

## 變電機器의 豫測保全

(6)

### 뉴럴네트워크에 의한 GIS의 異常診斷에의 적용

#### 1. 머리말

근년에 技術이나 社會 시스템의 電力依存度가 점점 많아지면서 電力 시스템의 안정된 制御와 그것을 구성하는 각 機器의 신뢰성이 대단히 중요하게 되었다. 예를 들면 GIS(Gas Insulated Switchgear : 가스絕緣開閉裝置)에서는 사고가 발생한 후에 대책을 강구하는 것이 아니라 사고가 일어날 것 같은 정후를 찾아내서 사고를 예측, 방지하고자 하는 豫測保全에 대한 사고방식이 機器의 신뢰성을 높이고 또 維持補修를 용이하게 하기 위하여 중요시되고 있다.

豫測保全은 하기 위해서는 精度 높고 信賴性이 좋은 센서를 機器의 개소에 적절하게 설치하여 그 센서의 出力を 잘 활용하도록 情報處理를 할 필요가 있다. 그러나 종래 흔히 사용되어 오던 방법은 기본적으로는 레벨判定法으로서 센서의 出力이 어느 영역값보다 크면 機器에 어떤 異常이 발생한 것으로 보고 센서出力이 작으면 정상적으로 동작하고 있다고 보았다. 이와 같은 방법으로는 異常發生이 없는데도 센서出力에 포함되는 雜音 때문에 正常을 異常으로 판정하는 誤判을 방지하기 곤란하며 또 어떠한 사고가 어디에 어떤 원인으로 발생하였는가 하는 미세한 判定은 대단히

어렵다.

그러므로 生體의 神經系를 모방한 뉴럴네트워크가 주목의 대상이 되어 종래의 情報處理手法을 넘는 무언가가 될 수 있지 않을까 기대되고 있다. 뉴럴네트워크에서는 對象에 대한 지식이 없더라도 學習데이터만 충분하면 뉴론간의 結合 중첩을 學習알고리즘으로 변경함으로써 對象이 되는 모델을 自己組織화할 수가 있다. 또 動作原理가 본질적으로 아날로그이므로 未知의 데이터가 들어오더라도 補間에 의하여 어떤 적절한 답을 얻을 수 있는 등의 특징이 있다.

그러므로 이 논문에서는 GIS의 豫測保全 시스템에서 특히 이상원인의 분류 확정에 뉴럴네트워크를 적용하는 기초적인 시도를 해보았다. 우선 단 하나의 뉴럴네트워크를 사용하여 센서出力의 스펙트럼을 入力하고 異常原因을 出力하는 간단한 적용을 하고 다음에 뉴럴네트워크를 모듈화하여 각 모듈이 단계적으로 異常原因을 分類確定하는데 적용하여 본다.

#### 2. GIS의 豫測保全

豫測保全의 기본적인 생각은 사고가 발생하여 機器에 중대한 손해를 입힌 후에 대처하기 보다

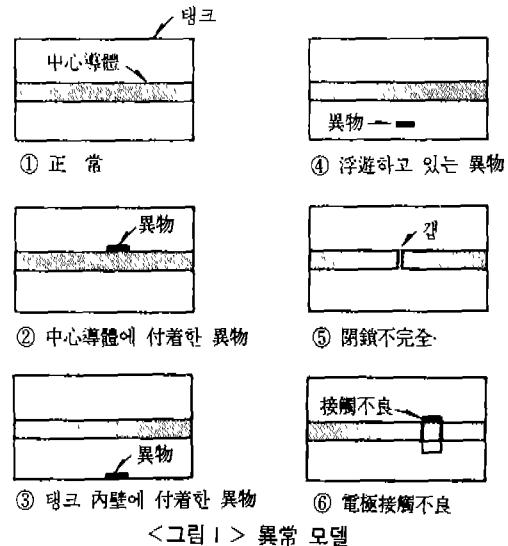
는 事故의 정후를 찾아내어 미리 적절한 처리를 하는 것이 전체적으로 보아 경제적이고 또한 신뢰성도 높다고 하는 것이다. 機器가 어떤 원인으로든 異常이 발생하였다면 통상은 우선 미소한 정후가 나타나고 점차로 그것이 커져서 최종적으로 短絡 등의 重大障害를 일으킨다. 즉 豫測保全 시스템은 캐치할 수 있는 정후가 작으면 작을수록 시스템으로서의 性能이 좋다고 하겠다. 이 性能은 센서 자체의 性能과 센서出力を 처리하는 情報處理性能의 둘로 나누어 생각할 수 있다.

