する画素も曖昧性があります。そういうことも含めて、Deep Learning では隠れ層の重み付投票値を学習していくことになります。まず、画素の名前を推定して、その後に、全体で認識対象は何かということ棄別することになります。画素ノードの名前の推定には2項関係ノードの情報が重要になってきます。2項でなく、3項関係も考慮できるようになれば更に精度が高くなるでしょう。しかし、ノードは多くなり、処理スピードは落ちてきます。

ということで、Deep Learning を構成するニューロンネットワークも学習によって、変化していくべきでしょう。高速化のために、判断に弱い関与し olmayan ノードは捨てていく、重要なノードは生成していく・・・というようなことですね。それに、ニューロンネットワークをクローンして、そのクローンを起点にして、実際の学習に適応させていくという手法も有効と思います。