異常現象으로서 部分放電을 검토하면 소리, 빛, 熱, 가스의 分解, 電磁波, 突發電流 등 여러 가지 정후가 발생하므로 센서로 이것들을 검지하면 된다. 구체적으로는 機械的인 振動을 검지하는 加速度센서, 電壓의 變化를 검지하는 部分放電센서, 絶緣가스의 分解를 검지하는 가스체커 등이 있다.

한편 센서出力의 情報處理에 관해서 살펴보면 종래의 방법은 기본적으로 레벨判定이다. 즉 센서出力이 미리 정해진 영역값보다 크면 异常으로, 영역값보다 작으면 正常으로 판정한다. 통상 异常 때에는 센서出力이 크므로 레벨判定에 따라 대단히 정도 높은 异常임을 판정할 수가 있다. 그러나 센서出力이 크다고 해서 반드시 异常일 수는 없고 正常임에도 불구하고 雜音 때문에 센서出力이 커져서 그 결과 正常을 异常으로 誤判하는 경우가 있다. 또 판정할 수 있는 것도 异常인가 아닌 가일 뿐이고 异常을 보다 더 상세하게 알기는 어려우므로 보다 高度한 處理알고리즘의 개발이 기대되고 있다.

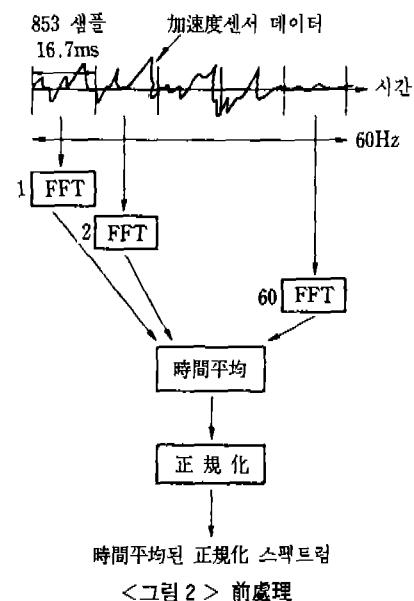
### 3. 試驗데이터

試驗데이터는 그림 1에 표시하는 것과 같이 正常을 포함하는 6개의 异常 모델을 想定하여 공장 실험으로 얻은 것이다. 异常으로서는 탱크 내부에 金屬異物이 있는 경우와 接觸不良을 想定하였다. 异物의 존재는 GIS의 中心導體나 탱크內壁에 고정시킨 경우와 어디에도 고정시키지 않고 浮遊하



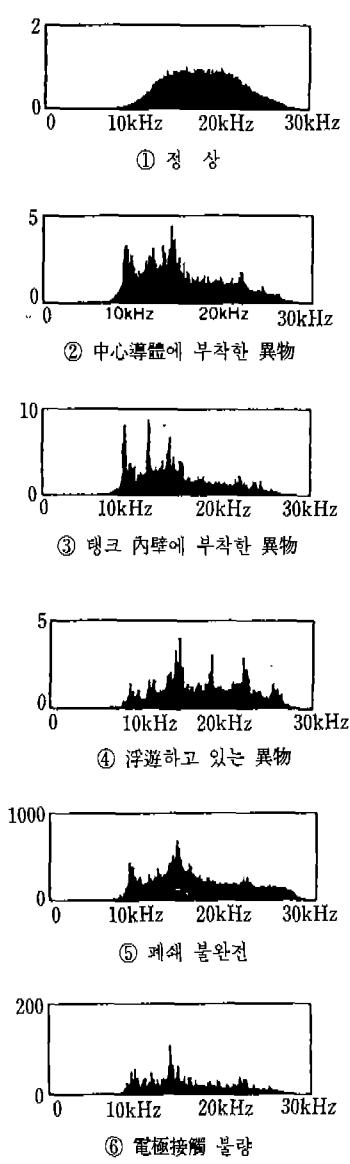
고 있는 경우의 3종류로 모델화하였다. 接觸不良은 中心導體가 완전히 달하지 않고 약간의 缺鎖이 있는 缺鎖不完全인 경우와 電極의 接觸不良을 想定한 모델이다.

이들의 异常原因是 어느 것이나 部分放電을 일으키고 그것이 GIS 内部의 絶緣가스를 진동시켜



결과적으로 미소하긴 하지만 탱크 自體를 기계적으로 진동시킨다. 여기서는 센서로서 加速度센서를 사용하고 있으며 이 기계적 진동을 加速度의 변화로서 檢知하고 있다. 그림 2에 표시하는 것과 같이 센서信號는 60Hz 電源에서 1/60초의 1사이클에 853點 샘플링된다. 그 다음에 FFT(Fast Fourier Transform)에 의하여 스펙트럼으로 변

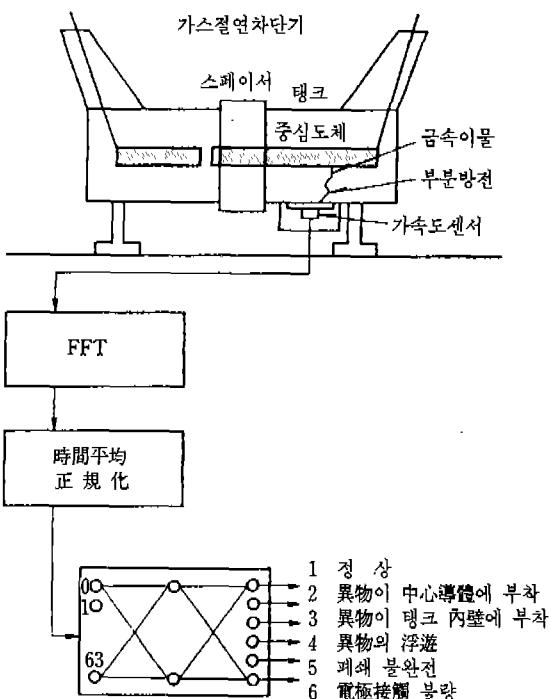
환되고 불필요한 雜音을 低減시키기 위하여 또 1초간 平均을 한다. 그림 3에 時間平均된 스펙트럼을 나타낸다. 뉴럴네트워크에 入力할 때는 또 스펙트럼强度의 正規化를 행하지만 그림에 표시된 것은 그렇게 하기 전의 상태이다. 또한 그림에서 縱軸 스키일이 각각 다르게 되어 있는 것에 주의하기 바란다.



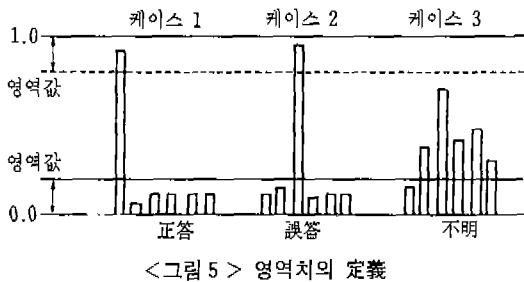
<그림 3> 스펙트럼의例

#### 4. 간단한 適用

간단한 뉴럴네트워크의 適用을 그림 4에 든다. 사용하고 있는 뉴럴네트워크는 3층의 피드퍼워드型으로 入力層, 中間層, 出力層은 각각 64, 50, 6뉴론으로 되어 있다. 加速度센서의 스펙트럼은 1,024차원이므로 密度變換에 의하여 入力層의 64차원으로 변환하고 있다. 또 뉴론의 入力은 크기가 통상 0에서 1까지므로 스펙트럼의 最大振幅을 1에 正規化하고 있다. 出力層의 각 뉴론은 異



<그림 4> 간단한 뉴럴네트워크의 적용



<그림 5> 영역치의 定義

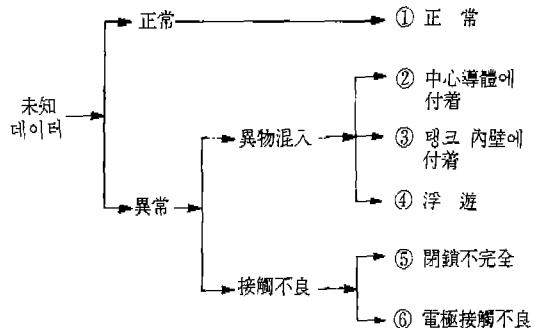
常原因에 대응하고 있다.

뉴론의 出力은 아날로그값이므로 뉴럴네트워크의 성능을 평가하기 위하여 出力值에 대한 해석을 그림 5와 같이 정의한다. 그림에서는 出力뉴론이 6개 있고 그 중에서 1개의 異常原因是 분류화 정한다. 올바른 異常原因是 最左端의 뉴론에 대응하고 있다. 그 이외의 뉴론은 0을 出力하는 것이 이상적이다. 그래서 여기서는 영역치를 설정하여 1을 出力하여야 할 뉴론은 1로부터 영역치 이내의 값, 0을 出力하여야 할 뉴론은 0으로부터 영역치 이내의 값이고, 1을 出力하고 있는 뉴론이 단 하나이고 특히 그 뉴론이 올바른 原因에 대응하고 있을 때를 正答으로 하기로 한다. 그림에서는 케이스 1이 正答이다. 케이스 2는 1을 出力하고 있는 뉴론은 단 하나이긴 하지만 올바른 原因과는 다른 原因의 出力뉴론이므로 誤答이 된다. 그 이외는 正答도 아니고 誤答도 아니기 때문에 不明으로 정의한다.

## 5. 모듈型 뉴럴네트워크

앞의 절에서는 센서의 스펙트럼을 入力으로 하고 원인을 出力으로 하는 것과 같은 간단한 뉴럴네트워크의 적용에 대하여 기술하였지만 整備員의 思考過程이나 整備節次, 뉴럴네트워크의 學習時間 등을 고려하면 트리구조로 원인을 추정하는 편이 보다 적절하다고 생각된다.

整備員의 思考過程은 아마도 단계적이 아닌가 추정된다. 센서의 出力を 보고 우선 異常 여부를

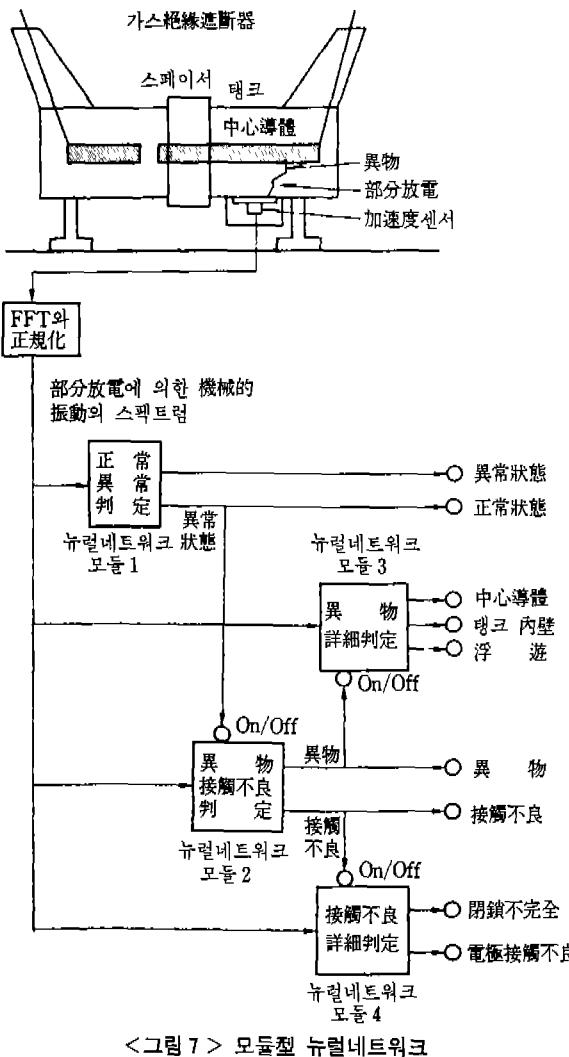


<그림 6> 異常狀態의 트리構造分類

판단하고 만일 異常이면 어떤 異常인가를 생각하게 된다. 또 整備節次에 관해서도 GIS가 正常이 아니라고 판단하면 運轉을 정지시키고 즉시 整備하지 않으면 안된다. 이때에 중요한 것은 故障原因을 상세하게 추정하는 일이 아니라 異常을 간과하지 않도록 하는 일이다. 따라서 상세한 故障原因의 규명은 일단 留保하여도 된다. 다만 運轉停止後에는 故障原因 또는 그 場所를 확정할 수 있으면 整備에는 대단히 유익하다. 이와 같이 整備節次도 또한 단계적으로 되어 있다고 생각된다.

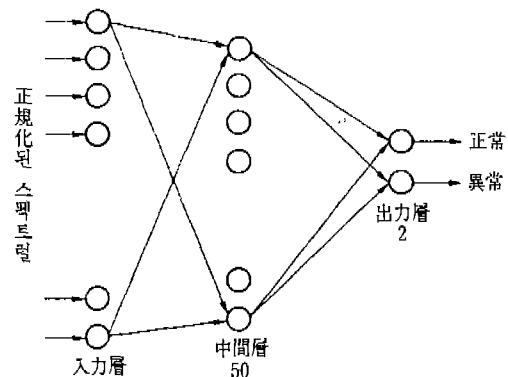
트리構造分類는 뉴럴네트워크의 學習時間의 低減이라든가 精度向上에도 쓸모가 있다. 階層的으로 분류할 때는 각 段階, 즉 트리構造의 각 노드에서 분류하여야 할 카테고리의 수가 직접 모두를 분류할 때에 비하여 적어진다. 예를 들면 2進木인 경우는 각 노드에서 분류하여야 할 카테고리 수는 2개이다. 통상 한 번에 多數를 분류하기보다는 2개로 분류하는 쪽이 훨씬 용이하므로 그 學習도 쉽고 속도도 빨라진다. 그림 6에 GIS의 異常原因을 추정하는 트리構造의 일례를 든다. 센서出力이 入力되면 먼저 正常인지 異常인지를 판정하고, 異常이라고 판정되면 그 原因이 異物의混入 때문인지 또는 接觸不良 때문인지를 판정하고 각각에 대하여 더욱 상세한 판정을 한다.

그림 7에 트리構造를 분류하는 모듈型 뉴럴네트워크를 나타낸다. 센서出力의 스펙트럼은 우선 모듈 1에 入力되고 거기서 正常인지 異常인지를

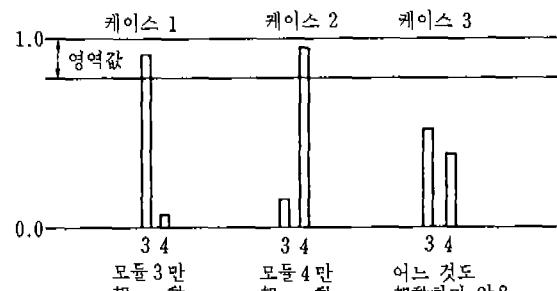


판정한다. 모듈 1의 구조를 그림 8에 든다. 正常에 대응하는 뉴론의 出力이 영역치보다 크면 GIS는 正常으로 판정된다. 逆으로 異常에 대응하는 뉴론의 出力이 영역치보다 크면 GIS는 異常으로 판정되고 상세한 것을 알기 위하여 모듈 2가 起動된다.

모듈 2는 구조적으로는 모듈 1과 같고 入力層에는 역시 センサー出力의 스펙트럼이 入力되어 異常原因이 異物混入인지 接觸不良인지를 판정한다. 만일 異物混入에 대응하는 뉴론의 出力이 크면 모듈 3이 起動되고 接觸不良에 대응하는 뉴론의



<그림 8> 모듈 1의構造



<그림 9> 각 모듈의起動

出力이 크면 모듈 4가 起動되어 보다 상세하게 異常原因을 분류한다. 예로서 모듈 2가 그子인 모듈을 어떻게 起動하는가를 그림 9에 표시한다. 또 트리構造에서 異常原因을 분류하였을 경우에는 최종결과 뿐만 아니라 각 노드에서의 판정 결과를 모두 사용할 수가 있다.

## 6. 시뮬레이션實驗에 의한 평가

영역치가 0.1인 경우의 시뮬레이션 결과를 그림 10~그림 12에 표시한다. 學習데이터의 個數는 可變이고 3절에 표시한 방법으로 얻은 약 100개의 試驗데이터로부터 亂數로 랜덤하게 선택하였다. 각 그림에서의 正答率 등의 수치는 學習데이터에 의해 학습시킨 뉴럴네트워크를, 試驗데이터

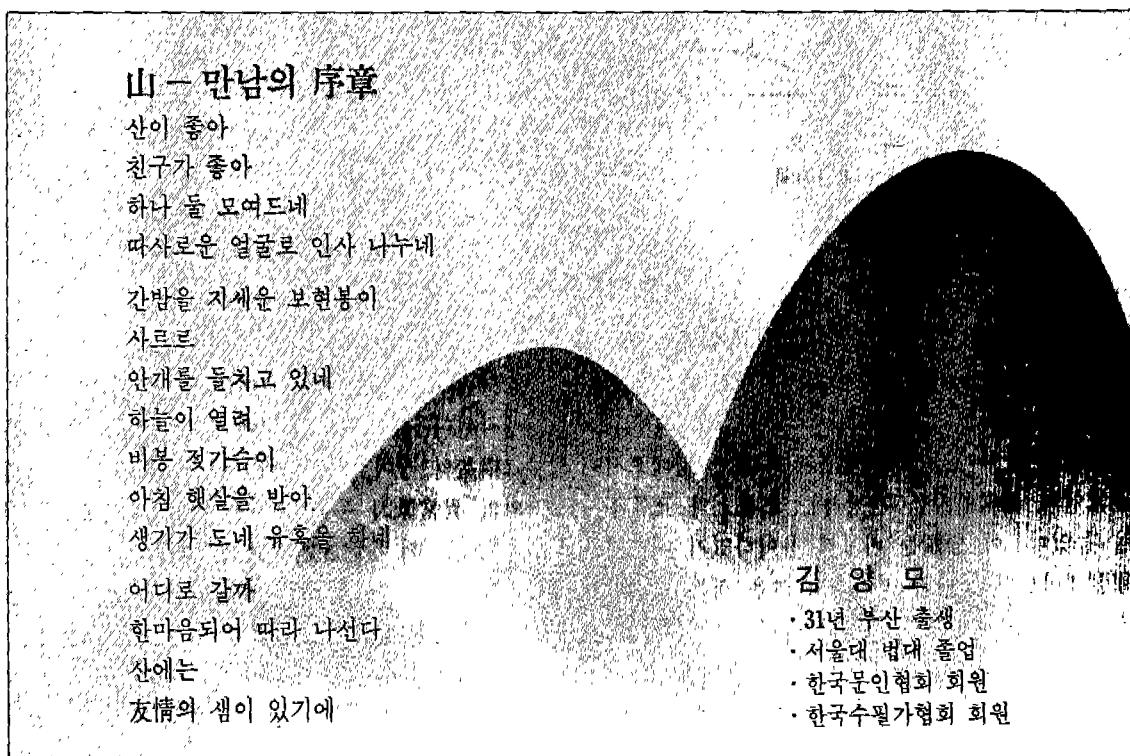
중 學習데이터에 사용하지 않은 데이터 즉 未學習데이터에 의한 평가결과이다. 간단한 적용에서 는 1회의 試行, 모듈형 뉴럴네트워크에서는 3회의 試行에 의한 平均值를 나타내고 있다.

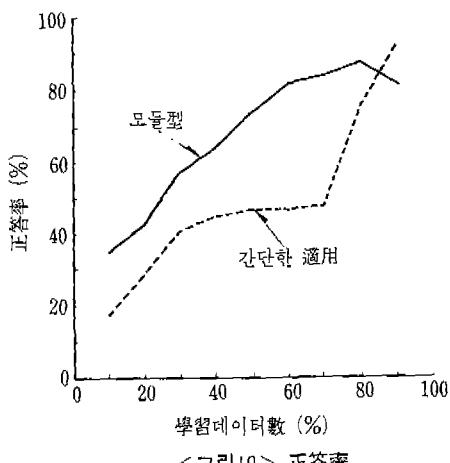
그림10에 의하면 간단한 적용과 모듈型 뉴럴네트워크 양쪽에 대하여 學習데이터가 증가할수록 正答率이 향상하는 것을 알 수 있다. 전체의 약 80% 이상의 學習데이터를 사용하면 80% 내지 90%의 正答率이 얻어진다. 영역차가 작기 때문에 誤答은 거의 없고 대부분이 不明으로 된다. 모듈型은 간단한 적용에 비하여 學習데이터가 적어도 正答率이 잘 低下하지 않는 것을 알 수 있다. 이것은 모듈화에 의하여 트리構造의 각 노드에서 분류하여야 할 카테고리數가 줄어듦으로써 분류가 쉬워졌기 때문이다. 또한 선택률 90%인 것일 때는 간단한 적용쪽이 正答率이 좋으나 이것은 試行回數가 적음으로써의 誤差라고 생각된다. 영역차를 크게 하면 評價基準이 엄하지 않게 되어

正答率은 향상하지만 逆으로 誤答率이 증가한다.

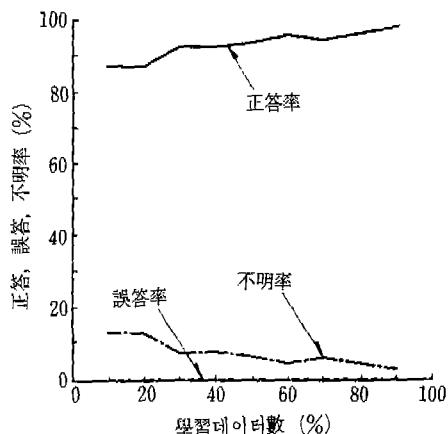
그림11은 모듈 3의 學習時間을 나타내고 있다. 사용한 學習알고리즘은 모멘트附의 誤差逆傳搬法으로 學習레이트 등의 패러미터는 學習데이터 수에 따라 動的으로 조정되어 있다. 선택률 90%인 때 간단한 쪽은 약 10시간, 모듈型 쪽은 모듈 1에서부터 순차로 약 10분, 1시간, 2시간, 15분이다. 모듈型의 학습은 각 모듈에 대하여 병렬로 실행할 수 있으므로 전체로서는 學習時間이 가장 긴 모듈 3으로 규정된다. 다만 예를 들면 모듈 4에 대하여서는 接觸不良과 관련된 學習데이터만으로 學習이 가능하다는 등 각 모듈에 대하여 필요한 學習데이터만 있으면 된다.

그림11에 표시하는 것과 같이 모듈型은 간단한 경우에 비해서 약 5배 學習이 高速으로 된다. 學習時間이 길다는 것은 그 모듈에 대응하는 분류가 어렵다는 것으로 異物混入時의 異物位置의 분류확정이 꽤 어렵다는 것을 나타내고 있다. 또한

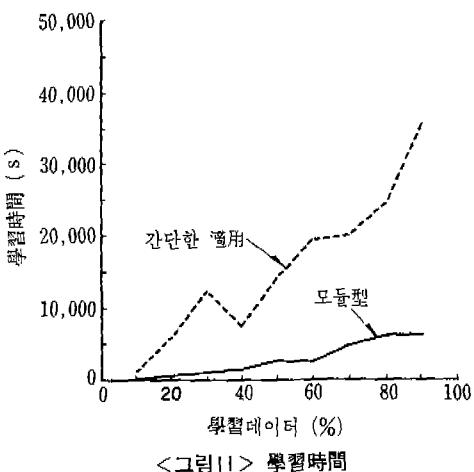




<그림10> 正答率



<그림12> 모듈 1의 正答率



<그림11> 學習時間

이速度差는 모듈構造에 기인하는 것으로 임의의高速學習 알고리즘을 각 뉴럴네트워크에 적용하였을 경우에도 모듈型의 상대적인 優位性에는 변함이 없다.

그림12에 각 모듈의 性能을 나타내는 일례로서正常인지 異常인지를 판정하는 모듈 1의 正答率을 들었다. 이 分類는 비교적 용이하였기 때문에學習데이터가 상당히 적더라도 높은 正答率을 나타내고 있다. 이 경우 誤答率은 거의 零이다. 또한 正答率이 좋다는 관점에서는 모듈 1, 4, 2, 3의 순으로 데이터 1개당의 學習時間이 짧은 순으로 되어 있다.

## 7. 맷음말

이論文에서는 GIS의豫測保全 시스템에 있어서의異常診斷에 뉴럴네트워크의 적용을 시도하였고, 惟서出力を 넣으면 異常原因을 直接出力하는 간단한 적용과 더불어 異常原因을 트리構造로 추정하는 모듈型 뉴럴네트워크를 시험하였다. 시뮬레이션實驗에 의하여, 특히 모듈型 뉴럴네트워크에서는, ① 學習데이터가 적어도 精度가 그리떨어지지 않으며, ② 각 모듈이 개별적으로 학습할 수 있고 또 대번에 상세한 분류를 하지 않고 단계적으로 분류하기 때문에 學習時間이 대폭 단축된다는 것을 나타냈다.

이들의 기초적인 시험결과는 GIS의豫測保全에 뉴럴네트워크適用의有用性을 나타내고 있다고 생각된다. 다만 實際運用에 임하여서는 GIS의 템크構造의 상이, 設置場所 특유의環境雜音, 想定외의異常原因 등을 고려할 필요가 있으며 이것들은 금후의檢討課題라고 생각한다.

<연재 끝>

---

本稿는 日本三菱電氣(株)의 諒解下에 번역한 것으로서. 著作權은 上記社에 있고 翻譯責任은 大韓電氣協會에 있습니다.